



Design and development of hybrid forecasting model using artificial neural networks and ARIMA methods for sustainable energy management systems: A case study in tobacco industry

Hamdi Giray Reşat*

Department of Industrial Engineering, Izmir University of Economics, Izmir, 35330, Turkey

Highlights:

- Design of hybrid forecasting model
- Generating feasible solutions for energy management decision makers in real-life cases
- Integration of ARIMA and artificial neural network models into energy management models

Keywords:

- Artificial Neural Networks
- Forecasting
- Energy Management

Article Info:

Research Article
Received: 12.07.2019
Accepted: 11.12.2019

DOI:

10.17341/gazimmfd.591248

Correspondence:

Author: Hamdi Giray Reşat
e-mail:
giray.resat@ieu.edu.tr
phone: +90 232 488 8465

Graphical/Tabular Abstract

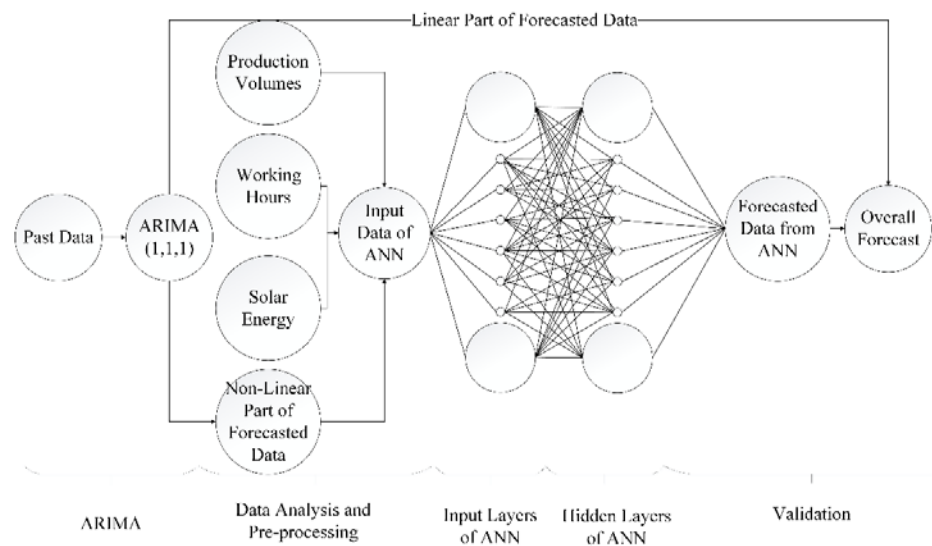


Figure A. General flow diagram for proposed hybrid forecast model

Purpose: The main purpose of this study is to design and develop a hybrid-forecasting model by using ARIMA and artificial neural networks for short-term energy estimation processes in energy management systems.

Theory and Methods:

Proposed hybrid forecast model starts with initial forecast data obtained by using ARIMA model based on past electricity consumption data sets. Then, obtained forecast data from ARIMA model is divided into linear and non-linear parts. Some of the other factors affecting electricity energy consumption and non-linear part of the initial forecast obtained from ARIMA are taken into consideration as input data for artificial neural network model. After considering the correlation between solar energy generation, working hours, production quantities and past electricity consumption data, various number of neurons and different training algorithms are tested in neural network to design the optimal system for the cases.

Results:

Proposed hybrid model is applied into a company operating in the tobacco products manufacturing industry and reliability of the model is tested by using real-life data set in illustrative cases. The proposed hybrid model provides around 39.9% improvement compared to forecast data obtained by using only ARIMA model.

Conclusion:

The main conclusions of the study are that proposed hybrid forecast model is able to capture and adapt itself against sudden oscillations occurred in real-life input data sets better than ARIMA models. In addition, there is a significant improvement in terms of total error percentages between actual and forecast values, especially compared with single ARIMA models.



Sürdürülebilir enerji yönetimi için yapay sinir ağları ve ARIMA metotları kullanılarak melez tahmin modelinin tasarlanması ve geliştirilmesi: Tütün endüstrisinde vaka çalışması

Hamdi Giray Reşat*

İzmir Ekonomi Üniversitesi, Endüstri Mühendisliği Bölümü, İzmir, 35330, Türkiye

ÖNEÇIKANLAR

- Melez tahminleme modeli tasarımı
- Enerji yönetiminde karar vericiler için gerçek hayat verilerine dayalı çözüm önerisi
- ARIMA ve yapay sinir ağı modellerinin enerji yönetim modellerine entegre edilmesi

Makale Bilgileri

Araştırma Makalesi
Geliş: 12.07.2019
Kabul: 11.12.2019

DOI:

10.17341/gazimmfd.591248

Anahtar Kelimeler:

Yapay sinir ağları,
enerji,
tahminleme

ÖZET

Çalışma kapsamında enerji yönetim sistemlerinde önemli bir yere sahip olan kısa vadeli enerji tahmin süreçleri için ARIMA ve yapay sinir ağları kullanılarak geliştirilen melez tahmin modeli ortaya konulmuştur. Bu model kapsamında tütün endüstrisinde üretim yapan bir firmadan elde edilen gerçek hayat verisi ile uygulama çalışmaları yapılarak sistemin güvenilirliği test edilmiştir. ARIMA yönteminden elde edilen sonuçlar doğrultusunda elektrik enerjisi tüketimini etkileyen faktörlerden bazıları göz önüne alınarak yapay sinir ağı modeline girdi verisi olarak eklenmiştir. Ele alınan veri setlerinde güneş enerjisi üretimi, çalışma saatleri, tütün ürünlerine ait üretim miktarları ve geçmiş elektrik enerjisi tüketim verileri arasındaki korelasyona bakılarak, çeşitli nöron sayıları ve farklı eğitim algoritmaları deneyerek planlaması yapılmak istenilen şirket için en uygun sistem tasarımı yapılmıştır. Elde edilen bilgiler ışığında geliştirilen melez tahmin modeli, sadece ARIMA modeli ile yapılan tahmin verilerine göre %39,9'luk bir iyileştirme sağlamaktadır.

Design and development of hybrid forecasting model using artificial neural networks and ARIMA methods for sustainable energy management systems: a case study in tobacco industry

HIGHLIGHTS

- Design of hybrid forecasting model
- Generating feasible solutions for energy management decision makers in real-life cases
- Integration of ARIMA and artificial neural network models into energy management models

Article Info

Research Article
Received: 12.07.2019
Accepted: 11.12.2019

DOI:

10.17341/gazimmfd.591248

Keywords:

Artificial neural networks,
forecasting,
energy management

ABSTRACT

This study presents a design and development of hybrid forecasting model by using ARIMA and artificial neural networks for short-term energy forecasting processes in energy management systems. Proposed model is applied into a company operating in the tobacco products manufacturing industry and reliability of the model is tested by using real-life data set in illustrative cases. In line with the results obtained from ARIMA method, some of the factors affecting electricity consumption are taken into consideration as input data for artificial neural network model. After considering the correlation between solar energy generation, working hours, production quantities and past electricity consumption data, various number of neurons and different training algorithms are tested to design the optimal system for the company. The proposed hybrid model provides around 39.9% improvement compared to forecast data obtained by using only ARIMA model.

