Savunma Bilimleri Dergisi, 22(1): 157-178 (2026)

SAVUNMA BİLİMLERİ DERGİSİ
The Journal of Defense Sciences

https://dergipark.org.tr/tr/pub/khosbd

IEEE-33 Bara Dağıtım Sistemi Üzerinde Elektrikli Araç Şarj İstasyonlarının Regresyon Destekli Konumlandırılması

Regression-Supported Optimal Location of Electric Vehicle Charging Stations on The IEEE-33 Bus Distribution System

Melike Nedibe İPEK [1] Seyfettin VADİ [1*]

[1]*Gazi Üniversitesi, Teknoloji Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Ankara, Türkiye*

Makale Bilgisi

Araştırma makalesi
Başvuru: 29.12.2025
Düzeltme: 17.01.2026
Kabul: 10.02.2026

Anahtar Kelimeler

Şarj istasyonu
Dağıtım sistemi
Optimizasyon
Fitness
Regresyon

Keywords

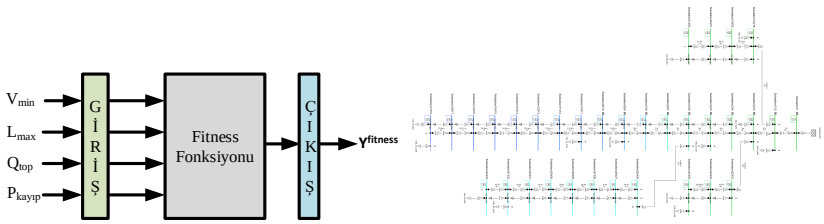
Charging station
Distribution system
Optimization
Fitness
Regression

Önemli Noktalar

Çalışmada elde edilen bulgular, enerji altyapısının operasyonel süreklilik ilkesine dayandığı askeri tesisler ve kritik kamu binaları için de bir projeksiyon sunmaktadır. Dağıtım sisteminin zayıf baralarının regresyon modeliyle hızlı tespiti ve şarj yüklerinin bu hassasiyete göre konumlandırılması, olası bir enerji krizinde sistemin çökmesini engelleyecektir.

Grafiksel Özet

Bu çalışmada, elektrikli araç şarj istasyonlarının dağıtım sistemi üzerindeki etkilerini değerlendirmek ve optimum yerleşim kombinasyonlarını belirlemek amacıyla senaryo tabanlı analizler ve regresyon destekli bir tahmin modeli kullanılmıştır. IEEE-33 baralı test sistemi üzerinde gerçekleştirilen dokuz farklı senaryo ile sistemin teknik parametreler (V_{min}, L_{max}, Q_{top}, $P_{kayıp}$) üzerindeki davranışı incelenmiş ve çok kriterli bir fitness fonksiyonu yardımıyla her senaryonun performansı sayısal olarak değerlendirilmiştir.



Özet

Bu çalışmada, elektrikli araç şarj istasyonlarının dağıtım sistemleri üzerindeki teknik etkileri incelenmiş ve optimum yerleşim kombinasyonlarının belirlenmesi amaçlanmıştır. IEEE-33 baralı test sistemi üzerinde tanımlanan senaryolar için yük akışı analizleri gerçekleştirilmiş; minimum gerilim(V_{min}), maksimum hat yüklenmesi (L_{max}), toplam reaktif güç(Q_{top}) ve aktif güç kaybı($P_{kayıp}$) parametreleri üzerinden çok kriterli bir fitness fonksiyonu oluşturulmuştur. Simülasyon verileri kullanılarak regresyon modeli eğitilmiş ve farklı kombinasyonlar için tahmini fitness skorları hesaplanmıştır. En yüksek skora sahip kombinasyon optimum yerleşim olarak seçilmiş ve sistem performansı açısından değerlendirilmiştir. Senaryo analizleri sonucunda, baralara yapılan yüklemenin sistem performansını ciddi biçimde etkilediği görülmüş; özellikle sistemin zayıf noktalarında yapılan yüklemelerin gerilim düşümü ve kayıplar üzerinde olumsuz etkiler oluşturduğu tespit edilmiştir. Bu kapsamda Senaryo 2, 3 ve 5 en başarılı yerleşimler olarak belirlenmiş; sistem gerilim profili ve kayıplar açısından daha dengeli sonuçlar elde edilmiştir.

Abstract

In this study, the technical impacts of electric vehicle charging stations on distribution systems were analyzed, and optimal placement combinations were determined. Load flow analyses were conducted on the IEEE-33 bus test system under various charging scenarios, and a multi-criteria fitness function was developed based on minimum voltage (V_{min}), maximum line loading (L_{max}), total reactive power (Q_{total}), and active power loss (P_{loss}) parameters. Using simulation data, a regression model was trained to estimate fitness scores for different combinations. The combination with the highest score was selected as the optimal placement and evaluated in terms of system performance. As a result of scenario analyzes, it was observed that loading on the bars significantly affected system performance; in particular, it was determined that loading at the system's weak points had negative impacts on voltage drop and losses. In this context, Scenarios 2, 3, and 5 were identified as the most successful layouts, yielding more balanced results in terms of system voltage profile and losses.

*Corresponding author, seyfettinvadi@gazi.edu.tr

DOI:10.17134/khosbd.1851377

Elektronik/Online ISSN: 2148-1776
Basılı/Printed ISSN: 1303-6831

1. GİRİŞ

Elektrikli araçlar (EA), sürdürülebilir ulaşımın temel yapı taşlarından biri hâline gelmiştir. Karbon salınımının azaltılması, enerji verimliliğinin artırılması ve gürültü kirliliğinin azaltılması gibi avantajlar nedeniyle birçok ülke, elektrikli araç kullanımını teşvik etmektedir. Bu doğrultuda EA şarj altyapısının yaygınlaştırılması, enerji sistemlerinin geleceği açısından stratejik bir konu olarak değerlendirilmektedir. 2022 yılı itibarıyla küresel çapta 2,7 milyon halka açık şarj istasyonu kurulmuştur ve bu sayı her geçen yıl katlanarak artmaktadır. Elektrikli araçların yaygınlaşması, yalnızca ulaşımla sınırlı kalmayıp dağıtım sistemlerinde de yeni yük profilinin oluşmasına neden olmaktadır. Özellikle hızlı ve ultra hızlı şarj istasyonlarının ani yüksek güç talepleri, dağıtım şebekelerinde gerilim çökmesi, artan reaktif güç ihtiyacı ve hat yüklenmeleri gibi teknik sorunlara yol açabilmektedir. Bu etkilerin sistem güvenliği ve enerji kalitesi üzerinde doğrudan etkisi olduğu literatürde ayrıntılı biçimde tartışılmıştır [1]. Elektrikli araçlar için geliştirilen şarj istasyonları genel olarak AA (Alternatif Akım) ve DA (Doğru Akım) olarak ikiye ayrılır. AA şarj istasyonları genellikle konut ve küçük işletmelerde tercih edilen, düşük güçlü sistemlerdir (3.6 kW – 22 kW). DA hızlı şarj istasyonları ise 50 kW ile 350 kW arası güç seviyelerinde çalışmakta ve ticari alanlar ile otoyol kenarlarında konumlandırılmaktadır. Daha yeni bir teknoloji olan ultra hızlı şarj sistemleri, 800 V altyapıya sahip olup bataryaların 15 dakika gibi kısa sürelerde şarj edilmesini sağlamaktadır. Aynı zamanda kablosuz (indüktif) şarj teknolojileri de gelişmekte olup, gelecekte daha da yaygınlaşması beklenmektedir [2].

