



Biological Interactions in Distribution Networks and Analysis of Weather-Related Failures Using Artificial Neural Networks

Kübra Dağgez^{1,a,*}, Vekil Sarı^{2,b}

¹ Sivas Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 58140, Sivas, Türkiye

² Sivas Cumhuriyet Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 58140, Sivas, Türkiye

*Corresponding Author

Research Article

History

Received: 11/11/2024

Accepted: 20/12/2024

Copyright



This work is licensed under
Creative Commons Attribution 4.0
International License

ABSTRACT

Overhead line faults have a critical impact on the reliability of electrical distribution systems. Literature reviews show that overhead lines are highly susceptible to environmental factors such as weather conditions, vegetation and wildlife. This study presents a data-driven approach to analysing biologically induced outages in overhead distribution lines using Artificial Neural Network (ANN) techniques. The study aims to predict regions where outages are likely to occur using meteorological data. For the analysis, real outage data from an electricity distribution company for the period 2021-2023, together with meteorological data for the same period, were used to model the ANN structure in MATLAB software. The model achieved an accuracy rate of 97% on the test data, demonstrating a high generalisation ability. The results of this study provide valuable insights for electricity distribution companies to better understand biologically induced outage problems, and to develop effective models for predicting such outages.

Keywords: Overhead Distribution Lines, Artificial Neural Networks, Meteorological Data Analysis, Biological Outages

Dağıtım Şebekelerinde Biyolojik Etkileşimler ve Hava Koşullarına Bağlı Arızaların Yapay Sinir Ağları ile İncelenmesi

Öz

Havai dağıtım hatlarında meydana gelen arızalar, elektrik dağıtım sistemlerinin güvenilirliği üzerinde kritik bir etkiye sahiptir. Literatür incelemeleri, havai hatların hava koşulları, ağaçlar ve hayvanlar gibi çevresel faktörlere karşı oldukça hassas olduğunu göstermektedir. Bu çalışma, yapay sinir ağları tekniğini kullanarak havai dağıtım hatlarında biyolojik kaynaklı kesintilerin analizi için veri odaklı bir yaklaşım sunmaktadır. Çalışmada, meteorolojik veriler kullanılarak kesintilerin gerçekleşebileceği bölgelerin tahmin edilmesi hedeflenmiştir. Analizlerde, 2021-2023 yılları arasında bir elektrik dağıtım şirketine ait gerçek kesinti verileri ve aynı döneme ait meteorolojik veriler temel alınarak, yapay sinir ağı (YSA) yapısı Matlab yazılımında modellenmiştir. Test verileri üzerinde elde edilen %97 doğruluk oranı, modelin genelleme kapasitesinin oldukça yüksek olduğunu ortaya koymaktadır. Bu çalışmanın sonuçları, elektrik dağıtım şirketlerine biyolojik kaynaklı kesinti sorunlarını daha iyi anlamaları ve bu kesintileri tahmin etmek için etkili modeller geliştirmeleri konusunda bilgiler sağlayabilir.

Anahtar Kelimeler: Elektrik Dağıtım Hatları, Yapay Sinir Ağları, Meteorolojik Veri Analizi, Biyolojik Kesintiler

Süreç

Geliş: 11/11/2024

Kabul: 20/12/2024

^a kubradaggez@gmail.com

^{ID} 0009-0008-2764-0901

^b vsari@cumhuriyet.edu.tr

^{ID} 0000-0001-5963-0179

How to Cite: Dağgez K, Sarı V (2025) Biological Interactions in Distribution Networks and Analysis of Weather-Related Failures Using Artificial Neural Networks, Journal of Engineering Faculty, 3(1): 11-19.

Giriş

Elektrik dağıtım sistemlerinin güvenilirliği, özellikle olumsuz hava koşullarında meydana gelen arızalar nedeniyle önemli ölçüde etkilenmektedir. Bu arızaların tahmin edilmesi, dağıtım şirketlerinin operasyonel ve bakım kararlarını iyileştirerek risk yönetim kapasitelerini artırmaktadır [1].