*Sorumlu Yazar/Corresponding Author: giray.resat@ieu.edu.tr / Tel: +90 232 488 8465

1. GİRİŞ (INTRODUCTION)

Dünya ticaret faaliyetlerinde küresel rekabet koşulları, sosyo-ekonomik gelişmeler ve çevreye olan duyarlılık koşulları göz önüne alındığında firmaların tedarik zinciri yönetim süreçlerinde önemli değişimler meydana gelmektedir. Küreselleşen ticari aktivitelerin sonucunda ortaya çıkan ihtiyaçların ve sistemsel karmaşıklıkların sürdürülebilir bir perspektifte giderilmesi için firmalar yenilikçi, adaptif yönetim ve planlama destek sistemleri geliştirmeye başlamışlardır. Bu dönüşüm süreci içerisinde firmaların özellikle sürdürülebilirlik faaliyetleri içerisinde en önemli konulardan birine sahip olan enerji tüketimi ön plana çıkmaktadır. Enerji ve Tabii Kaynaklar Bakanlığının çalışmasına göre bütün sektöründe üretim faaliyeti gösteren firmaların toplam operasyonlara ait giderlerinin %3-6'sını enerji masrafları oluşturmaktadır [1]. Bu bağlamda senelik üretimlerini minimum duraksamalar ile devam ettiren sektör genelinde kısa/orta vadeli enerji tüketimine ait planlamalar oldukça önemli bir rol oynamaktadır. Gerek şebeke hatlarından çekilen enerji miktarları, gerekse de kendi bünyelerinde kurmuş oldukları enerji üretim tesislerine (örneğin, kojenerasyon, trijenerasyon üniteleri, yenilebilir enerji sistemleri, vb.) ait planlamaların doğru ve zamanında yapılması ile enerji sistemlerine ait maliyetlerin minimum seviyelere indirilmesi mümkün olabilmektedir. Üretim sektöründe faaliyet gösteren firmalar kısa ve orta vadede enerji tüketimlerini planlayarak ve kontrol mekanizmalarını gerçekleştirerek elektrik kesintilerinden kaynaklanan üretim duraksamalarının önüne geçebilmektedirler. Ayrıca, makro perspektiften bakıldığında geliştirilecek olan sürdürülebilir enerji yönetim mekanizmaları ile firmaların olası enerji tasarruf potansiyelleri ile maliyetlerini en aza indirerek, kar oranlarında iyileştirmeler yapabileceklerdir. Bu iyileşme sayesinde firmaların ulusal/uluslararası platformda rekabet seviyeleri artarak, kaynaklarını daha verimli bir şekilde kullanmaları sağlanacaktır. Ayrıca, planlama mekanizmalarının geliştirilmesi ile ortaya çıkacak tasarruflar ile firmaların enerji üretim sistemlerinde yenilebilir ve çevreci enerji sistemlerinin (güneş panelleri, rüzgâr türbinleri, vb.) kullanım oranları da artırılacaktır.

Firmaların bütünsel planlama yöntemlerine geçmeden önce geçmiş enerji tüketim verilerinin analizleri yapılarak ve anlamlandırılarak, sisteme doğru bir tahmin verisinin verilmesi gerekmektedir. Tahmin süresince kullanılacak olan modeller ve ilgili çözüm algoritmaları literatürde oldukça geniş bir yer almaktadır. Debnath ve Mourshed [2] enerji planlama modellerinde kullanılacak tahmin yöntemlerini sistematik bir sınıflandırma kullanarak paylaşmıştır. Geliştirilecek olan tahmin modelinin bölgesel özellikleri (şirket, şehir veya ülke bazlı); tahmin periyotları (kısa, orta ve uzun vade) ve geliştirilecek olan model içeriğine göre çeşitlilik göstereceğini belirtmiştir. Kim vd. [3] kısa ve orta vadeli talep tahmin yöntemlerinde genellikle istatistiksel metotlar ve yeni nesil derin öğrenme metotları olmak üzere iki temel yaklaşımın olduğunu vurgulamıştır. Tso ve Yau [4] karar ağacı ve yapay sinir ağı modellerini

elektrik tüketimine ait kısa vadeli tahmin aşamasında kullanmış ve elektrik tüketiminin temel özelliklerini izlemek için kademeli bir regresyon modeli önermektedir. Ancak bazı durumlarda geliştirilen modellerin karmaşıklık ve hesaplama performansı sınırları nedeniyle belirli problemler için farklı tahmin modellerinin kombinasyonları kullanılabilir. Örneğin, Meng vd. [5] gri modelin (GM) daha iyi tahmin yüzdesi elde ettiğini ve aylık verilerin özelliklerini göreceli olarak basit bir seriden ayırarak sezgisel davranışı ayıran ayrık dalgacık dönüşümü (DWT) kullanarak beklenen riski azalttığını öngörmektedir. Zahan ve Kenett [6] R-istatistik modelleme ortamında yirmi yıllık veriyi kullanarak enerji tüketimini tahmin etmek için kesitsel bir model sunmaktadır. Elde edilen çözümünün değerlendirmesinde istatistiksel analiz yazılımından (SAS) elde edilen ortalama kare hata (OKH), kök ortalama kare hata (KOKH), ortalama mutlak hata (OMH) ve ortalama mutlak yüzde hata (OMYH) değerleri hesaplanmaktadır. Es vd. [7] kurulan yapay sinir ağı modelinin tahmin performansını çoklu doğrusal regresyon tekniği ile karşılaştırarak ortalama kare hata değerleri arasındaki farkı ortaya koymuştur. Zhang vd. [8] kurumsal bir binanın enerji tüketimini tahmin etmek için ağırlıklı destek vektör regresyonu (SVR) modeli sunmaktadır. Modeldeki parametrelerin optimizasyonu için, karmaşık veri serileri için diferansiyel evrim (DE) algoritması kullanılmaktadır. Rahman vd. [9] saatlik veya daha kısa sürelerde yapılan ölçümler gibi orta-uzun vadede elektrik enerjisi talebinin karşılanması, dağıtım ve depolama operasyonlarının yönetimi ve planlanması için elektrik tüketimini optimize etmek ve elde edilen çözümleri iyileştirmek için yinelenen sinir ağı (RNN) modelini önermiştir. Tahmassebi ve Gandomi [10] hesaplamalı ve algoritma tabanlı sistemler tarafından hesaplanan enerji performansının yapılan öngörüler, veri güvenilirliği ve sistemlerin karmaşıklığı nedeniyle gerçek durumları yansıtmadığını, bu nedenle yapılacak tahminlerdeki hata oranını en aza indirmek için mekanik paralel algoritmalar kullanılması gerektiğini vurgulamıştır. Singh ve Dwivedi [11] genetik programlama (GA), yapay sinir ağı (YSA) ve destek vektör regresyon (SVM) yöntemlerinin, ortalama mutlak yüzde hatası (OMYH) açısından diğer yöntemlerden daha yüksek oranda başarılı çözümler paylaştığını göstermektedir. Mohan vd. [12] kısa vadede daha iyi tahminler yapmak için veriye dayalı stratejiyi temel alan dinamik mod ayrıştırma (DMD) modelini önermiştir. Ruiz [13] bina enerji tüketimlerine ait yapay sinir ağı (YSA) ve elman sinir ağı (ENN) kullanılarak optimum modeller elde etmek için genetik algoritma tabanlı model kullanmıştır. Anvari vd. [14] sezgisel talebin etkisinin gerçek zamanlı tahminlerde göz önünde bulundurulması gerektiğini ortaya koymaktadır. Katsatos ve Moustris [15] binalardaki enerji tüketimini tahmin etmek için Yapay Sinir Ağları (YSA) kullanan bir tahmin aracı geliştirmiştir.

Ancak, tahmin yapılacak olan veri seti içinde doğrusal ve doğrusal olmayan parçaların bir arada bulunduğu durumlarda geliştirilen melez modellerin bireysel modellere kıyasla daha düşük hata yüzdesi verdiği gözlenmiştir. Bu