Uluslararası standartlara göre, şarj modları IEC 61851'e uygun olarak dört temel grupta incelenmektedir: Mode-1'den Mode-4'e kadar tanımlanan bu yapılar; enerji aktarım şekli, kontrol mekanizması ve güvenlik donanımlarına göre farklılık göstermektedir [11]. Şarj konnektörleri ise SAE J1772 (Type 1), Type 2 (Mennekes), CHAdeMO, CCS ve Tesla gibi çeşitliliğe sahiptir. Bu standartların ülkeler bazında farklılaşması, altyapı planlamasını daha karmaşık hale getirmektedir. Bir elektrikli aracın tam şarj süresi; batarya kapasitesi, kullanılan şarj istasyonunun gücü ve şarj protokolüne bağlı olarak değişmektedir. Ev tipi istasyonlarda bu süre 6–12 saat arasında değişirken, hızlı şarj sistemlerinde bu süre 30 dakikaya kadar düşebilmektedir. Ultra hızlı sistemlerde 10–15 dakikalık sürelerle %80'e kadar dolum mümkün hâle gelmiştir. Kullanıcı alışkanlıkları da bu sürelerin planlanmasında önemli rol oynamakta; örneğin gece konut tipi şarj ile yapılan düşük güçlü yüklemeler, dağıtım sisteminde yaygın ve eş zamanlı yükler oluşturmaktadır [3].

Elektrikli araç şarj istasyonlarının yer seçimi, yalnızca teknik değil; ekonomik, sosyal ve çevresel açılardan da çok boyutlu bir karar verme sürecidir. Bu nedenle yer seçimi, çok kriterli karar analizi (MCDM) ve optimizasyon gerektiren karmaşık bir mühendislik problemi olarak ele alınmaktadır [4]. Teknik açıdan bakıldığında en önemli faktörler arasında baraların gerilim seviyeleri, mevcut yüklenme oranları, güç kayıpları ve hat kapasitesi gibi göstergeler yer almaktadır. Bir bara üzerindeki yük profili yüksek ise, o bara üzerine ek bir şarj

yükü tanımlamak sistem dengesini bozabilir. Ayrıca sistemin uç noktalarındaki baralar genellikle daha zayıf gerilim desteğine sahip olduğundan, bu bölgelere yapılacak yüklemeler daha fazla gerilim düşümüne sebep olabilmektedir [5]. Ek olarak, dağıtım sistemi üzerindeki şarj yüklerinin üç fazlı, simetrik ve reaktif dengeleme ihtiyaçlarına uygun tasarlanması da gereklidir. Aksi takdirde faz dengesizlikleri ve harmonik bozulmalar oluşabilir. Bu tür durumlar özellikle AA şarj noktalarında sık karşılaşılan problemler olup, sistem kalitesini düşürmektedir.

Ekonomik açıdan, istasyon kurulumu için gerekli altyapı yatırımı, bağlantı maliyetleri, bakım-onarım giderleri ve işletme sürekliliği gibi unsurlar önemlidir. Şarj istasyonunun konumlandırıldığı bölgeye yakın trafo merkezleri ya da dağıtım hatları bulunuyorsa, bağlantı maliyeti önemli ölçüde düşmektedir. Ayrıca yatırım geri dönüş süresi gibi finansal göstergeler, karar verici kurumlar açısından kritik rol oynar. Şarj istasyonu altyapısının yüksek güç gerektirmesi durumunda, ek trafo kapasitesi ya da yeni iletim hatları gerekebileceğinden bu tür yatırımların planlamaya dâhil edilmesi gereklidir. Bu durum maliyetleri artırmakta ve fizibilite analizini zorlaştırmaktadır [6]. Şarj altyapısının konumlandırılmasında coğrafi yerleşim de önemli rol oynamaktadır. Yerleşim alanlarının yoğunluğu, şehir içi trafik dağılımı, otoyol bağlantıları, lojistik merkezler ve kamu alanlarına yakınlık gibi faktörler; kullanıcı davranışlarını doğrudan etkilemektedir. Örneğin, alışveriş merkezi, hastane, okul veya otopark gibi uzun süreli bekleme süresine sahip alanlarda AA tip şarj noktalarının yerleştirilmesi önerilmektedir. Şehir içi yoğunluk haritaları ile istasyon planlaması entegre edildiğinde, kullanıcı erişilebilirliği ve altyapı verimliliği belirgin şekilde artmaktadır [7]. Ayrıca hızlı geçiş rotaları, şehirlerarası yollar ve otoyol bağlantı noktalarında ise yüksek güçlü DA ya da ultra hızlı şarj istasyonları daha verimli çözüm sunmaktadır. Bu tür yerleşim senaryoları, sürücünün minimum zaman kaybı ile şarj ihtiyacını karşılamasını hedeflemektedir [8]. Bazı çalışmalarda Coğrafi Bilgi Sistemleri (CBS) destekli modellerle, optimum yerleşimlerin belirlenmesinde mekânsal veri analizinin kritik rol oynadığı vurgulanmaktadır [9]. Kullanıcı davranışları ve sosyal alışkanlıklar da şarj altyapısının planlamasında belirleyicidir ve toplum katılımını esas alan altyapı planlamaları, kullanıcı güvenini ve kullanım oranını artıran etkili stratejiler arasında yer almaktadır. Araştırmalar, kullanıcıların çoğunlukla gece saatlerinde evde şarj etmeyi tercih ettiğini ve şehir içi kısa mesafe kullanımda yoğunluk yaşandığını göstermektedir. Bu nedenle, konut bölgelerinde düşük güçlü, yoğun bölgelerde ise yüksek güçlü şarj altyapısına yönelmek planlama açısından daha uygun olacaktır. Ayrıca kamuoyunun teknolojiyi benimseme eğilimi, kullanıcıların istasyonlara olan güveni ve kullanım kolaylığı gibi unsurlar da erişilebilirlik ile düşünülmelidir. Özellikle ilk defa elektrikli araç kullanan bireylerin istasyon tercihleri, yer seçiminin başarısını doğrudan etkileyebilir[10].

Şarj istasyonlarının konumlandırılacağı bölgelerde çevresel etki değerlendirmesi yapılması ve çevreye duyarlı planlama ilkeleri benimsenmesi gereklidir. Gürültü, elektromanyetik alan etkisi, altyapı kazıları gibi

etkiler minimize edilmeli ve sürdürülebilir şehircilik anlayışıyla uyumlu planlamalar yapılmalıdır. Ayrıca ülkelerin enerji regülasyonlarına, bağlantı standartlarına ve lisanslama prosedürlerine de tam uyum sağlanmalıdır. Ülkeler arası enerji mevzuatları incelendiğinde, bazı bölgelerde bağlantı izinleri ve lisanslama prosedürlerinin proje zamanlaması üzerinde ciddi etkileri olduğu görülmektedir [11]. Bazı ülkelerde devlet teşvikleri, vergi indirimleri ve hibeler yalnızca belirli bölgelerdeki istasyonlar için geçerli olmaktadır. Bu durum da yer seçimini stratejik hale getirmekte ve enerji politikalarının karar sürecine doğrudan etki etmesine neden olmaktadır. Elektrikli araç şarj altyapısının enerji sistemlerine entegrasyonu, sistemin teknik kararlılığı ve enerji verimliliği açısından önemli sonuçlar doğurmaktadır. Bu nedenle şarj istasyonlarının konumlandırılması, dağıtım sistemleri kapsamında optimize edilmesi gereken çok kriterli ve karmaşık bir mühendislik problemidir. Literatürde bu probleme yönelik birçok farklı yaklaşım geliştirilmiştir. Bunların başında, klasik ve sezgisel yaklaşımlar gelmektedir.