Elektrik dağıtım hatlarındaki arızalar, genel olarak dört ana başlık altında toplanabilir: çevresel faktörler, biyolojik etkileşimler, teknik arızalar ve insan kaynaklı hatalar. Çevresel faktörler arasında özellikle olumsuz hava koşulları, fırtınalar, aşırı sıcak veya soğuk hava, yıldırım düşmesi gibi etkenler yer alırken; biyolojik etkileşimler ise kuşlar, kemirgenler veya diğer hayvanların hatlarla temasından kaynaklanabilir. Teknik arızalar, altyapının eskimesi, ekipmanların arızalanması veya hatalı kurulum gibi nedenlerle ortaya çıkabilir. İnsan kaynaklı hatalar ise, hatların yanlış kullanımı, vandalizm veya bakım süreçlerindeki eksikliklerden kaynaklanabilir.

Havai enerji dağıtım sistemindeki kesintiler, hava durumu, ağaçlar ve hayvan faaliyetleri gibi birçok çevresel faktörden kaynaklanır [2]. Bu faktörlerden kaynaklanan arızaların incelenmesi kritik bir öneme sahiptir. Sistemin güvenilirliğini artırmak için, toplanan sistem verilerinden elde edilen tahminlerin etkin bir şekilde analiz edilmesi büyük önem taşımaktadır [3].

Geleneksel arıza tahmin yöntemleri genellikle fiziksel modeller ve istatistiksel analizlere dayanırken, son yıllarda yapay zekâ ve makine öğrenimi tekniklerinin kullanımı artmıştır. Özellikle YSA, karmaşık ve doğrusal olmayan ilişkileri öğrenme yetenekleri sayesinde arıza tahmininde etkili araçlar olarak öne çıkmaktadır [4].

Elektrik şebekesi arıza riskini değerlendirmek için meteorolojik verilerden yararlanılan mevcut çalışmalarda, yapay sinir ağları (ANN) [5, 6], istatistiksel yöntemler [7, 8, 9] ve bulanık mantık [10, 11] gibi farklı yaklaşımlar tercih edilmiştir.

Pahwa ve arkadaşları hayvan kaynaklı elektrik dağıtım kesintilerini analiz ederek, tahmin yapmak için bir Bayes ağı modeli geliştirmiş ve modelin doğruluğunun %90'ın üzerinde olduğunu belirlemiştir [12].

Kankanala ve arkadaşları, havai elektrik dağıtım sistemlerinde hayvan kaynaklı kesintileri tahmin etmek için AdaBoost algoritmasını kullanarak çeşitli modeller geliştirmiştir. Kansas'taki dört şehirden 1998-2007 yılları arasındaki verilere dayanan çalışmada, AdaBoost+ buradaki artı işaretinin bir anlamı var mı? modelinin, hata oranlarını düşürerek (MSE, MAE) ve tahmin doğruluğunu artırarak (korelasyon katsayısı) diğer yöntemlerden daha başarılı olduğu gösterilmiştir. Bu çalışma, çevresel faktörlere bağlı

kesintilerin tahmin edilmesi ve önlenmesine yönelik literatürde önemli bir katkı sağlamaktadır [13].

Hayvanlar ve bitkilerden kaynaklanan elektrik kesintilerinin hava koşullarıyla ilişkisini incelemek için birliktelik kuralı madenciliği yöntemi de kullanılmıştır. Çalışma, 495.274 kesinti olayını analiz ederek hayvan kaynaklı kesintilerin sakin hava koşullarında, bitki kaynaklı kesintilerin ise yağışlı ve kötü hava koşullarında daha sık meydana geldiğini göstermiştir. Bu çalışma, elektrik kesintilerini önlemeye yönelik bakım stratejilerinin geliştirilmesinde önemli bir referans oluşturmaktadır [14].

Ele alınan dağıtım sistemi altyapısının %75'inin havai hatlardan oluşması, bu hatların çevresel ve biyolojik etkenlere karşı daha fazla duyarlı olmasına neden olmaktadır. Havai hatlar, açık hava koşullarına doğrudan maruz kaldıkları için özellikle şiddetli rüzgar, fırtına, aşırı sıcaklık ve buzlanma gibi hava olaylarından yoğun şekilde etkilenmektedir. Bunun yanı sıra, kuş çarpması, kemirgenlerin oluşturduğu zararlar ve diğer hayvan etkileşimleri de arıza nedenleri arasında yer almaktadır.