konuda ilk çalışma Zhang [16] tarafından ortaya konularak veri setinin doğrusal ve doğrusal olmayan kısımları ayrıştırılarak otoregresif bütünlük hareketli ortalama modeli (ARIMA) ve yapay sinir ağlarının beraber kullanıldığı melez bir modele dahil edilmiştir. Demirel vd. [17] adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve otoregresif hareketli ortalama (ARMA) teknikleri ile elektrik enerjisi talep tahmini yapmış ve aralarındaki farkları ortaya koymuştur. Khashei ve Bijari [18]; Babu ve Reddy [19] geliştirmiş oldukları melez modellerde veri setlerinin doğrusal kısımları için ARIMA yöntemini kullanmışlardır, Khandelwal vd. [20] ise dalgalı dönüşüm yöntemini (DWT) ve De Oliveira ve Ludermir [21] doğrusal vektör makinası (DVM) kullanmıştır. Basoglu ve Bulut [22] Türkiye'nin piyasa ve mevsimsel koşulları göz önüne alarak yapay sinir ağları ve uzman sistemlerin birlikte kullanıldığı kısa vadeli elektrik talep tahminlerinde yüksek doğruluk derecesi sağlayan bir melez sistem geliştirmiştir. Xiao vd. [23] yapmış olduğu geniş ölçekli literatür taramasında geliştirilen melez modellerin temelinde iki ana metodu kullanıldığı gözlenmiştir. Bunlar benzetimli tavlama ve böl-yönet yöntemleridir. Karadede vd. [24] 15 yıllık doğal gaz tüketim verisini kullanarak genetik algoritma ve benzetimli tavlama yöntemlerini kullanarak geliştirmiş oldukları melez model ile doğrusal olmayan veri setlerinin tahminlerini yapmaktadır. Li vd. [25] ortaya sundukları kombinasyon modellerinde yakıt tüketimine ait tahmin yapmış, özellikle geliştirdikleri yirmi altı farklı modelin kıyaslamasını yaparak hata oranını minimize edecek bir kombinasyon modeli önermektedir. Zhang vd. [26] geliştirmiş oldukları melez tahmin modeli kapsamında iteratif olarak farklı kombinasyonlar ortaya sunarak ham petrol fiyatlarını tahmin etmeye çalışmaktadır. De Oliveira ve Oliveira [27] orta vadeli enerji tüketim verisini sezona bağlı ARIMA ve üssel düzleme metodlarının melez yapısı ile torbalama algoritmasını kullanarak tahminini yapmaktadır. Wang vd. [28] kömür üretim sektöründe fazla üretim miktarını destek vektör makinaları, ARIMA ve deneye dayalı modüller ayrıştırma modellerinin kombinasyonlarını kullanarak tahminini yapmaktadır.

Bu çalışma ile birlikte aşağıda listelenmiş olan temel bulgu ve yöntemlerin karar vericiler ile paylaşılması ve enerji tahmin çalışmalarına katkı sunması beklenmektedir.

- Tütün endüstrisinde enerji tüketimine yönelik tahmin güvenilirliğini arttırmak için kapsamlı, otomatik, doğru ve hızlı öngörme çerçeveleri içerisinde melez tahmin modeli sunulmaktadır.
- Literatürde yer alan diğer melez tahmin modeli sunan çalışmalardan farklı olarak (örneğin, Zhang [16]; Khashei ve Bijari [18]; Babu ve Reddy [19]), tek tip hazır veri setleri kullanılmadan, sektörden bağımsız bir şekilde uygulanabilecek, dinamik üretim yapılarına sahip gerçek sanayi verisi kullanılarak, geliştirilen modelde uygulamaların yapılması ve anlamlı sonuç setlerinin elde edilmesi sağlanmıştır. Ayrıca, birden fazla veri seti YSA sistemine eş zamanlı sokularak, gerçek hayat dinamiklerinin elde edilecek olan tahmin verileri

üzerindeki etkisi artırılmaya çalışılmıştır. Örneğin, yapılan çalışmada elektrik tüketimine doğrudan veya dolaylı etkisi olduğu düşünülen gerçekleşen tütün ürünleri üretim miktarları, çalışma günleri ve güneş enerjisi üretim verileri de eş zamanlı olarak sisteme girdi verisi olarak kullanılmıştır.

- Literatürde yer alan diğer melez tahmin modellerinden (örneğin, Zhang [16]) farklı olarak ARIMA modeli ile elde edilen doğrusal zaman serisi tahminleri ve artık değerlerin ANN modellemesinde birlikte kullanılmasıdır. Elde edilen artık değerler ve diğer veri setleri (güneş enerjisi, üretim miktarları, vb.) YSA modeline girdi verisi olarak sokulmasına rağmen, ARIMA modelinden elde edilen doğrusal veri seti YSA modelinin hedef setine konularak girdi ve çıktı veri setleri arasında geçmiş veri setinin genel karakterlerini eş zamanlı ele alma imkanı tanımaktadır.
- İncelenen enerji tüketim veri serisinin doğrusal mı yoksa doğrusal olmayan bir temel işlemden mi üretildiğini veya belirli bir yöntemin örneklem dışı tahminlerde diğerinden daha etkili olup olmadığını gerçek hayatta kullanılan sistemlerde hızlı ve efektif olarak belirlemek mümkün olmamaktadır. Bu sebeple önerilen melez tahmin modeli sayesinde kontrol sistemlerinden dinamik olarak temin edilecek olan verinin planlaması yapılabilecektir.

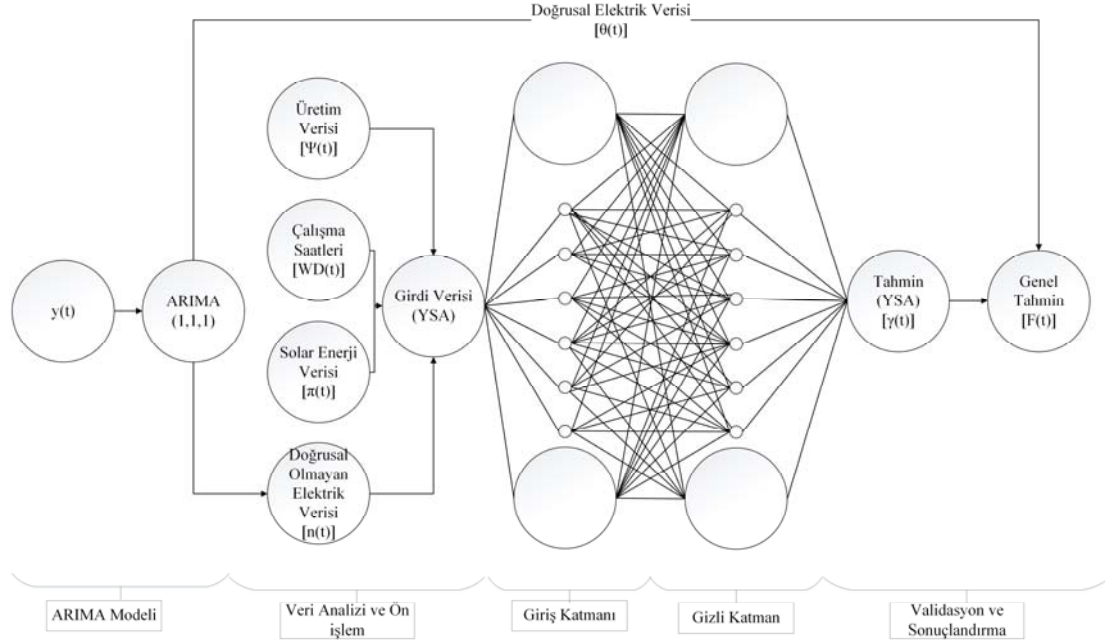
Bu çalışma 5 ana bölümden oluşmaktadır. Problemin tanımı ve detaylı literatür taramasının paylaşıldığı bu giriş bölümünden sonra, 2. Bölümde geliştirilecek olan melez tahmin metoduna ait detaylar paylaşılacaktır. 3. Bölümde geliştirilecek sistemde kullanılacak olan veri setinin detayları paylaşılacaktır. Ayrıca, sistem kapsamında kullanılan çeşitli varsayımlarda bu bölümde paylaşılacaktır. 4. Bölümde yapılan tahmin çalışmasına ait hesaplamaları ve ilgili sonuçlar paylaşılmıştır. 5. Bölümde ise elde edilen sonuçların yorumlanması yapılarak, gelecek araştırma imkânları ortaya konulmuştur.

2. METODOLOJİ (METHODOLOGY)

Araştırmada kullanılan temel yöntemler, gerçek hayat problemi için geliştirilmiş melez tahmin modelinin detayları ve çözüm akışı bu bölümde açıklanmaktadır.