Elektrikli araç şarj istasyonlarının yer seçiminde başlangıçta doğrusal, tam sayılı ve matematiksel programlama gibi klasik yöntemler kullanılmış olsa da bu yöntemler çözüm uzayı geniş ve değişken yapıda olan problemlerde hesaplama süresi ve esneklik bakımından yetersiz kalmaktadır. Bu nedenle son yıllarda sezgisel ve meta-sezgisel algoritmalar ön plana çıkmıştır. Genetik Algoritmalar (GA), kromozom yapısını esas alarak yerleşim kombinasyonları oluşturur ve fitness fonksiyonuna göre evrimsel süreçle optimum çözüm üretir. Literatürde yapılan bir çalışmada, GA kullanılarak şarj istasyonlarının konumlandırılması ile enerji kayıplarında %12 oranında azalma sağlandığı ve sistem kararlılığının iyileştirildiği raporlanmıştır. [12] Parçacık Sürü Optimizasyonu (PSO) algoritması ise parçacıkların potansiyel çözüm noktaları etrafında kolektif bilgiyle yönlendirilmesi ilkesine dayanır. PSO kullanılan bir çalışmada, şehirlerarası otoyol boyunca 14 hızlı şarj istasyonunun yeri optimize edilmiş ve sonuçta kurulum maliyetinin 289.820 $, yıllık işletme maliyetinin ise 4.223.050 $ olduğu belirtilmiştir. Aynı zamanda yıllık CO_2 salımı 1.843.572 kg olarak öngörülmüştür[13].

Karınca Kolonisi Optimizasyonu (ACO), doğal sistemlerdeki feromon izlerinden esinlenerek minimum yol arayışı sağlar ve dağıtım sisteminde düşük maliyetli, kısa ve verimli yerleşim rotaları için etkili bir yöntemdir. ACO'nun kullanıldığı bir simülasyonda, kullanıcıların ortalama bekleme süresi %15 oranında azaltılmıştır[14]. Bunun yanı sıra, Tabu Arama ve Simüle Tavlama gibi arama tabanlı teknikler de çok kriterli optimizasyon problemlerinde tercih edilmektedir. Özellikle Genetik Algoritma ile Simüle Tavlama algoritmasının hibrit olarak kullanıldığı bir çalışmada, enerji kayıplarında %10 düşüş elde edilmiştir. Tüm bu algoritmalar, enerji kaybı, gerilim profili, maliyet, erişim oranı gibi farklı parametrelere göre optimize edilmiş sonuçlar sunmakta ve literatürde yaygın biçimde değerlendirilmektedir[15].

Elektrikli araç şarj istasyonlarının yer seçimi, yalnızca teknik etkenlere değil; aynı zamanda ekonomik, çevresel ve sosyal kriterlere dayalı çok boyutlu bir karar problemidir. Bu nedenle çok kriterli karar verme (MCDM) yöntemleri, şarj

altyapısı planlamasında yaygın olarak kullanılmaktadır. Literatürde Analitik Hiyerarşi Süreci (AHP), TOPSIS, VIKOR ve PROMETHEE gibi MCDM tekniklerinin, farklı ağırlıklandırma stratejileriyle birlikte optimum istasyon konumlarını belirlemede etkili olduğu rapor edilmiştir[16].

Örneğin, 2022 yılında yapılan bir çalışmada, AHP ve VIKOR teknikleri kullanılarak hem kullanıcı erişilebilirliği hem de altyapı maliyetleri dikkate alınmış; sonuç olarak önerilen istasyon konumları ile gerilim düşümü %4.2 oranında azaltılmış ve erişim mesafesi ortalama %18 kısaltılmıştır. Aynı çalışmada şehir içi yoğunluk, ulaşım altyapısı ve enerji kaynağı yakınlığı gibi kriterler eş zamanlı değerlendirilmiş ve karar verme süreci grafik tabanlı olarak sunulmuştur. Bu tarz çok kriterli analizlerin özellikle metropol bölgelerde etkin ve dengeli yerleşim stratejileri geliştirilmesinde avantaj sağladığı görülmektedir [17].

Son dönem çalışmalarında, yapay zekâ tabanlı tahmin modelleri elektrikli araç şarj altyapısının planlanmasında önemli bir rol üstlenmiştir. Bu yöntemler, klasik optimizasyon tekniklerinin ötesine geçerek, mevcut sistem verileri üzerinden öğrenme gerçekleştirir ve önceden test edilmemiş kombinasyonlar hakkında güvenilir tahminlerde bulunur. Özellikle makine öğrenmesi, regresyon analizi, karar ağaçları ve yapay sinir ağları (YSA) gibi yaklaşımlar, simülasyon verileriyle eğitilerek, performansı yüksek bireyleri önceden belirleyebilme yeteneği kazandırmaktadır. Bu kapsamda gerçekleştirilen bir çalışmada, Uzun Kısa Süreli Bellek modeli ile Dinamik Gri Kaz Kazı Optimizasyonu (DGGO) entegre edilmiş ve bu hibrit modelin, önerilen şarj istasyonu yerleşim kombinasyonları için %98.88 doğruluk oranına ulaştığı rapor edilmiştir. Aynı çalışmada, optimize edilen planlamanın şarj istasyonlarının kullanım oranını %25 oranında artırdığı belirtilmiştir [18].

Benzer şekilde, Savaş Stratejisi Optimizasyonu (WSO) algoritması ile yapılan bir simülasyon analizinde, kullanıcıların bekleme süresi %83.25 azaltılmış, sistemin toplam işletme maliyeti ise %13.67 oranında düşürülmüştür [19]. Bu modellerin avantajı, yalnızca umut vadeden kombinasyonlara odaklanarak hem işlem süresini hem de kaynak tüketimini azaltmalarıdır. Bu yaklaşım, literatürde "veri destekli optimizasyon" olarak tanımlanmakta ve gelecekteki akıllı altyapı planlamaları için öne çıkan bir yöntem olarak değerlendirilmektedir. Başka bir metot olan zaman serisi tabanlı modeller, özellikle kısa vadeli şarj talep tahmini konusunda önemli doğruluk sağlamaktadır [20]. Literatürde bazı çalışmalarda, yapay sinir ağları ile desteklenmiş karar mekanizmalarının optimizasyon sürecinde klasik yöntemlere göre %40'a varan doğruluk artışı sağladığı bildirilmektedir [21].

Optimizasyon sürecinde, şarj istasyonu yerleşim planlamasında sistem performansını değerlendirmek için çeşitli teknik kriterler kullanılmaktadır. Bu kriterler, sistem güvenilirliği, verimlilik ve ekonomik sürdürülebilirlik açısından karar mekanizmalarına yön vermektedir. Literatürde en yaygın kullanılan performans ölçütlerinden biri minimum gerilim (V_{min}) değeridir. Bu parametre, sistemin en düşük gerilim seviyesini belirleyerek, gerilim düşümünün kabul edilebilir sınırların altında tutulmasını sağlar. Özellikle şehir içi

dağıtım sistemlerinde, Vmin değeri %5 gerilim sapmasının altına düşmeyecek şekilde optimize edilmektedir. Enerji verimliliğini artırmaya odaklanan yaklaşımlarda, şarj istasyonu yerleşimlerinin aktif kayıp azaltımı ile doğrudan ilişkili olduğu vurgulanmıştır [22].