Bu çalışma, havai dağıtım hatlarında biyolojik kaynaklı kesintilerin analizi için yapay sinir ağları (YSA) tekniğini kullanarak veri odaklı bir yaklaşım sunmaktadır. 2021-2023 yılları arasında bir elektrik dağıtım şirketinden alınan gerçek kesinti verileri ve aynı döneme ait meteorolojik veriler kullanılarak, kesinti riskinin yüksek olduğu bölgelerin tahmin edilmesi hedeflenmiştir. Matlab yazılımı ile modellenen YSA yapısı, test verileri üzerinde %97 doğruluk oranı ile başarılı bir performans sergilemiştir. Bu bulgular, elektrik dağıtım şirketlerinin biyolojik kaynaklı kesintileri anlamalarına ve önlemeye yönelik etkili stratejiler geliştirmelerine katkı sağlayabilir.

Materyal ve Metot

Bu bölümde, biyolojik kaynaklı kesintilerin tahmininde kullanılan model ve meteorolojik verilere dayalı olarak, kesinti riskinin belirlenmesinde kullanılan Yapay Sinir Ağı yapısı açıklanmıştır.

Çalışmada, sinir ağı modelini eğitmek ve değerlendirmek amacıyla meteorolojik ve şebeke arıza verileri birleştirilerek toplam 814 veri noktası içeren bir veri seti hazırlanmıştır. Veri seti meteorolojik veriler ve şebeke arıza verileri olmak üzere iki ana kaynaktan türetilmiş ve bu verilerin arasında konuma bağlı olarak bir entegrasyon sağlanmıştır.

Meteorolojik Veriler: Çalışmada kullanılan meteorolojik değişkenler, sıcaklık (t_{2m} :°C), bağıl nem (%), rüzgar hızı (m/s), rüzgar yönü, global radyasyon (W/m^2), bulut örtüsü (%) ve tahmini yağış olasılığı (%) gibi ölçütleri içermektedir. Veriler saatlik zaman aralıklarıyla toplanmış ve örneklem seçilen bölgelere ait koordinatlarla eşleştirilmiştir.

Tablo 1. Meteorolojik Veriler

Table 1. Meteorological Data

Meteorolojik Veriler	Tanım	Birim
Sıcaklık	Yer seviyesinden 2 metre yükseklikte ölçülen hava sıcaklığı	°C
Bağıl Nem	Havada mevcut su buharının, taşıyabileceği maksimum miktara oranı.	%
Rüzgar Hızı	Hava kütlelerinin yatay hareket hızı.	m/s
Rüzgar Yönü	Rüzgarın geldiği coğrafi yön veya azimut açısı.	° veya yön
Global Radyasyon	Yeryüzüne ulaşan toplam güneş ışınımı (doğrudan ve difüz).	W/m^2
Bulut Örtüsü	Gökyüzünün bulutlarla kaplanma oranı.	%
Tahmini Yağış Olasılığı	Belirli bir bölgede yağış meydana gelme olasılığı.	%

Elektrik şebekesindeki arıza verisi, tarih, zaman, şebeke unsuru ve sensör konum bilgileriyle birlikte arıza başlangıç gün, ay ve yılı gibi parametreleri içermektedir. Bu veriler, ilgili meteorolojik koşullarla eşleştirilerek analiz için entegre edilmiştir. Tablo 2'de kullanılan verilere ait örnekler sunulmuştur

Veri setinin ilk 700 veri noktası modelin eğitimi için ayrılmış, kalan 114 veri noktası ise modelin test performansını değerlendirmek için kullanılmıştır. Bu


bölünme, modelin genelleme kabiliyetini objektif bir şekilde değerlendirmeye olanak sağlamıştır.

Sinir ağı modeli (Şekil-1), giriş, gizli ve çıkış katmanlarından oluşmaktadır. Giriş katmanında model, 10 özellikten oluşan giriş verilerini işler ve bu verileri gizli katmana aktarır. Bu özellikler, modelin öğrenme sürecinde veri setindeki ilişkileri anlamasını sağlayan temel girdilerdir.