2.1 Problem Tanımı (Problem Definition)

Bu çalışma kapsamında tütün ürünleri üretim endüstrisinden elde edilen elektrik enerjisi tüketim verileri kullanılarak sürdürülebilir bir enerji yönetim sisteminin ilk aşaması olan geçmiş verinin anlamlı ve hızlı tahmininin yapılarak gelecek senaryoların planlamasının temelini teşkil edecek melez tahmin modeli tasarlanmış ve geliştirilmiştir. Geliştirilen model kapsamında Şekil 1'de de yer verildiği üzere geçmiş yıllara ait elektrik enerjisi tüketim verisi kullanılarak gelecek dönem elektrik enerjisi tüketimleri için tahmin çalışmaları yapılmıştır. Çalışmada, Ocak 2014 - Mart 2019 tarihleri arasında günlük bazda elektrik enerjisi tüketim verilerinin yer aldığı 1.655 adet gözlem veri seti olarak kullanılmıştır. Bu gözlem verisi fabrikanın bakım, resmi tatiller, vb. sebepler ile üretimin olmadığı zaman dilimlerine ait günlük



Şekil 1. Geliştirilen melez tahmin modelinin genel akış diagramı (General flow diagram for proposed hybrid forecast model)

verileri içermemektedir. Bu tahmin süreci gerçek sanayi verisinin Genişletilmiş Dickey-Fuller birim kök testi ile temel özelliklerinin analizi ile başlamaktadır. Bu test kapsamında oto regresyon modeli kullanılarak farklı artık değerlere ait kriterlerin optimize edilmesi sağlanmaktadır. Bu bağlamda, aşağıda paylaşılan hipotezler test edilmiştir.

- H_0 : Elektrik enerjisi tüketim miktarı durağan değildir (zamana bağlıdır)
 H_1 : Elektrik enerjisi tüketim miktarı durağandır (zamana bağlı değildir)

Öne sürülen boş hipotez (H_0 : veri setinin durağan olmaması) baz alınarak uygulandığında elde edilen p -değerinin %5'lik kritik seviyenin altında olup olmadığı ve t -istatistik değerlerinin MacKinnon kritik test değerlerine [29] göre konumu değerlendirilerek test edilmiştir, veri setinin durağan olmadığı ve zamana bağlı olarak sabit artış gösterdiği anlaşılmaktadır. Sonrasında ilgili veri seti ARIMA modeline sokularak verinin doğrusal ve doğrusal olmayan parçaları (artık değerleri) temin edilmiştir. ARIMA modelleri pozitif tam sayı değeri alan üç önemli parametre (p , d ve q) ile tanımlanmaktadır. Bu parametrelerden p oto regresyon modelin sırasını (zaman gecikme sayısı), d verilerin geçmiş değerlerine göre farklılaşma derecesini ve q hareketli ortalama modelinin sırasını göstermektedir. p ve q 'nin belirlenmesinde veri setine ait oto korelasyon fonksiyonu (ACF) ve kısmi oto korelasyon fonksiyonu (PACF) grafiklerinden faydalanılmıştır. Bu grafiklerde güven sınırına (0,05) ulaşma yaklaşımına bağlı olarak ilgili p ve q değerleri bulunmuştur. d değeri ise Genişletilmiş Dickey-Fuller birim kök testinin sonucu doğrultusunda tanımlanmıştır. ARIMA modelinden çıkan tahmin değeri doğrusal parça olarak öngörülerek sistemin sonuna gönderilmiştir. Doğrusal olmayan artık verisi (gerçek ve

tahmin arasındaki fark) yapay sinir ağı modelinin girdi verilerinden bir tanesi olarak sistemde devam etmektedir. Elektrik tüketimine doğrudan veya dolaylı etkisi olduğu düşünülen diğer girdi verileri (özellikle gerçekleşen bütün ürünleri üretim miktarı, çalışma günleri ve güneş enerjisi üretim verileri) de bu aşamada yapay sinir ağı modeline dahil edilmiştir. Yapay sinir ağlarının eğitilmesinde Levenberg-Marquardt, Bayes regülasyonu ve Ölçekli Eşlenik Gradyan algoritmaları kullanılarak denemeleri yapılmıştır. Gavin [30] belirttiği üzere Levenberg-Marquardt metodu doğrusal olmayan fonksiyonların karelerinin toplamı olan fonksiyonunun minimumunu bulmak için Gauss-Newton metoduna alternatif olarak ortaya sunulmuştur. Levenberg-Marquardt algoritması iki minimizasyon yöntemi olan gradyan iniş yöntemi ve Gauss-Newton yöntemlerinin kombinasyonunu kullanmaktadır. Metodun çözüm algoritmasında parametreler optimal değerlerinden çok uzaktayken gradyan-iniş metodu gibi davranmaktadır ve parametreler optimum değerlerine yakın olduğunda Gauss-Newton metodu gibi davranmaktadır. Askin vd. [31] çalışmasında Bayes Regülasyonu metodunun Levenberg-Marquardt algoritmasına göre ağırlık ve bias değerlerini kullanarak farklı alternatifler içerisinde OKH değerini minimize etmeye çalıştığını belirtmiştir. Moller [32] ölçekli eşlenik gradyan yönteminin Taylor ikinci dereceden yaklaşım modelleri kullanılarak arama yönünü ve adım boyutunu seçerek çözüm setine daha kısa sürede ulaşmaya çalıştığını belirtmiştir. Her bir metod için nöron sayıları ayrı ayrı 5, 10, 15, 20, 25 olarak ve veri eğitim verilerini %60, %65, %70, %75, %80 oranlarını farklı kombinasyonlar halinde çalıştırarak en düşük hata yüzdesine sahip kombinasyonun bulunması sağlanmıştır. Bu kombinasyona ait çıktılardan ARIMA modelinden gelen doğrusal veri tahmini ile birleştirilmesi ile nihai tahmin değerine ulaşılmıştır.

2.2 Model Formülleri (Model Formulation)

Setler :

- t : Zaman aralığı (t: 1, .. , T)
i : YSA gizli katman nöron sayısı (i: 1, ..., H)

Sabitler :

- p, d, q : ARIMA modeli sabitleri
 ω_t : ARIMA modelinde oto korelasyon katsayısı
 δ_t : ARIMA modelinde hareketli ortalama katsayısı
 y_t : Her periyot t için gerçek elektrik enerjisi tüketim verisi [kW-h]
 φ_t : Her periyot t için tütün ürünleri üretim verisi [milyon adet]
 WD_t : Her periyot t için çalışılan gün sayısı [gün]
 π_t : Her periyot t için güneş enerjisi üretim verisi [kW-h]

Değişkenler :

- n_t : Her periyot t için ARIMA modelinden çıkan doğrusal olmayan elektrik tüketim verisi
 θ_t : Her periyot t için ARIMA modelinden çıkan doğrusal elektrik tüketim verisi
 γ_t : Her periyot t için YSA modelinden çıkan elektrik tüketim verisi tahmini
 F_t : Her periyot t için melez modelden çıkan elektrik tüketim verisi tahmini
 ϵ_t : Her periyot t için YSA modelinden çıkan elektrik tüketim verisi tahmin hatası
 β_{ij} : YSA modelinde giriş ve gizli katmanlar arasındaki i ve j nöronları arasındaki bağlantı katsayısı
 α_i : YSA modelinde giriş katmanındaki nöron i'lerin bağlantı katsayısı

Denklemler

$$\min z = \frac{1}{T} \sum_{t=1}^T (y_t - F_t)^2 \quad (1)$$

$$\gamma_t = \alpha_0 + \sum_{i=1}^H \frac{\alpha_i}{1 - \exp(-(\beta_{0i} + \beta_{1i}n_{t-1} + \beta_{2i}\pi_{t-1} + \beta_{3i}WD_{t-1} + \beta_{4i}\varphi_{t-1})) + \epsilon_t} \quad (2)$$

$$\forall t \in T \quad (3)$$

$$y_t = n_t + \theta_t, \quad \forall t \in T \quad (3)$$

$$F_t = \gamma_t + \theta_t, \quad \forall t \in T \quad (4)$$

$$N_t = \omega_1 y_{t-1} + \omega_2 y_{t-2} + \dots + \omega_p y_{t-p} + \delta_1 \epsilon_{t-1} + \delta_2 \epsilon_{t-2} + \dots + \delta_q \epsilon_{t-q}, \quad \forall t \in T \quad (5)$$

$$n_t, \theta_t, \gamma_t, F_t, \epsilon_t \geq 0, \quad \forall t \in T \quad (6)$$