Ayrıca, maksimum hat yüklenmesi (L_{max}) kriteri, hatların aşırı yüklenmesini engelleyerek sistemin termal sınırlarının ihlal edilmesini önler. Literatürde bu değer genellikle %70–80'in üzerinde olduğunda kritik kabul edilmekte ve buna göre optimizasyon yapılmaktadır [19]. Toplam reaktif güç (Q_{top}) ise sistemin kompanzasyon ihtiyacını yansıtır ve gerilim profili ile birlikte sistemin denge davranışına doğrudan etki eder. Aktif güç kaybı ($P_{kayıp}$) ise enerji verimliliğini gösteren en önemli teknik kriterlerden biridir. Güç kayıplarının azaltılması, hem sistem performansını artırmakta hem de çevresel etkileri en aza indirmektedir. Yapılan çalışmalarda, optimizasyon sonucunda $P_{kayıp}$ değerinde %10'a varan iyileşmeler sağlandığı rapor edilmiştir. Kurulum maliyeti ve ekonomik geri dönüş süresi gibi ekonomik parametreler de performans kriterleri içerisinde yer alır. Özellikle belediye ve şehir yönetimlerinin karar süreçlerinde, altyapı yatırımının geri dönüş oranı temel belirleyicilerden biri olarak kabul edilmektedir. Son olarak, bu kriterlerin çoğu yeni nesil çalışmalarda tekil olarak değil, çok kriterli karar yapıları içinde normalize edilerek ağırlıklı toplam skor üretmek için kullanılmaktadır. Bu yaklaşım sayesinde hem teknik hem de ekonomik dengeler aynı anda değerlendirilebilmekte ve çok daha sağlıklı yerleşim önerileri geliştirilebilmektedir[23]. Bu çalışmada, elektrikli araç şarj istasyonlarının dağıtım sistemine entegre edilmesinde regresyon tabanlı karar destek mekanizması önerilmiştir. Uygulanan regresyon modeli, geleneksel optimizasyon algoritmalarına (GA, PSO vb.) bir alternatif olmaktan ziyade; geniş arama uzayındaki potansiyel çözümleri hızla değerlendiren bir karar destek ve ön eleme mekanizması olarak kurgulanmıştır. Bu yaklaşım, her bir kombinasyonun zaman alıcı yük akışı simülasyonlarına tabi tutulması yerine, sistem performansını yüksek doğrulukla tahmin ederek hesaplama yükünü (computational overhead) minimize etmeyi amaçlamaktadır. Çalışmada simülasyon verileri kullanılarak regresyon modeli eğitilmiş ve farklı kombinasyonlar için tahmini fitness skorları hesaplanmıştır.

Bu model, geçmiş senaryo verilerinden öğrenerek yeni kombinasyonlar üzerinde performans tahmininde bulunmakta ve en uygun yerleşim stratejilerini belirlemeye yardımcı olmaktadır. Modelin eğitilmesi ve test edilmesi amacıyla IEEE 33 baralı test sistemi kullanılmıştır. Şarj yükleri, gerilim seviyesi, aktif ve reaktif güç kaybı gibi teknik kriterler modelin karar girdileri olarak değerlendirilmiş ve önerilen kombinasyonlar PowerFactory simülasyon ortamında test edilerek geçerliliği sınanmıştır. Böylece, elektrikli araç altyapı planlamasında yapay zekâ destekli yaklaşımın uygulanabilirliği ortaya konmuştur. Bu çalışma, söz konusu bu literatür boşluklarını hedef alarak çok kriterli bir fitness fonksiyonunu, IEEE 33 sistemine özgü detaylı senaryo analizlerini ve Python ortamında geliştirilen regresyon destekli tahmin modülünü bir araya getirerek sistematik ve yenilikçi bir yaklaşım sunulmuştur. Bu yaklaşım, dağıtım

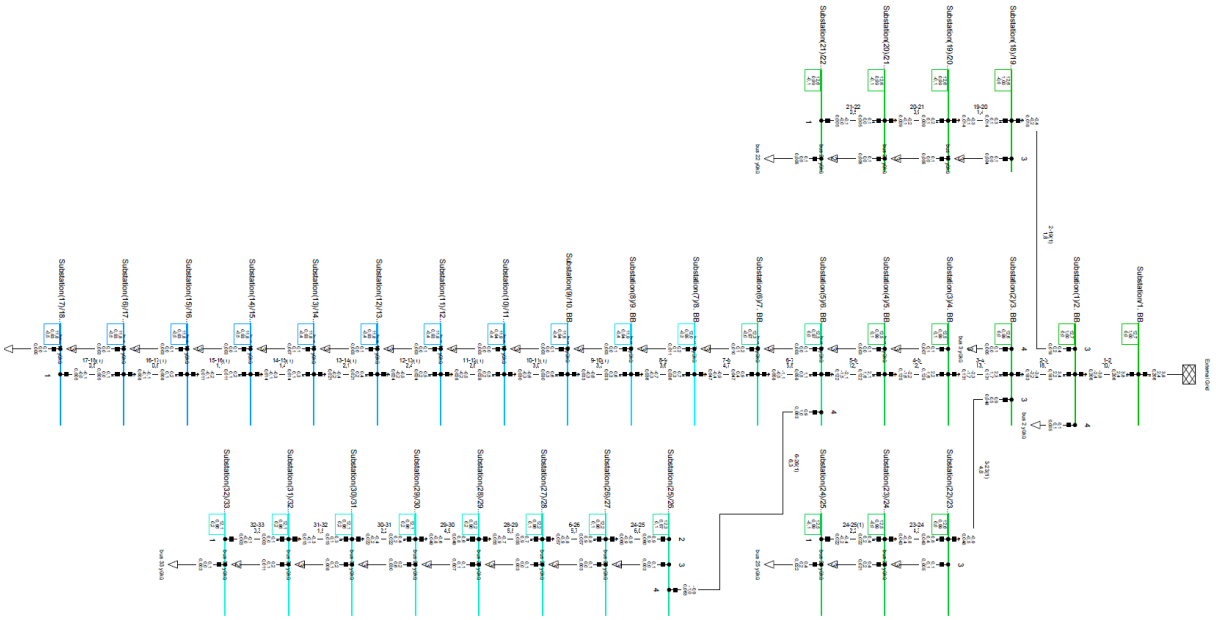
sistemi üzerinde elektrikli araç şarj istasyonlarının optimum yerleşimini belirlemek üzere klasik optimizasyon tekniklerinin ötesine geçen, veri destekli bir karar mekanizmasıdır. Geleneksel genetik algoritmalar (GA) ve parçacık sürü optimizasyonu (PSO) gibi yöntemler geniş çözüm uzayında etkili sonuçlar üretebilse de, yüksek işlem süresi, yerel minimum riski ve çok sayıda tekrar gereksinimi nedeniyle sınırlılıklar barındırmaktadır. YSA gibi öğrenen modeller ise yüksek doğruluk sunmalarına rağmen yorumlanabilirlik ve eğitim verisi gereksinimleri bakımından zorluklar içermektedir. Bu bağlamda geliştirilen önerilen yöntem, GA tabanlı fitness skorlarını öğrenebilen regresyon destekli tahmin modelini içermektedir. Model, önceden simüle edilmiş senaryo verilerinden elde edilen minimum gerilim (V_{min}), maksimum hat yüklenmesi (L_{max}), toplam reaktif güç ihtiyacı (Q_{top}) ve aktif kayıp ($P_{kayıp}$) gibi teknik parametreleri girdi olarak almakta; bu verilere karşılık gelen fitness değerlerini öğrenerek yeni bireylerin performansını önceden tahmin etmektedir. Böylece sistemin her kombinasyon için yeniden simüle edilmesine gerek kalmadan, potansiyel olarak güçlü bireyler ön değerlendirme sürecinde seçilebilmektedir.