Tablo 2. Örnekler

Table 2. Samples

Sıcaklık (°C)	Bulut Örtüsü (%)	Global Radrasyon (W/m ²)	Bağıl Nem (%)	Rüzgar Yönü (°)	Rüzgar Hızı (m/s)	Yağış Olasılığı (%)	Çıkış (ilçe Kodları)
10.7	52.6	0	88	101.3	2.9	1	2
11.3	11.9	0	89.2	207.4	0.7	1	39
21.2	70.6	181.7	58.9	190.5	2.0	1	38
18.3	87.5	94.9	62.6	171.0	6.5	23.9	9
10.9	74.9	363.3	48.1	150.0	2.4	1	29



Şekil 1. Temel YSA Yapısı
Figure 1. Basic ANN Structure



Şekil 2. Çalışmada Kullanılan YSA Yapısı
Figure 2. ANN Structure Used in the Study

Gizli katman (Hidden Layer), 10 nörondan oluşmakta ve veri işleme sürecinin ana kısmını oluşturmaktadır. Bu katmanda, ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmıştır. ReLU, doğrusal olmayan ilişkilerin öğrenilmesine olanak tanıyarak modelin karmaşık veri yapılarındaki bağımlılıkları daha iyi yakalamasını sağlar. Gizli katman, giriş verilerindeki özellikleri dönüştürerek çıkış katmanına aktarılabilecek şekilde düzenler.

İleri yayılım sırasında, giriş değerleri ağırlıklı olarak giriş katmanından gizli katmana iletilir. Burada, ağırlıklar ve önyargılar ReLU aktivasyon fonksiyonu kullanılarak ayarlanır. Çıkış katmanı ise tek bir nörona sahiptir ve son tahmin değerini doğrusal bir dönüşüm ile hesaplar (Şekil 2). Matematiksel olarak, gizli katman çıktısı h , W_1 gizli katman ağırlıklarına ve b_1 önyargılarına bağlı olarak hesaplanmaktadır (1).

$$h = \text{ReLU}(W_1x + b_1) \quad (1)$$

Çıkış aktivasyon fonksiyonu $\hat{y}$ ise W_2 ve b_2 değerlerine bağlı olarak hesaplanmaktadır (2).

$$\hat{y} = W_2h + b_2 \quad (2)$$

Modelin ağırlık ve bias parametreleri, giriş verilerini anlamlı bir şekilde dönüştürmek ve veri setindeki bağımlılıkları öğrenmek amacıyla optimize edilmiştir. Bu yapı, hem doğrusal hem de doğrusal olmayan ilişkileri etkili bir şekilde modelleyerek yüksek doğrulukla tahminler yapılmasına olanak tanır. Sinir ağı mimarisi, veri setindeki karmaşık ilişkileri öğrenmek ve model performansını en üst düzeye çıkarmak amacıyla dikkatlice tasarlanmıştır.

Modelin eğitimi sırasında veri seti, mini-batch gruplarına bölünerek işlemler paralel hale getirilmiştir. Eğitim süreci boyunca model, doğrulama verileri üzerinden düzenli olarak değerlendirilmiştir. Bu aşamada, doğrulama veri seti, modelin eğitime fazla uyum sağlayarak genelleme yeteneğini kaybetmemesi için izleme amaçlı kullanılmıştır. Eğitim süreci belirli bir erken durdurma kriterine göre tamamlanmıştır. Bu kriter, doğrulama kaybındaki iyileşmenin belirli bir dönem boyunca durması durumunda eğitimi sonlandırmıştır.

Model eğitimi sonrasında oluşturulan ağırlık ısı haritaları, sinir ağına iç bağlantılarını görselleştirerek giriş özellikleri, gizli katmanlar ve çıkış katmanı arasındaki ilişkileri göstermektedir. Bu haritalar, hata tahmini modeli için ağırlık öğrenme süreçlerini anlamaya olanak sağlar.


Şekil 3, giriş özellikleri ile birinci gizli katman (H1) nöronları arasındaki ağırlıkları göstermektedir. Satırlar, giriş özelliklerini temsil ederken, sütunlar birinci gizli katmandaki nöronlara karşılık gelmektedir. Ağırlıkların büyüklüğünü ve yönünü ifade eden renk yoğunluğu, pozitif ağırlıkları kırmızı, negatif ağırlıkları ise mavi olarak göstermektedir.

Örneğin, $t_{\text{apparent:C}}$ ve $wind_speed_{10m:ms}$ özellikler, birçok nöronla güçlü bağlantılar sergileyerek birinci katmanda önemli bir rol oynadıklarını göstermektedir.