Geliştirilen melez tahmin modelinde kullanılan eşitlikler yukarıdaki gibi paylaşılmıştır. Eş. 1 geliştirilen modelin hedef fonksiyonunu göstermektedir. Gerçekleşen veri ile model sonucunda tahmin edilen veri arasındaki ortalama kare hata miktarını minimize etmeye çalışmaktadır. Eş. 2 ise yapay sinir ağlarında girdi verileri ile tahmin verisi arasındaki ilişkiyi ortaya koymaktadır. Nöronlar arasındaki ağ katsayıları kullanılarak sistemin r^2 değerini 1'e yaklaştıracak şekilde eğitilmesi ve tahmin sonuçlarının elde edilmesini sağlamaktadır. Eş. 3 ARIMA modelinden elde edilen doğrusal ve doğrusal olmayan parçaların toplamının sisteme verilen ham veri setine eşit olduğunu ifade etmektedir. Eş. 4 ise melez modelin ortaya koymuş olduğu yöntemi açıklamaktadır. Bu yöntemde ilk etapta ARIMA modelinden elde edilen doğrusal veri seti ile yapay sinir ağlarından elde edilen tahmin sonuçlarının toplanarak nihai tahmin veri setini oluşturmaktadır. Eş. 5 sisteme verilen geçmiş elektrik tüketim verilerinin alınarak ARIMA modelinde doğrusal ve doğrusal olmayan parçalarının elde edilmesinde kullanılmaktadır. Bu denklem sonunda elde edilen tahmin verileri gerçek veri setinden çıkartılarak yapay sinir ağlarının girdilerinden bir tanesi olarak sisteme yüklenmiştir. Eş. 6 ise değişkenlerin pozitif değer almasını sağlamaktadır.

3. UYGULAMALI HESAPLAMALAR (COMPUTATIONAL EXPERIMENTS)

Tütün ürünleri üretim sektöründe faaliyet gösteren bir firmadan elde edilen gerçek yaşam verileri kullanılarak bir vaka çalışması yapılmıştır. Bu vaka çalışmasının amacı, iki aşamalı melez tahmin yaklaşımının tasarlanması ve sürdürülebilir enerji yönetim sisteminin tasarımında girdi olacak ayrıntılı hesaplamaları göstermektir. Geliştirilen melez tahmin modelinde gerçek ve tahmin verilerinin arasındaki ortalama kare hata değerinin minimize edilmesi hedeflenmektedir.

3.1. Data (Data)



Bu bölümde, şirket için önerilen melez tahmin sisteminin tasarım ve geliştirilmesinin kapsamlı analizi için gerekli olan tüm veriler paylaşılmaktadır. Geliştirilen tahmin modelinde kullanılmak üzere Ocak 2014 - Mart 2019 tarihleri arasında günlük bazda elektrik enerjisi tüketim verilerinin yer aldığı 1.655 adet gözlem veri seti olarak kullanılmıştır. Tablo 1'de veri kümesi özellikleri özetlenmiştir.

Şekil 2, günlük ve aylık olarak temsil edilen 2018 yılına ait elektrik enerjisi tüketiminin (kWh) üç boyutlu grafiğini göstermektedir. Tüketim verilerindeki düşük seviyeler üretimin olmadığı günlere, yüksek seviyedeki veriler ise üretim planını karşılamak için fabrikanın fazla mesai yaptığı günlere ait elektrik tüketimini göstermektedir.

Şekil 3 de ise yapay sinir ağı modelinin girdilerinden olan ve elektrik enerjisi tüketimi ile doğrudan ilişkili olan tütün ürünlerine ait üretim miktarı verisi ve dolaylı olarak ilişkilendirilebilecek güneş enerjisi üretim verileri

Tablo 1. Veri kümesine ait detay bilgiler (Details of the data set)

Veri Tipi	Veri Birimi	Minimum Değer y_{min}	Maksimum Değer y_{max}	Ortalama Değer (\bar{y}_t)	Standart Sapma (σ_{y_t})	Çarpıklık	Basıklık
Elektrik enerjisi tüketimi	kWh	81.129	113.111	96.978	9.045	0,29	-0,65

**Şekil 2.** 2018 yılı elektrik tüketim verilerine ait 3B ve kontör grafikleri [kWh]
(Contour and 3D graphs for 2018 electricity consumption)**Şekil 3.** Tütün ürünleri üretimi ve güneş enerjisi üretim miktarları
(Tobacco products manufacturing and solar energy production amounts)

paylaşmıştır. Güneş enerjisi üretim verisinin geliştirilen modele eklenmesindeki temel amaç güneş panellerinden elde edilen enerjinin hava durumu, bulutların dağılımı, rüzgar, vb. meteorolojik etkenlerden direk olarak etkilenmesi olarak ön görülmüştür. Bu sayede elektrik enerjisi tüketim verisine dolaylı olarak meteorolojik faktörleri de eklemek imkanı ortaya çıkmıştır. Geliştirilen modelin çözümünde R programlama dili ve MATLAB yazılımının beraber kullanıldığı bir ara yüz kullanılmıştır. Ham girdi verisinin okunarak gerekli analizlerinin yapılmasının ardından, veri setinin doğrusal ve doğrusal olmayan kısımlarının ayrıştırılması süreçlerinde R Stüdyo İstatistiksel Hesaplama programı 3.1.3 sürümü [33] kullanılmıştır. MATLAB R2017a yazılımı kullanılarak

çağrılan R programlama kodu, eldeki verilerle belirlenen sinir ağı düzeninin benzetiminin yapılabilmesi için MATLAB R2017a yazılımının sinir ağı araç paketini [34] çalıştıracak bir kodla senkronize edilerek modelin test edilmesi ve çalıştırılması sağlanmıştır. Önerilen model 2,50 GHz çift çekirdekli işlemci ve 4,00 GB RAM ile desteklenen Intel Core I5 2520 M CPU işletim sistemi kullanılarak çözümlenmiştir.

4. DENEYSEL SONUÇLAR (COMPUTATIONAL RESULTS)

Bu bölümde tütün ürünleri üretim sektöründe faaliyet gösteren bir firmadan elde edilen geçmiş dönemlere ait

elektrik enerjisi tüketim verisi kullanılarak yapılan tahmin çalışmasına ait hesaplamalar ve ilgili sonuçlar paylaşılmıştır. Önerilen metot ilk olarak çalışmanın girdi veri setinin detaylandırılması ile başlamıştır. Bu amaçla ilgili elektrik enerjisi tüketim veri setine Genişletilmiş Dickey-Fuller birim kök testi uygulanmıştır ve veri setinin genel yapısı anlaşılmaya çalışılmıştır. Bu bağlamda, aşağıda paylaşılan hipotezler test edilmiştir.

- H_0 : Elektrik enerjisi tüketim miktarı birim köke sahiptir (durağan değildir ve zamana bağlıdır)
 H_1 : Elektrik enerjisi tüketim miktarı birim köke sahip değildir (durağandır ve zamana bağlı değildir)

Yapılan test sonucunda Tablo 2’de yer verilen test sonuçları elde edilmiştir ve ham veri setinin %9,5’luk p -değeri ile %5’lik kritik eşiği aştığı ve aynı zamanda t -istatistik değerinin mutlak değerinin MacKinnon %1, %5 ve %10’luk seviyelerine ait kritik test değerlerinden az olmasından ötürü boş hipotezin reddedilemeyeceği ve veri setinin durağan bir yapıda olmadığı anlaşılmıştır. Ancak, veri setinin 1. derece farkı alınarak aynı birim kök testi uygulandığında elde edilen p -değeri (%3,9) kritik eşik olan %5’in altında olduğu ve aynı şekilde elde edilen t -istatistik değerinin mutlak değerinin farklı seviyelere ait kritik test değerlerinden fazla olmasından ötürü boş hipotezin reddedilerek veri setinin durağan bir yapıya kavuştuğu öngörülmüştür. Bu analiz sonucunda ARIMA modelinde kullanılacak olan gecikme

sayısının 1’e eşit olduğu gözlenmiştir ve d değeri 1 olarak alınması gerektiği öngörülmüştür.