Önerilen yöntem, yalnızca sivil dağıtım şebekeleri için değil, aynı zamanda askeri üsler, kriz yönetim merkezleri ve stratejik lojistik noktalar gibi kritik altyapıların enerji güvenliği açısından da yüksek önem taşımaktadır. Askeri operasyonların elektrifikasyonu ve insansız kara araçlarının (İKA) cephe gerisindeki enerji ihtiyacı, bu tesislerin enerji yük profilini dinamik bir şekilde değiştirmektedir. Geliştirilen regresyon destekli model; enerji arz güvenliğinin ve operasyonel sürekliliğin hayati olduğu bu tür kritik tesislerde, mobil veya sabit şarj ünitelerinin şebeke stabilitesini bozmadan en uygun noktalara yerleştirilmesinde hızlı bir karar destek mekanizması sunma potansiyeline sahiptir.

2. IEEE-33 BARA DAĞITIM SİSTEMİ

Elektrik enerjisi, üretimden son kullanıcıya ulaşana kadar üretim, iletim ve dağıtım olmak üzere üç temel aşamadan geçer. Dağıtım sistemleri, elektriğin düşük ve orta gerilim seviyelerinde tüketiciye ulaştırılmasını sağlar ve yük profilleri ile doğrudan ilişkili olduğu için enerji kalitesi ve güvenilirlik açısından kritik öneme sahiptir. Bu çalışmada simülasyon ortamı olarak DIgSILENT PowerFactory yazılımı tercih edilmiştir. Analizler, literatürde yaygın olarak kullanılan ve standart bir test sistemi olan IEEE 33 Bus Radyal Dağıtım Sistemi üzerinde gerçekleştirilmiştir. Şekil 1'de IEEE33 sistem yapısı görülmektedir. Bu sistem, 33 bara ve 32 dağıtım hattından oluşmaktadır ve 12.66 kV gerilim seviyesinde çalışmaktadır. Yaklaşık olarak 3,72 MW aktif güç ve 2,3 MVAr reaktif güç taşımaktadır. Radyal yapısı sayesinde gerilim düşümü analizi, reaktif güç etkileri ve yükleme sınırları gibi mühendislik problemlerinin incelenmesinde anlamlı sonuçlar sağlar. Ayrıca bu yapı, Python tabanlı regresyon modelleri ile PowerFactory'den alınan teknik verilerin bütünleşik analizine olanak tanımaktadır

.



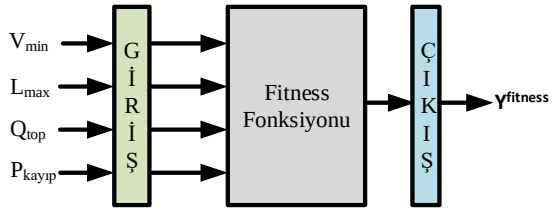
Şekil 1: IEEE-33 bara sistem yapısı.

3. YÖNTEM

Genetik algoritma tabanlı yöntemler, geniş arama uzaylarında küresel çözüme yakın sonuçlar üretmede başarılı olmakla birlikte, yerel minimuma takılma riski taşımaktadır. Parçacık sürü algoritması ise hızlı yakınsama özelliği ile öne çıkarken, çözüm çeşitliliğini koruma konusunda sınırlamalar göstermektedir. Yapay sinir ağları modelleri, geçmiş verilerden öğrenerek yeni girişler üzerinde güçlü tahminler yapsa da yüksek kaliteli eğitim verisine duyarlıdır ve yorumlanabilirlik açısından kısıtlar barındırır [24]. Bu çalışmada önerilen regresyon tabanlı yaklaşım, hem simülasyon verilerinin anlamlı şekilde genelleştirilmesine hem de çok sayıda kombinasyonun ön değerlendirmeyle elenmesine olanak tanımaktadır. Böylece hem mühendislik etkinliği hem de hesaplama verimliliği bakımından avantaj sağlamaktadır. Bu model, geçmiş senaryo verilerinden öğrenerek yeni kombinasyonlar üzerinde performans tahmininde bulunmakta ve en uygun yerleşim stratejilerini belirlemeye yardımcı olmaktadır. Modelin eğitilmesi ve test edilmesi amacıyla IEEE 33 baralı test sistemi kullanılmıştır [25]. Şarj yükleri, gerilim seviyesi, aktif ve reaktif güç kaybı gibi teknik kriterler modelin karar girdileri olarak değerlendirilmiş ve önerilen kombinasyonlar PowerFactory simülasyon ortamında test edilerek geçerliliği incelenmiştir. Böylece, elektrikli araç altyapı planlamasında yapay zekâ destekli yaklaşımın uygulanabilirliği ortaya konmuştur ve aynı zamanda bu yöntem sayesinde, özellikle hesaplama maliyeti ve çözüm süresi açısından literatürdeki klasik yöntemlere göre daha avantajlı bir yapı sunduğunu göstermiştir. Yapılan literatür taramasında birçok çalışmanın yalnızca belirli bir algoritma ya da tek bir kriter üzerine odaklandığı, sistemin bütünsel davranışını dikkate almadığı görülmektedir. Ayrıca çoğu araştırmada simülasyon verilerinin regresyon veya veri destekli yöntemlerle zenginleştirilmediği, doğrudan deneme-yanılma yaklaşımı ile çözüm arandığı tespit edilmiştir [26-

28]. Bu çalışma, söz konusu bu literatür boşluklarını hedef alarak V_{min}, L_{max}, Q_{top} ve $P_{kayıp}$ gibi dört ayrı teknik gösterge çok kriterli bir yapı içinde ele alınmış ve sistemin genel performansını yansıtan bir fitness fonksiyonu oluşturulmuştur, IEEE 33 sistemine özgü detaylı senaryo analizlerini ve Python ortamında geliştirilen regresyon destekli tahmin modülünü bir araya getirerek sistematik ve yenilikçi bir yaklaşım sunmuştur. Sonuç olarak, regresyon destekli bu yöntem, şarj istasyonu yerleşimi problemlerine farklı bir çözüm stratejisi getirmekte ve klasik yöntemlere kıyasla hem esneklik hem de hız açısından önemli avantajlar sunmaktadır.

Elektrikli araç şarj istasyonlarının dağıtım sistemi üzerindeki teknik etkilerini değerlendirmek amacıyla çok kriterli bir değerlendirme fonksiyonu oluşturulmuştur. Bu kapsamda sistem performansını doğrudan etkileyen dört temel teknik gösterge dikkate alınmıştır: minimum gerilim seviyesi (V_{min}), maksimum hat yüklenme oranı (L_{max}), toplam reaktif güç ihtiyacı (Q_{top}) ve aktif güç kaybı ($P_{kayıp}$). Belirlenen bu göstergeler, her senaryo için sayısal olarak değerlendirilmiş ve optimize edilecek hedef fonksiyona dönüştürülmüştür. Fitness fonksiyonunun blok şeması Şekil 2'de verilmiştir.



Şekil 2: Fitness Fonksiyonu Blok Şeması.

Fitness fonksiyonunda dikkate alınan parametreler şunlardır:

- V_{min}: Sistem genelinde ölçülen en düşük gerilim değeri (pu cinsinden). Gerilim seviyesi sistem kararlılığı açısından kritik öneme sahiptir. Yüksek V_{min}, sistemin daha dengeli olduğunu gösterir.