Birinci gizli katman (H1) nöronları ile ikinci gizli katman (H2) nöronları arasındaki ağırlıkları Şekil 4'te görselleştirilmiştir. Satırlar H1 nöronlarına, sütunlar ise H2 nöronlarına karşılık gelir. Pozitif ve negatif ağırlıkların varlığı, birinci gizli katmanın ikinci katmana öğrenilen önemli desenleri nasıl aktardığını göstermektedir. Örneğin, H1_9 nöronu, H2_6 nöronuna güçlü pozitif katkıda bulunarak, derin katmanlarda belirli desenlerin taşınmasında önemli bir rol oynamaktadır. Pozitif ve negatif ağırlıkların dengesi, giriş özelliklerinin ayrıntılı bir temsili için elde edilmesini sağlar.

Şekil 5'te ise, ikinci gizli katman (H2) ile hata tahmin çıkış katmanı arasındaki ağırlıkları göstermektedir. Satırlar H2 nöronlarını, tek sütun ise hata tahmin çıkışını temsil eder. Örneğin, H2_4 ve H2_5 gibi nöronlar, hata tahmini olasılığını artırmada kritik bir rol oynayan güçlü pozitif ağırlıklara sahiptir. Buna karşılık, H2_1 ve H2_9 gibi nöronlar, hata tahminini baskılayan güçlü negatif ağırlıklar sergilemektedir. H2_10 gibi düşük ağırlıklara sahip nöronlar ise çıktıya minimal katkı sağlayarak model performansında daha az etkili olabilmektedir.


Bu ısı haritaları, sinir ağına öğrenme süreçlerini yorumlanabilir bir şekilde sunarak, belirli özelliklerin önemini ve nöronların hata tahminiyle ilgili desenleri nasıl yakaladığını ortaya koymaktadır. Bu görselleştirme, modelin iç işleyişini anlamayı kolaylaştırmakta ve düşük etkili nöronların budanması ya da özellik önemini analiz edilmesi gibi iyileştirme alanlarının belirlenmesine olanak sağlamaktadır.



Şekil 3. Giriş Özellikleri ile Birinci Gizli Katman (H1) Nöronları Arasındaki Ağırlıklar
Figure 3. Weights Between Input Features and First Hidden Layer (H1) Neurons



Şekil 4. Birinci gizli katman (H1) nöronları ile ikinci gizli katman (H2) nöronları arasındaki ağırlıklar
Figure 4. Weights between the neurons of the first hidden layer (H1) and the neurons of the second hidden layer (H2)



Şekil 5. İkinci Gizli Katman (H2) ile Hata Tahmin Çıkış Katmanı Arasındaki Ağırlıkları
Figure 5. Weights Between Second Hidden Layer (H2) and Error Prediction Output Layer


Bulgular

Elektrik dağıtım hatlarında meydana gelen biyolojik kaynaklı arızaların tahmini için hava durumu değişkenleri ve yapay zeka tabanlı bir modelin kullanımı incelenmiştir. Analizler sonucunda, bağıl nem ve sıcaklık gibi meteorolojik faktörlerin, arızaların meydana geldiği tarihlerle güçlü bir ilişki içinde olduğu tespit edilmiştir.


Özellikle, bağıl nem ve sıcaklık değerlerinin zaman içindeki değişimleri ile arıza tarihlerinin işaretlendiği Şekil 6'da, arızaların yüksek bağıl nem oranı veya ani sıcaklık değişikliklerinin gözlemlendiği dönemlerde yoğunlaştığı görülmektedir. Bu bulgu, elektrik hatlarının çalışma koşullarının atmosferik değişkenlerden doğrudan etkilendiğini ve bu değişkenlerin dikkatle izlenmesi gerektiğini ortaya koymaktadır. Eğitim aşamasında elde edilen R değeri 0.99662 olarak kaydedilmiştir, bu da modelin eğitim verisi üzerinde oldukça iyi bir uyum sağladığını göstermektedir. Benzer şekilde, doğrulama aşamasındaki R değeri 0.99654 ve test aşamasındaki R değeri 0.99443 olarak hesaplanmıştır. Bu sonuçlar, modelin genelleme kabiliyetinin yüksek olduğunu ve hem doğrulama hem de test verilerinde iyi performans sergilediğini ortaya koymaktadır. Genel olarak, tüm veri seti üzerindeki R değeri 0.99619 olarak hesaplanmış, modelin tahmin doğruluğunu istikrarlı bir şekilde koruduğunu göstermiştir.