İkinci olarak, geçmiş yıllara ait ham elektrik enerjisi tüketim verisi ARIMA modeline sokularak veri setinin doğrusal ve doğrusal olmayan kısımlarının ayrıştırılması planlanmıştır. Bu süreçte en düşük ortalama kare hata değerini verecek sistem parametrelerinin bulunması için korelasyon fonksiyonları kullanılmıştır. Şekil 4’de yer verildiği üzere ACF ve PACF grafikleri üzerinden yapılan yorumlama sayesinde p ve q değerlerinin (1, 1) olduğu gözlenmiştir. Bu bilgiler ışığında ARIMA(1,1,1) modeli kullanılarak ham veri seti doğrusal ve doğrusal olmayan kısımlarına ayrıştırılmıştır.

Yapay sinir ağı (YSA) eğitimine geçmeden önce ARIMA(1,1,1) modelinden gelen doğrusal olmayan veri seti, tütün ürünlerine ait üretim verisi, güneş enerjisi üretim miktarı, çalışma gün sayıları sisteme girdi bilgisi olarak verilmiştir. Şekil 5’de ise ARIMA modelinden elde edilen doğrusal ve doğrusal olmayan veriler paylaşılmıştır. Özellikle dalgalanmaların olduğu dönemlerde doğrusal olmayan veri çıktıkları ortaya çıkmaktadır ve sistemin planlanması ve tahmin edilebilirliğini negatif yönde etkilemektedir.

YSA uygulaması için Levenberg-Marquardt, Bayes Regülerizasyon ve Ölçekli Eşlenik Gradyan metodlarının

Tablo 2. Genişletilmiş Dickey-Fuller birim kök testi sonuçları (Augmented Dickey-Fuller unit root test results)

		d=0		d=1	
		t-istatistik değeri	p-değeri	t-istatistik değeri	p-değeri
		-3,1929	0,0948	-3,7696	0,0387
MacKinnon Kritik Test Değeri	%1 Seviyesi	-4,4407		-3,1319	
	%5 Seviyesi	-3,6329		-3,0048	
	%10 Seviyesi	-3,2546		-2,6423	

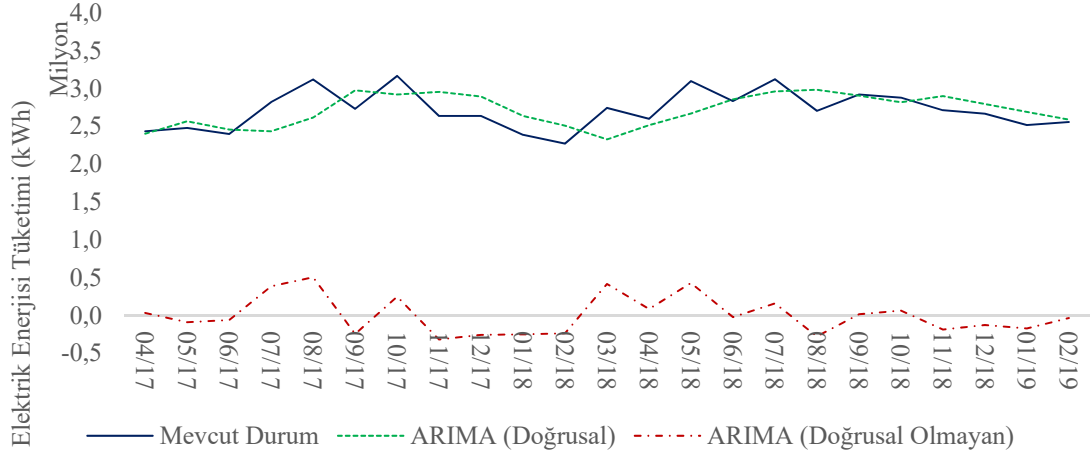


Şekil 4. Elektrik tüketim verisine ait ACF ve PACF grafikleri (ACF and PACF for electricity consumption values)

denemeleri yapılmıştır. Her bir metod için katmanları ayrı ayrı 5, 10, 15, 20, 25 olarak ve eğitim verilerini %60, %65, %70, %75, %80 oranlarını farklı kombinasyonlar halinde en az 5 kez ortalama kare hata (OKH) değeri alınarak denenmiştir. Tablo 3’de YSA uygulaması kapsamında eğitim, validasyon, test ve çıktı verilerine ait ayrı ayrı ortalama kare hata (OKH) değerlerine yer verilmiştir. Özellikle çıktı veri setleri içerisinde her bir metod için en düşük OKH değerlerine ait alternatifler koyu renkler ile gösterilmiştir. Örneğin, tüm analiz göz önüne alındığında en düşük OKH değeri ($3,91 \times 10^{10}$ kWh²) 15 katman ve %80 test

veri yüzdesi ile Levenberg-Marquardt metodu kullanılarak yapılan senaryodan elde edilmiştir. Ayrıca, tüm alternatifler göz önüne alındığında en düşük r^2 değerlerine Bayes Regülerizasyon metodu kullanıldığında elde edilmiştir. Bu kısıtlar altında gerçekleştirilen tahmin çalışmasına ait sonuçlar Şekil 5’de paylaşılmıştır.

Şekil 6’da yer verildiği üzere gerçekleşen elektrik enerjisi tüketim verisi ARIMA ve önerilen melez tahmin yöntemi kullanılarak elde edilen farklı tahmin verileri karşılaştırılmıştır.

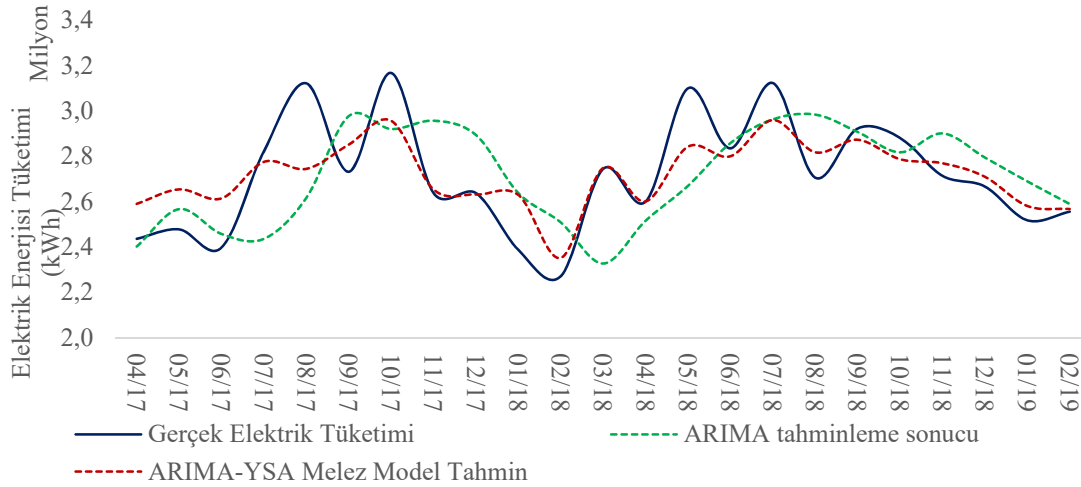


Şekil 5. ARIMA modeli doğrusal ve doğrusal olmayan veri analizi
(ARIMA model linear and nonlinear outputs)

Tablo 3. YSA sisteminde farklı kombinasyonlara ait ortalama kare hata değerlerinin kıyaslanması
(Comparison of mean square error values for different scenarios in ANN)