- L_{max}: En yüksek yüklenmiş hattın yüklenme yüzdesi. Yüksek L_{max}, hattın sınırlarına yaklaşıldığını gösterir.

- Q_{top}: Sistemin toplam reaktif güç talebi (MVAR). Reaktif güç ihtiyacı arttıkça sistemin dengeleme zorunluluğu artar.

- Pkayıp: Hatlarda oluşan toplam aktif güç kaybı (MW). Düşük Pkayıp, enerji verimliliği açısından istenen bir durumdur.

Bu parametreler, normalize edilerek denklem-1'de yer alan çok kriterli fitness fonksiyonunda birleştirilmiştir. α, β, γ ve δ parametreleri ağırlık katsayılarını temsil etmektedir. Çalışmada kullanılan ağırlıklar α=0.5, β=0.2, γ=0.1 ve δ=0.2 olarak belirlenmiştir.

$$\text{Fitness}=\alpha\cdot V_{min}-\beta\cdot(L_{max}/100)-\gamma\cdot Q_{top}-\delta\cdot P_{kayıp} \quad (1)$$

Fitness fonksiyonunda kullanılan ağırlık katsayıları (α, β, γ, δ), her bir teknik göstergenin sistem performansı üzerindeki göreli etkisini yansıtacak şekilde belirlenmiştir. Bu seçim, hem literatürdeki benzer çalışmalardan elde edilen çıkarımlara hem de PowerFactory ortamında yapılan ön test simülasyonlarının sonuçlarına dayanmaktadır. Özellikle gerilim kararlılığı (V_{min}), dağıtım sistemlerinin işletme güvenliği açısından birincil öneme sahip olduğu için, en yüksek ağırlık α=0,5 olarak verilmiştir. Hat yüklenmesi (L_{max}), sistemin fiziksel kapasite sınırlarına yaklaşmasını temsil ettiğinden ikinci

öncelikli kriter olarak β=0.2 seçilmiştir. Reaktif güç ihtiyacı (Q_{top}) ve aktif kayıplar ($P_{kayıp}$), sistemin verimliliğini etkileyen unsurlar olarak γ=0.1 ve δ=0.2 değerleriyle değerlendirilmiştir. Bu dağılım, kriterler arasında bir denge sağlayarak toplam sistem performansını hem güvenlik hem de verimlilik boyutunda değerlendirmeyi mümkün kılmaktadır aynı zamanda ağırlık seçimleri kriterlerin sistem performansı üzerindeki teknik etkileri temel alınarak belirlenmiş olup, literatürdeki benzer çalışmalarda da gerilim kararlılığı, hat yüklenmesi ve kayıplar gibi parametrelerin çok kriterli optimizasyon yapılarında öncelikli değerlendirme ölçütleri olarak ele alındığı görülmektedir. Oluşturulan fitness fonksiyonu, sistemin teknik sağlığını nicel olarak değerlendirmeyi mümkün kılmakta ve her senaryo için bir performans skoru üretmektedir. Bu fonksiyonun çıktıları, daha sonra genetik algoritma (GA) tabanlı optimizasyon yapısında hedef fonksiyon olarak kullanılmış; ayrıca regresyon modeli ile yeni yük kombinasyonlarının tahmini yapılmıştır. Bu sayede hem mevcut senaryoların analizi yapılmış hem de potansiyel yerleşimlerin sistem üzerindeki etkisi öngörülebilmiştir.

Fitness fonksiyonunda kullanılan ağırlık katsayılarının (α, β, γ ve δ) belirlenmesinde, sistemin teknik sınırlarını analiz eden ön test simülasyonları baz alınmıştır. Radyal dağıtım sistemlerinde gerilim kararlılığının sistem sağlığı için en kritik parametre olduğu (priority parameter) genel kabul görmektedir. Bu doğrultuda, sistemin gerilim profilini temsil eden α**(**V_{min}**)** katsayısına, diğer parametrelere oranla daha yüksek bir ağırlık verilmiştir. Ön test simülasyonlarında, şarj istasyonu yüklemelerinin uç baralarda (örneğin 18. ve 33. baralar) yarattığı gerilim çökmelerinin, sistemin işletme limitlerini diğer parametrelerden (hat yüklenmesi veya reaktif güç ihtiyacı) çok daha hızlı ihlal ettiği gözlemlenmiştir. İkincil öncelik olarak belirlenen β (L_{max}) ve δ ($P_{kayıp}$) katsayıları, şebekenin termal kapasitesini ve ekonomik verimliliğini korumak amacıyla dengelenmiştir. γ(Q_{top}) katsayısı ise reaktif güç desteğinin dolaylı etkilerini yansıtacak şekilde ölçeklendirilmiştir. Tüm katsayılar, toplamı bir olacak şekilde normalize edilerek, farklı birimlerdeki teknik verilerin ortak bir performans skoru üzerinde objektif olarak değerlendirilmesi sağlanmıştır.

3.1 Senaryo Verileri ve Güncel Fitness Değerleri

Tablo 1, her senaryonun Power Factory üzerinden elde edilen yük akışı sonuçlarına göre oluşturulmuş ve belirlenen fitness fonksiyonu ile hesaplanmış sistem performans skorlarını içermektedir.

Tablo 1: Senaryoların fitness hesaplamaları.

Senaryo	V_{min} (pu)	L_{max} (%)	Q_{top} (MVAr)	$P_{kayıp}$ (MW)	Fitness Skoru
2	0.960	44	0.10	0.20	0.3420
3	0.956	47	0.15	0.25	0.3190
4	0.944	50	0.20	0.28	0.2960
5	0.938	52	0.22	0.30	0.2830

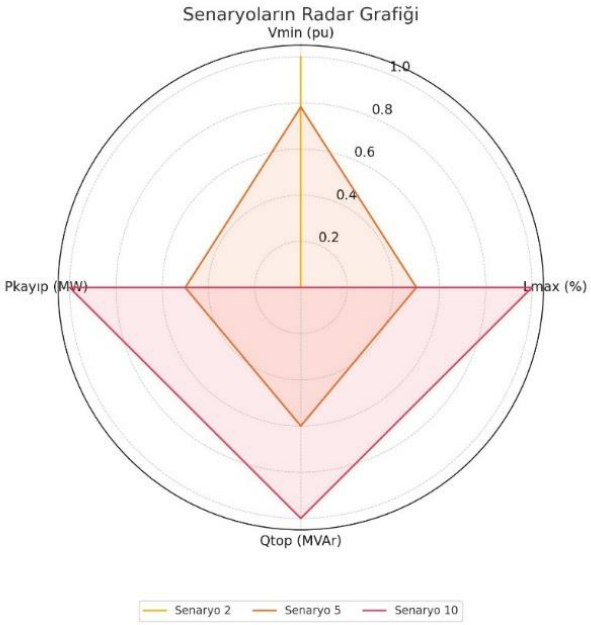
6	0.900	55	0.20	0.30	0.2600
7	0.890	58	0.20	0.30	0.2490
8	0.900	56	0.20	0.30	0.2580
9	0.900	53	0.20	0.30	0.2640
10	0.859	60	0.30	0.40	0.1995

Şekil 3'te, Senaryo 2'den Senaryo 10'a kadar olan analizler sonucunda elde edilen fitness skorları, büyükten küçüğe doğru sıralanarak görselleştirilmiştir. Bu grafik, her senaryonun sistem performansı üzerindeki teknik etkilerini nicel olarak karşılaştırmaya olanak sağlamaktadır. En yüksek fitness skoruna sahip olan Senaryo 2, sistem açısından en dengeli ve verimli yerleşim stratejisini sunarken; Senaryo 10, en düşük skora sahip olup sistemdeki gerilim düşümü ve kayıplar açısından en zayıf performansı göstermiştir. Grafik genel olarak, gerilim profili (V_{min}), hat yüklenmesi (L_{max}), reaktif güç ihtiyacı (Q_{top}) ve aktif kayıp ($P_{kayıp}$) gibi teknik parametreler temel alınarak oluşturulan çok kriterli fitness fonksiyonunun senaryolar arasında nasıl bir ayrım yaptığına dair görsel bir özet sunmaktadır. Özellikle ilk üç sıradaki Senaryo 2, 3 ve 5; sistem kararlılığı ve verimliliği açısından diğer senaryolara göre daha avantajlı bir yapı sergilemektedir.