Modelin tahmin ettiği bölge ID değerleri ile gerçek bölge ID değerleri arasındaki uyum Şekil 7'de gösterilmiştir. Gerçek değerler kesintisiz bir çizgiyle, tahmin edilen değerler ise kesikli bir çizgiyle görselleştirilmiştir. Grafik, modelin her bir veri örneği için tahmin doğruluğunu ve genelleme başarısını ortaya koymaktadır. Eğitim sırasında model, doğruluk oranını giderek artırmış ve belirli bir epoch'ta en iyi validasyon performansına ulaşmıştır. Test verisi üzerinde elde edilen tahmin doğruluğu ise %97 seviyesinde olup, modelin genelleme kapasitesinin oldukça yüksek olduğunu göstermektedir. Bununla birlikte, eğitim ve test hataları arasındaki fark incelendiğinde eğitim hatalarının ortalama %5 civarında düşük bir seviyede olduğu, ancak test hatalarının %7 seviyesinde olduğu görülmektedir. Bu durum, modelin genelleme yeteneğinin geliştirilmesi için daha büyük veri setleriyle eğitilmesi veya veri artırma gibi yöntemlerin uygulanabileceğini işaret etmektedir.

Bu sonuçlar, modelin yüksek tahmin doğruluğu ile çalıştığını ve genelleme kabiliyetinin güçlü olduğunu göstermektedir. Şekil 7'de sunulan görselleştirme, modelin hem eğitim sürecindeki başarısını hem de test verilerindeki performansını destekler niteliktedir. Tahmin ve gerçek değerler arasındaki güçlü uyum, modelin sahada kullanılabilirliği açısından olumlu sonuçlar sunmaktadır.



Şekil 6. (a) Eğitim, (b) Validasyon, (c) Test ve (d) Bütün Sonuçların Ortalaması
Figure 6. (a) Training, (b) Validation, (c) Testing and (d) Average of All Results



Şekil 7. Tahmin Edilen Kesinti Değerleri ve Bölge Karşılaştırılması
Figure 7. Estimated Cut-Off Values and Comparison of Regions

Eğitim, doğrulama ve test süreçlerinde modelin hata değerlerinin epoch'lara göre değişimi Şekil 8'de sunulmuştur. Eğitim süreci boyunca, tüm veri gruplarında hata değerlerinin düzenli olarak azaldığı gözlemlenmiştir. Modelin doğrulama performansı, 44. epoch'ta 0.17829 ortalama kare hata (MSE) değeri ile en iyi seviyeye ulaşmıştır. Bu noktada, modelin doğrulama performansının zirve yapması, öğrenme sürecinin etkili bir şekilde yönetildiğini göstermektedir.

Doğrulama ve test hatalarının eğitim hatasına yakın bir eğilim göstermesi, modelin aşırı öğrenme eğiliminden kaçındığını ve genelleme yeteneğinin yüksek olduğunu doğrulamaktadır. Test hatalarının düşük seviyede kalması, modelin gerçek dünyadaki veri setlerinde başarılı tahminler yapabileceğini göstermektedir. Eğitim, doğrulama ve test süreçlerindeki bu uyum, modelin yapılandırılma ve optimizasyon aşamalarının başarılı bir şekilde gerçekleştirildiğine işaret etmektedir.


Sonuç olarak, modelin hem doğrulama hem de test veri setlerinde elde ettiği düşük hata değerleri, sinir ağı modelinin tahmin doğruluğunun ve genelleme kabiliyetinin yüksek olduğunu ortaya koymaktadır. Şekil 7'te gösterilen eğilimler, modelin öğrenme sürecini etkili bir şekilde tamamladığını ve tüm veri gruplarında istikrarlı performans sergilediğini göstermektedir.

Modelin eğitim sürecinde öğrenme dinamiklerini değerlendirmek amacıyla gradyan büyüklüğü, momentum ve doğrulama kontrol noktalarının epoch bazında değişimi analiz edilmiştir (Şekil 8). Bu analiz, modelin öğrenme sürecindeki istikrarını ve optimizasyon başarısını değerlendirmek için kritik bir yol göstermiştir.

Eğitim süresince gradyan büyüklüğünün azalma eğiliminde olduğu görülmüştür. Özellikle, 50. epoch'ta gradyan değeri 0.13589 olarak ölçülmüştür. Gradyanın bu şekilde azalması, modelin kayıp fonksiyonunu başarılı bir şekilde minimize etmeye yaklaştığını ve parametrelerin optimize edildiğini göstermektedir. Bu durum, modelin öğrenme sürecinin kararlı bir hale ulaştığını ve ağırlık güncellemeleri için büyük adımların artık gerekmediğini işaret etmektedir.