Method	Levenberg-Marquardt										
	Nöron Sayısı 5		10		15		20		25		
	OKH	R ²	OKH	R ²	OKH	R ²	OKH	R ²	OKH	R ²	
60	Eğitim	0,21	0,91	0,01	0,99	0,01	0,99	0,01	0,99	0,01	0,99
	Validasyon	0,21	0,94	0,21	0,90	0,03	0,99	0,01	0,98	0,01	0,99
	Test	0,21	0,97	0,03	0,99	0,21	0,96	0,21	0,97	0,01	0,99
	Çıktı	9,49		8,14		19,16		4,92		6,13	
65	Eğitim	0,21	0,97	0,21	0,79	0,07	0,99	0,21	0,93	0,01	0,99
	Validasyon	0,04	0,99	0,21	0,93	0,21	0,90	0,01	0,98	0,01	0,99
	Test	0,21	0,98	0,01	0,98	0,01	0,99	0,01	0,98	0,01	0,99
	Çıktı	12,63		8,53		8,30		5,28		6,72	
70	Eğitim	0,21	0,98	0,12	0,92	0,01	0,99	0,01	0,99	0,01	0,99
	Validasyon	0,21	0,96	0,18	0,89	0,21	0,90	0,21	0,94	0,21	0,91
	Test	0,21	0,66	0,21	0,81	0,01	0,99	0,21	0,96	0,01	0,99
	Çıktı	6,52		10,10		7,32		6,15		4,72	
75	Eğitim	0,21	0,18	0,21	0,64	0,06	0,99	0,21	0,83	0,01	0,99
	Validasyon	0,21	0,16	0,01	0,99	0,04	0,98	0,21	0,91	0,01	0,99
	Test	0,01	0,99	0,21	0,93	0,21	0,95	0,01	0,99	0,21	0,98
	Çıktı	5,35		12,33		7,28		6,37		35,17	
80	Eğitim	0,21	0,69	0,01	0,99	0,21	0,95	0,03	0,99	0,21	0,97
	Validasyon	0,01	0,99	0,21	0,86	0,01	0,99	0,12	0,98	0,01	0,99
	Test	0,21	0,80	0,21	0,97	0,21	0,92	0,01	0,99	0,21	0,94
	Çıktı	5,00		6,99		3,91		5,16		6,32	

Method		Bayes Regularizasyon										
Nöron Sayısı		5		10		15		20		25		
		OKH	R ²	OKH	R ²	OKH	R ²	OKH	R ²	OKH	R ²	
Test veri oranı (%)	60	Eğitim	0,21	0,74	0,21	0,64	0,21	0,74	0,21	0,52	0,21	0,68
		Validasyon	0,21	0,68	0,21	0,63	0,21	0,67	0,21	0,64	0,21	0,67
		Test	0,00	1,00	0,21	0,63	0,21	0,90	0,21	0,60	0,21	0,67
		Çıktı	6,18		7,53		5,48		6,11		6,14	
	65	Eğitim	0,01	0,99	0,21	0,68	0,21	0,64	0,21	0,92	0,21	0,72
		Validasyon	0,21	0,69	0,21	0,69	0,21	0,67	0,21	0,24	0,21	0,69
		Test	0,21	0,89	0,21	0,65	0,21	0,76	0,21	0,39	0,21	0,29
		Çıktı	5,63		6,14		6,21		6,24		6,25	
	70	Eğitim	0,01	0,99	0,21	0,53	0,21	0,91	0,21	0,31	0,21	0,64
		Validasyon	0,21	0,89	0,21	0,62	0,21	0,73	0,21	0,54	0,21	0,58
		Test	0,21	0,85	0,21	0,64	0,21	0,77	0,21	0,39	0,21	0,68
		Çıktı	6,90		6,14		9,46		6,27		6,25	
	75	Eğitim	0,21	0,97	0,21	0,46	0,21	0,67	0,21	0,41	0,21	0,66
		Validasyon	0,21	0,96	0,21	0,68	0,21	0,51	0,21	0,71	0,21	0,59
		Test	0,01	0,99	0,21	0,58	0,21	0,75	0,21	0,72	0,21	0,67
		Çıktı	6,13		7,85		6,28		7,35		6,29	
	80	Eğitim	0,21	0,96	0,21	0,67	0,21	0,37	0,21	0,42	0,01	0,99
		Validasyon	0,01	0,99	0,21	0,63	0,21	0,65	0,21	0,52	0,02	0,99
		Test	0,01	0,99	0,01	0,99	0,21	0,70	0,21	0,58	0,01	0,99
		Çıktı	7,90		6,20		10,78		6,26		5,07	
Method		Ölçekli Eşlenik Gradyan										
Nöron Sayısı		5		10		15		20		25		
		OKH	R ²	OKH	R ²	OKH	R ²	OKH	R ²	OKH	R ²	
Test veri oranı (%)	60	Eğitim	0,21	0,36	0,21	0,96	0,21	0,88	0,21	0,69	0,21	0,83
		Validasyon	0,21	0,75	0,21	0,43	0,21	0,94	0,21	0,73	0,21	0,73
		Test	0,21	0,95	0,02	0,99	0,21	0,94	0,21	0,95	0,02	0,99
		Çıktı	5,37		7,12		6,82		9,54		7,36	
	65	Eğitim	0,21	0,97	0,21	0,96	0,21	0,24	0,21	0,20	0,21	0,93
		Validasyon	0,01	0,99	0,21	0,49	0,21	0,91	0,21	0,96	0,21	0,94
		Test	0,21	0,39	0,21	0,67	0,21	0,90	0,21	0,46	0,21	0,95
		Çıktı	5,74		7,65		5,84		6,78		5,81	
	70	Eğitim	0,02	0,99	0,16	0,98	0,21	0,97	0,01	0,99	0,17	0,98
		Validasyon	0,21	0,93	0,01	0,94	0,21	0,47	0,09	0,99	0,21	0,55
		Test	0,21	0,88	0,02	0,96	0,03	0,99	0,14	0,99	0,01	0,99
		Çıktı	6,39		4,59		7,43		5,78		4,19	
	75	Eğitim	0,21	0,97	0,21	0,89	0,03	0,99	0,21	0,92	0,21	0,81
		Validasyon	0,21	0,86	0,21	0,83	0,21	0,92	0,21	0,31	0,21	0,80
		Test	0,21	0,82	0,21	0,95	0,01	0,99	0,14	0,99	0,10	0,99
		Çıktı	5,57		4,43		10,58		6,96		7,64	
	80	Eğitim	0,21	0,92	0,21	0,93	0,21	0,81	0,21	0,75	0,21	0,89
		Validasyon	0,21	0,83	0,21	0,79	0,21	0,83	0,21	0,40	0,03	0,99
		Test	0,21	0,95	0,21	0,74	0,11	0,99	0,05	0,99	0,21	0,77
		Çıktı	6,61		5,74		5,49		6,01		10,95	



Şekil 6. Melez ve ARIMA yöntemlerine ait tahmin sonuçlarının kıyaslanması
(Comparison of the results obtained from ARIMA and proposed ANN models)

Özellikle planlaması yapılan zaman aralığının son dönemlerine yaklaştıkça önerilen melez modelin gerçek veri setine oldukça yaklaştığı ve veri seti üzerindeki artış veya azalış eğilimlerini doğru bir şekilde yakaladığı gözlenmiştir.

Tablo 4’de farklı hata hesaplamalarına ait sonuçlar ARIMA ve melez model için paylaşılarak önerilen melez modelin ARIMA(1,1,1) modeline kıyasla ne kadarlık bir iyileştirme sağladığı paylaşılmıştır. En iyi iyileşmenin ortalama kare hata oranı ile sağlandığı gözlenmiştir.