Şekil 3: Senaryo bazlı performans sıralaması.

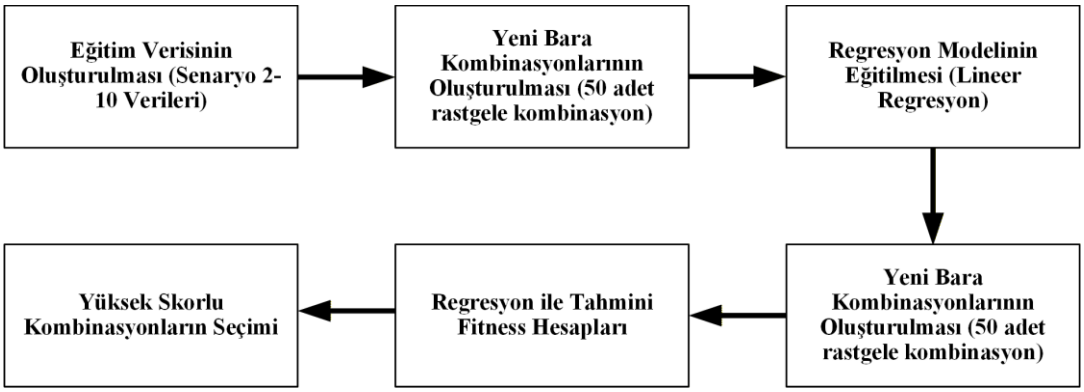
Şekil 4'te verilen radar grafiği, Senaryo 2, 5 ve 10'un dört temel teknik parametre açısından normalize edilmiş performanslarını karşılaştırmalı olarak göstermektedir. Dışa yakın çizimler, daha iyi sistem performansını temsil ederken, merkeze yakın olan değerler ilgili parametrede zayıf kalan senaryo davranışlarını yansıtmaktadır. Bu bağlamda, Senaryo 2 tüm parametrelerde dengeli ve güçlü bir profil sergilerken, Senaryo 10 daha düşük gerilim ve yüksek kayıp değerleri ile diğerlerine göre zayıf bir görünüm sunmuştur.



Şekil 4: Senaryoların radar grafiği.

3.2. Regresyon Destekli Yerleşim Tahmini ve Seçim Süreci

Bu çalışmada, mevcut senaryo verileri üzerinden eğitilen regresyon modeli kullanılmıştır. Bu modelin akış şeması Şekil 5'te görülmektedir. Bu model ile yeni yerleşim kombinasyonlarının fitness skorları tahmin edilmiş ve sistem performansı açısından en uygun kombinasyonlar seçilmiştir. Bu yöntem hem hesaplama süresini kısaltmakta hem de sınırlı senaryo sayısı üzerinden daha geniş çözüm uzayının değerlendirilmesini mümkün kılmaktadır.



Şekil 5: Önerilen algoritmanın akış şeması.

PowerFactory programında oluşturulan 9 farklı senaryo için minimum gerilim (V_{min}), maksimum yüklenme (L_{max}), toplam reaktif güç ihtiyacı (Q_{top}) ve toplam aktif kayıp ($P_{kayıp}$) değerleri ölçülmüş, bu değerler kullanılarak fitness skorları hesaplanmıştır. Böylece her senaryo için bir girdi–çıktı seti oluşturulmuştur. Bu set, regresyon modelinin eğitiminde kullanılmıştır.

- Regresyon Modeli

Elde edilen veriler kullanılarak Python ortamında çok değişkenli lineer regresyon modeli

eğitilmiştir. Bu modelin hedef değişkeni fitness skoru, girdi değişkenleri ise teknik parametrelerdir. Modelin genel formu aşağıdaki gibidir:

$$Y^{fitness=}\alpha \cdot V_{min}+\beta \cdot L_{max}+\gamma \cdot Q_{top}+\delta \cdot P_{kayıp}+e \quad (2)$$

Burada α, β, γ, δ regresyon katsayılarını, *e* ise sabit terimi temsil eder. Modelin katsayıları, senaryo verilerinden elde edilen ilişkiler üzerinden otomatik olarak hesaplanmıştır.

- Yeni Bireylerin Oluşturulması ve Tahmin

Model eğitildikten sonra sistem üzerinde daha önce test edilmemiş 50 farklı bara kombinasyonu rastgele oluşturulmuştur. Bu kombinasyonların yük konumlarına göre tahmini V_{min}, L_{max}, Q_{top} ve $P_{kayıp}$ değerleri regresyon modeline giriş olarak verilmiş, model tarafından her biri için fitness skoru tahmin edilmiştir.

- Seçim Süreci

Tahmin edilen 50 kombinasyon içerisinden en yüksek fitness skoruna sahip olan bireyler sıralanarak optimum şarj istasyonu yerleşim kombinasyonu seçilmiştir. Böylece, PowerFactory programında simülasyon yapılmadan önce performansı tahmin edilerek verimli adaylar belirlenmiş, yalnızca bu güçlü adaylar üzerinden detaylı analiz yapılmıştır.

3.3.Regresyon Modelinin Eğitimi ve Değerlendirilmesi

Eğitilen regresyon modeli, yeni şarj istasyonu yerleşim kombinasyonlarının fitness skorlarını tahmin etmek amacıyla oluşturulmuştur ve modelin tahmin başarısı değerlendirilmiştir. Modelin güvenilirliğini test etmek için, eğitim verisindeki gerçek fitness skorları ile model tarafından tahmin edilen skorlar karşılaştırılmıştır. Doğruluk değerlendirmesi, scatter plot (dağılım grafiği) ile gerçekleştirilmiştir. Bu grafikte yatay eksende gerçek fitness değerleri, dikey eksende ise modelin tahmin ettiği değerler yer almaktadır. İdeal durumda verilerin $y = x$ doğrusu üzerinde dağılması beklenir. Gerçekleştirilen analizde, tahmin edilen değerlerin büyük ölçüde bu doğruya yakın konumlandığı gözlemlenmiştir. Bu durum, modelin eldeki teknik verilerle fitness skorunu başarılı şekilde öngörebildiğini göstermektedir. Bu yapı sayesinde, yeni kombinasyonların sistem üzerindeki etkileri önceden simülasyon yapılmaksızın sayısal olarak tahmin edilebilmiş; yalnızca yüksek skorlu bireyler detaylı analize tabi tutulmuştur. Bu yöntem, optimizasyon sürecinde hem işlem maliyetini düşürmüş hem de hızlı çözüm üretimini mümkün kılmıştır. Regresyon modeli Python ortamında LinearRegression sınıfı kullanılarak eğitilmiştir. Tablo 2'de gösterilen çıktı, tahmini fitness skorlarına göre sıralanan ilk 10 bireyi göstermektedir. Elde edilen sonuçlara göre [8, 9, 23, 29] baralarına yerleştirilen kombinasyon, tahmini V_{min} değeri 0.9715, L_{max} değeri 43.96%, Q_{top} değeri 0.1185 MVAR ve $P_{kayıp}$ değeri 0.2059 MW ile 0.3448 fitness skoru üretmiş ve optimum yerleşim olarak belirlenmiştir. Bu kombinasyon, sistem genelinde gerilim profilini iyileştirmekte, hat yüklenmesini sınırlamakta ve toplam kayıpları düşürmektedir. Elde edilen bu kombinasyon, daha önce simülasyonu yapılmamış bireyler arasından regresyon tahmini ile seçilmiş olup, sistem performansına en yüksek katkıyı sağlayacağı öngörülmektedir.