Momentum parametresinin (Mu) zaman içindeki değişimi de eğitim sürecinin kararlılığını desteklemektedir. Şekil 9'da görüldüğü üzere, Mu parametresi genel olarak düşük ve stabil seviyelerde kalmıştır. Bu stabilite, modelin öğrenme oranını etkin bir şekilde yönetmesini sağlamış ve parametre güncellemelerinin dengeli bir şekilde devam ettiğini göstermiştir. Eğitim sırasında ara sıra gözlemlenen küçük Mu artışları, modelin kayıp fonksiyonunda durağanlık yaşadığı anlarda öğrenmeyi kolaylaştırmak için optimize edilmiş adımlar atıldığını işaret etmektedir.

Doğrulama kontrol noktaları, modelin aşırı öğrenme (overfitting) yapma eğilimini izlemek için analiz edilmiştir. Şekil 9'da, doğrulama kaybında iyileşme görülmeyen epoch'ların sayısı doğrulama kontrolleri olarak gösterilmektedir. 50. epoch'ta toplamda 6 doğrulama kontrolü yapılmıştır. Doğrulama kontrollerindeki artış, modelin doğrulama verisi üzerindeki performansında küçük dalgalanmalar olduğunu göstermektedir. Ancak bu dalgalanmalar eğitim sürecini olumsuz yönde etkilememiştir. Modelin 50. epoch'ta durdurulması, doğrulama performansının korunmasını sağlamak açısından etkili bir karar olmuştur.



Şekil 8. Eğitim, Doğrulama ve Test Veri Setlerindeki Ortalama Kare Hata (Mean Squared Error - MSE) Değerlerinin Epoch Bazında Değişimi

Figure 8. Epoch-Based Changes in Mean Squared Error (MSE) Values in Training, Validation and Test Datasets



Şekil 9. Eğitim Süreci Boyunca Modelin Gradyan Büyüklüğü (Gradient), Momentum Parametresi (Mu) ve Doğrulama Kontrollerinin (Validation Checks) Epoch Bazında Değişimi

Figure 9. Epoch-Based Changes in Gradient Size (Gradient), Momentum Parameter (Mu) and Validation Checks of the Model During the Training Process

Modelin performansı, eğitim ve test setleri üzerinde yapılan analizlerle değerlendirilmiştir. Eğitim sırasında model, doğruluk oranını giderek artırmış ve belirli bir

epoch'ta en iyi validasyon performansına ulaşmıştır. Test verisi üzerinde elde edilen tahmin doğruluğu ise %97

seviyesinde olup, modelin genelleme kapasitesinin oldukça yüksek olduğunu göstermektedir.

Tartışma ve Sonuç

Bu çalışmada, havai dağıtım hatlarında biyolojik kaynaklı kesintilerin tahmin edilmesinde yapay sinir ağı (YSA) tabanlı bir modelin etkinliği incelenmiştir. Meteorolojik faktörlerin, özellikle sıcaklık ve bağıl nemin, elektrik dağıtım hatlarındaki arızalarla güçlü bir ilişki içinde olduğu tespit edilmiştir. YSA modelinin test verisi üzerinde elde edilen %97 doğruluk oranı, modelin yüksek genelleme kapasitesine sahip olduğunu ve saha koşullarında da başarılı sonuçlar verebileceğini göstermektedir. Bu bulgular, elektrik dağıtım şirketlerinin biyolojik etkileşimler ve hava koşullarına bağlı arızaları daha iyi anlamalarına ve tahmin etmelerine yardımcı olacak etkili stratejiler geliştirmelerini sağlayabilir.

Yapay sinir ağlarının, karmaşık ve doğrusal olmayan ilişkileri öğrenme kapasitesinden faydalanarak, elektrik dağıtım sistemlerinde biyolojik etkileşimlere dayalı arızaların daha doğru bir şekilde tahmin edilmesi mümkün olmaktadır. Çalışma, elektrik dağıtım şirketlerine biyolojik etkenlerin ve meteorolojik faktörlerin etkilerini daha iyi anlamaları ve önleyici bakım stratejileri geliştirmeleri konusunda önemli bir rehber sağlamaktadır. Gelecekte yapılacak çalışmalar, bu modellerin daha geniş veri setleriyle test edilerek, tahmin doğruluğunun daha da artırılmasını ve modelin daha fazla parametre ile optimize edilmesini sağlayacaktır. Bu tür çalışmalar, enerji sektöründeki güvenilirlik analizlerini derinleştirerek, arıza risklerini daha etkin bir şekilde yönetmeye yardımcı olabilir.