Tablo 4. ARIMA ve melez model kullanılarak elde edilen tahmin sonuçlarına ait hata verileri
(Forecasting errors obtained by using ARIMA and Hybrid models)

	OMH	OKH	KOKH
ARIMA	200.761,5	59.901.691.748,1	244.748,2
Melez Model	110.199,7	21.606.266.311,4	146.990,7
İyileşme	%45,1	%63,9	%39,9

5. SONUÇLAR VE TARTIŞMALAR (CONCLUSIONS AND DISCUSSIONS)

Mevcut rekabet koşulları ve dünyada artan çevreci yaklaşımların artması sonucunda firmaların tedarik zincirlerini daha sürdürülebilir bir forma çevirme çabaları artmaktadır. Bu yeni yaklaşımın içerisinde firmalar için hazırlanacak bütünsel planlamaların alt yapıları güvenilir ve hızlı tahmin modelleri ile desteklenmektedir. Özellikle bütün ürünleri üretim sektörü gibi enerji yoğun sektörlerde geçmiş enerji verilerinin kullanılarak gelecek senaryoların doğru ve güvenilir bir şekilde tahmin edilmesi şirketlerin maliyet tasarrufları ve sistem sürdürülebilirlikleri açısından oldukça kritik bir konumdur. Bu sebeple bu çalışma kapsamında şirketlerin sürdürülebilir enerji yönetim sistemleri kurmalarına destek olacak melez tahmin modeli geliştirilmiştir. Bu model kapsamında ARIMA ve yapay sinir ağları sistemleri bütünleşik olarak ele alınarak gerçekleşen ve tahmin verileri arasındaki hata oranları

minimize edilmek istenmiştir. Geliştirilen modelde şirketten alınan gerçek hayat verileri (elektrik enerjisi tüketimi, güneş enerjisi üretimi, üretim hacmi, çalışma günleri) kullanılarak şirketin kısa/orta vadeli elektrik tüketim verileri tahmin edilmiştir. Elde edilen bilgiler ışığında geliştirilen melez tahmin modeli, sadece ARIMA modeli ile yapılan tahmin verilerine göre %39,9’lık bir iyileştirme sağlamaktadır. Ayrıca, yapılan test senaryosundan elde edilen tahmin verilerinde test periyodu boyunca meydana gelen ani artış ve azalış eğilimlerini daha iyi yakalayarak, gerçek hayat verisine oldukça yakın sonuçlar elde edilmiştir.

İlgili çalışmanın, daha geniş ölçekli bir veri seti ile testlerinin yapılması durumunda iyileştirme oranının artarak, sıfır hata hedefine yaklaşması sağlanabilecektir. Ayrıca, sistem tarafından test edilen ham veri setinin sezgisel davranışının analizi yapılarak çözüm algoritmasına eklenmesi sayesinde daha yüksek benzerlik oranında bir çözüm setinin elde edileceği tahmin edilmektedir. İlaveten, yapılacak olan veri analizi kapsamında üretim sistemindeki plansız duruşların öngörüldüğü ileri sezgisel algoritmaların kullanıldığı ve sistemin üretim hattı boyunca indirilmesi yapılarak daha mikro ölçekli enerji planlama çalışmalarının yapılması sistemin verimliliğini artırması beklenmektedir.

KAYNAKLAR (REFERENCES)

1. Enerjinin etkin kullanımı ve enerji tasarrufu ile ilgili teknolojiler - alt grup raporu. <http://www.inovasyon.org/pdf/EEK.bolum5.3.pdf>. Yayın Tarihi Aralık 21, 2017. Erişim Tarihi Ocak 01, 2019.
2. Debnath K.B., Mourshed M., Forecasting methods in energy planning models, Renewable and Sustainable Energy Reviews, 88, 297-325, 2018.
3. Kim M., Choi W., Jeon Y., Liu L., A Hybrid Neural Network Model for Power Demand Forecasting, Energies, 12 (5), 931-948, 2019.
4. Tso GK, Yau KK. Predicting electricity energy consumption: A comparison of regression analysis,

- decision tree and neural networks. *Energy*, Sep 1, 32 (9), 1761-8, 2007.
5. Meng M., Niu D., Sun W., Forecasting monthly electric energy consumption using feature extraction, *Energies*, 4 (10), 1495-507, 2011.
 6. Zahan M., Kenett R.S., Modeling and Forecasting Energy Consumption in the Manufacturing Industry in South Asia, *International Journal of Energy Economics and Policy*, 3 (1), 87-98, 2012.
 7. Es H.A., Kalender F.Y., Hamzacebi C., Forecasting the net energy demand of Turkey by artificial neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29 (3), 495-504, 2014.
 8. Zhang F., Deb C., Lee S.E., Yang J., Shah K.W., Time series forecasting for building energy consumption using weighted Support Vector Regression with differential evolution optimization technique, *Energy and Buildings*, 126, 94-103, 2016.
 9. Rahman A., Srikumar V., Smith A.D., Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks, *Applied energy*, 212, 372-385, 2018.
 10. Tahmassebi A., Gandomi A.H., Building energy consumption forecast using multi-objective genetic programming, *Measurement*, 118, 164-171, 2018.
 11. Singh P., Dwivedi P., Integration of new evolutionary approach with artificial neural network for solving short term load forecast problem, *Applied energy*, 217, 537-549, 2018.
 12. Mohan N., Soman K.P., Kumar S.S., A data-driven strategy for short-term electric load forecasting using dynamic mode decomposition model, *Applied energy*, 232, 229-244, 2018.
 13. Ruiz L.G., Rueda R., Cuéllar M.P., Pegalajar M.C., Energy consumption forecasting based on Elman neural networks with evolutive optimization, *Expert Systems with Applications*, 92, 380-389, 2018.
 14. Anvari S., Tuna S., Canci M., Turkay M., Automated Box-Jenkins forecasting tool with an application for passenger demand in urban rail systems, *Journal of Advanced Transportation*, 50 (1), 25-49, 2016.
 15. Katsatos A.L., Moustris K.P., Application of Artificial Neuron Networks as energy consumption forecasting tool in the building of Regulatory Authority of Energy, Athens, Greece, *Energy Procedia*, 157, 851-861, 2019.
 16. Zhang G.P., Time series forecasting using a hybrid ARIMA and neural network model, *Neurocomputing*, 50, 159-175, 2003.
 17. Demirel Ö., Kakilli A., Tektaş M., Electric energy load forecasting using anfis and arma methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 25 (3), 601-610, 2010.
 18. Khashei M., Bijari M., A novel hybridization of artificial neural networks and ARIMA models for time series forecasting, *Applied Soft Computing*, 11 (2), 2664-2675, 2011.
 19. Babu C.N., Reddy B.E., A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data, *Applied Soft Computing*, 23, 27-38, 2014.
 20. Khandelwal I., Adhikari R., Verma G., Time series forecasting using hybrid ARIMA and ANN models based on DWT decomposition, *Procedia Computer Science*, 48, 173-179, 2015.
 21. de Oliveira J.F., Ludermit T.B., A hybrid evolutionary decomposition system for time series forecasting, *Neurocomputing*, 180, 27-34, 2016.
 22. Başoğlu B., Bulut M., Development of a hybrid system based on neural networks and expert systems for shortterm electricity demand forecasting, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32 (2), 575-583, 2017.
 23. Xiao J., Li Y., Xie L., Liu D., Huang J., A hybrid model based on selective ensemble for energy consumption forecasting in China, *Energy*, 159, 534-546, 2018.
 24. Karadede Y., Ozdemir G., Aydemir E., Breeder hybrid algorithm approach for natural gas demand forecasting model, *Energy*, 141, 1269-1284, 2017.
 25. Li J., Wang R., Wang J., Li Y., Analysis and forecasting of the oil consumption in China based on combination models optimized by artificial intelligence algorithms, *Energy*, 144, 243-264, 2018.
 26. Zhang Y., Ma F., Shi B., Huang D., Forecasting the prices of crude oil: An iterated combination approach, *Energy Economics*, 70, 472-483, 2018.
 27. de Oliveira E.M., Oliveira F.L., Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods, *Energy*, 144, 776-788, 2018.
 28. Wang D., Wang Y., Song X., Liu Y., Coal overcapacity in China: multiscale analysis and prediction, *Energy Economics*, 70, 244-257, 2018.
 29. Mackinnon J.G., Numerical Distribution Functions for Unit Root and Cointegration Tests, *Journal of Applied Econometrics*, 11, 601-618, 1996.
 30. Gavin H., The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems, Department of Civil and Environmental Engineering, Duke University, 28:1-5, 2011.
 31. Askin D., Iskender I., Mamizadeh A., Dry type transformer winding thermal analysis using different neural network methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 26 (4), 905-913, 2011.
 32. Møller M.F., A scaled conjugate gradient algorithm for fast supervised learning, *Neural networks*, 6 (4), 525-533, 1993.
 33. RStudio Team. RStudio: Integrated Development for R. <http://www.rstudio.com/>. Erişim Tarihi Nisan 1, 2019.
 34. Beale M., Hagan M., Demuth H., *Matlab R2017a Neural Network Toolbox User's Guide*, 2012.