Elde edilen bulgular, yapay zeka temelli modellerin elektrik dağıtım hatlarındaki arızaların tahmininde oldukça etkili bir araç olduğunu göstermektedir. Hava durumu değişkenlerinin modellenmesi, tahmin doğruluğunu artırmada kritik bir öneme sahiptir. Gelecekteki çalışmalar, saha koşullarında test edilen daha büyük veri setleriyle modelin performansını artırmayı hedefleyebilir. Bu analiz ve bulgular, elektrik dağıtım sistemlerinde güvenilirliği artırmak ve arıza risklerini minimize etmek adına önemli bir katkı sunmaktadır.

Kaynakça

- [1] Du, Y., Liu, Y., Wang, X., Fang, J., Sheng, G., & Jiang, X. (2020). Predicting weather-related failure risk in distribution systems

- using Bayesian neural network. *IEEE Transactions on Smart Grid*, 12(1), 350-360.
- [2] Das, S., Kankanala, P., & Pahwa, A. (2021). Outage estimation in electric power distribution systems using a neural network ensemble. *Energies*, 14(16), 4797.
- [3] Zhou, Y., Pahwa, A., & Yang, S. S. (2006). Modeling weather-related failures of overhead distribution lines. *IEEE Transactions on power systems*, 21(4), 1683-1690.
- [4] Brester, C., Niska, H., Ciszek, R., & Kolehmainen, M. (2020, July). Weather-based fault prediction in electricity networks with artificial neural networks. In *2020 IEEE Congress on Evolutionary Computation (CEC)* (pp. 1-8). IEEE.
- [5] Sarwat, A. I., Amini, M., Domijan, A., Damjanovic, A., & Kaleem, F. (2016). Weather-based interruption prediction in the smart grid utilizing chronological data. *Journal of Modern Power Systems and Clean Energy*, 4(2), 1-8.
- [6] Takata, H., Yanase, M., Waki, T., & Hachino, T. (2002, August). A prediction method of electric power damage by typhoons in Kagoshima via GMDH and NN. In *Proceedings of the 41st SICE Annual Conference. SICE 2002*. (Vol. 4, pp. 2424-2429). IEEE.
- [7] Li, G., Zhang, P., Luh, P. B., Li, W., Bie, Z., Serna, C., & Zhao, Z. (2013). Risk analysis for distribution systems in the northeast US under wind storms. *IEEE Transactions on Power Systems*, 29(2), 889-898.
- [8] Liu, Y. (2015, June). Short-term operational reliability evaluation for power systems under extreme weather conditions. In *2015 IEEE Eindhoven PowerTech* (pp. 1-5). IEEE.
- [9] Zhu, D., Cheng, D., Broadwater, R. P., & Scirbona, C. (2007). Storm modeling for prediction of power distribution system outages. *Electric power systems research*, 77(8), 973-979.
- [10] Chen, P. C., & Kezunovic, M. (2016). Fuzzy logic approach to predictive risk analysis in distribution outage management. *IEEE Transactions on Smart Grid*, 7(6), 2827-2836.
- [11] Nanadikar, A. A., Biradar, V. N., & Sarma, D. S. (2014, September). Improved outage prediction using asset management data and intelligent multiple interruption event handling with fuzzy control during extreme climatic conditions. In *2014 International Conference on Smart Electric Grid (ISEG)* (pp. 1-7). IEEE.
- [12] Sahai, S., & Pahwa, A. (2006, June). A probabilistic approach for animal-caused outages in overhead distribution systems. In *2006 9th International Conference on Probabilistic Methods Applied to Power Systems, PMAPS* (pp. 1-7).
- [13] Kankanala, P., Pahwa, A., & Das, S. (2015). Estimating animal-related outages on overhead distribution feeders using boosting. *IFAC-PapersOnLine*, 48(30), 270-275.
- [14] Chawthai, P., Raphisak, P., & Katithummarugs, S. (2023, December). Association Rule Mining for Power Outages Caused by Animals and Vegetation in Electrical Distribution Systems. In *Proceedings of the 13th International Conference on Advances in Information Technology* (pp. 1-5).