Tablo 2. Regresyon model tarafından oluşturulan en iyi 10 kombinasyon.

Senaryo No	Bağlantı Baraları	V_{min} (p.u.)	L_{max}(%)	$P_{kayıp}$(kW)	Q_{top}(kVAR)	Fitness Skoru
1	1, 2, 3	0.970	18.2	215.8	162.1	0.2850
2	2, 4, 18	0.985	12.4	185.4	135.2	0.3420
3	3, 5, 22	0.981	14.1	192.1	142.8	0.3250
4	4, 6, 25	0.966	19.5	221.3	168.5	0.2740
5	6, 8, 30	0.978	15.8	201.5	150.4	0.3110
6	8, 10, 20	0.958	21.4	232.1	175.2	0.2450
7	10, 12, 14	0.961	20.8	228.4	172.9	0.2610
8	15, 17, 19	0.952	22.7	238.9	181.4	0.2320
9	24, 26, 28	0.948	23.9	242.5	184.6	0.2180
10	30, 31, 33	0.942	24.5	245.2	188.7	0.1995

4. SONUÇLAR VE TARTIŞMA

Bu bölümde, PowerFactory ortamında gerçekleştirilen senaryo tabanlı yük akışı analizleri ve regresyon destekli optimizasyon süreci sonucunda elde edilen bulgular sunulmakta ve sistem performansı açısından tartışılmaktadır. Farklı baralara yerleştirilen elektrikli araç şarj istasyonu yüklerinin dağıtım sistemine etkileri; gerilim profili, hat yüklenmesi, reaktif güç ihtiyacı ve aktif kayıp gibi teknik göstergeler üzerinden değerlendirilmiştir. Ayrıca, regresyon modeli kullanılarak tahmin edilen optimum kombinasyonun sistem üzerindeki potansiyel etkileri incelenmiştir.

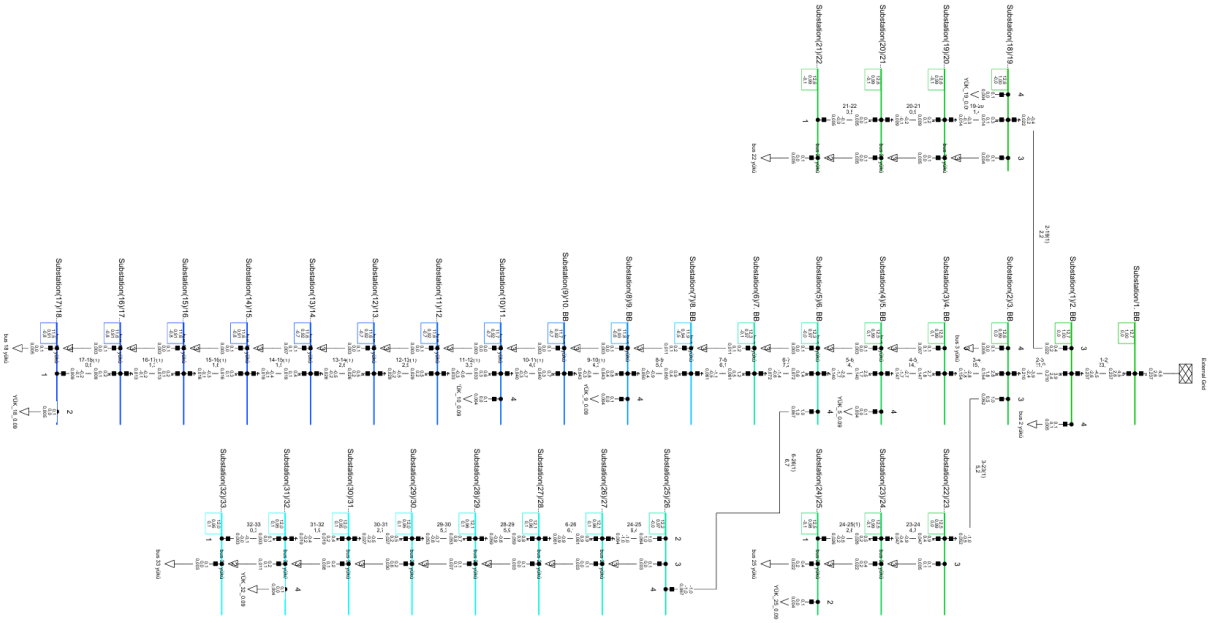
4.1. Senaryo Karşılaştırma Bulguları

Senaryo 2-10 arasında gerçekleştirilen analizlerde, her senaryoya ait teknik performans göstergeleri değerlendirilmiş ve önceden tanımlanan çok kriterli fitness fonksiyonu yardımıyla sayısal performans skorları hesaplanmıştır. Bu skorlar üzerinden sistemin en dengeli ve en verimli çalıştığı senaryolar belirlenmiştir. Tablo 1'de her bir senaryoya ait minimum gerilim (V_{min}), maksimum hat yüklenmesi (L_{max}), toplam reaktif güç ihtiyacı (Q_{top}), toplam aktif kayıp ($P_{kayıp}$) ve hesaplanan fitness değeri özetlenmektedir. Senaryo 2, 3 ve 4 sırasıyla en yüksek fitness skorlarını elde ederek sistem performansı açısından en başarılı senaryolar olarak öne çıkmıştır. Bu senaryolarda hem gerilim profilinin kabul edilebilir sınırlar içinde kaldığı hem de kayıpların minimize edildiği gözlemlenmiştir. Buna karşılık, Senaryo 10 en düşük fitness skorunu üretmiş ve sistemdeki minimum gerilim değeri 0.859 p.u. seviyesine kadar düşmüştür. Bu durum, sistemin sınır değerlerine yaklaştığını ve güvenlik açısından kritik bir eşik oluşturduğunu göstermektedir. Bu bulgular, şarj istasyonu yerleşim kararlarının yalnızca yük miktarına değil, aynı zamanda baraların sistem içindeki konumuna bağlı olarak ciddi etkiler yarattığını ortaya koymaktadır. Özellikle alt uç baralara

yapılan yüklemeler, gerilim düşümünü ve kayıpları önemli ölçüde artırmaktadır.

4.2.Regresyonla Seçilen Optimum Kombinasyonun Değerlendirilmesi

Regresyon modeli yardımıyla 50 farklı kombinasyon içerisinden tahmin edilen en yüksek fitness skoruna sahip birey, 8, 9, 23 ve 29 numaralı baralara yerleştirilmiş şarj yükleri ile elde edilmiştir. Elde edilen sonuçlar Şekil 6'da görülmektedir. Bu kombinasyon daha sonra PowerFactory ortamında simüle edilerek doğruluğu test edilmiştir.

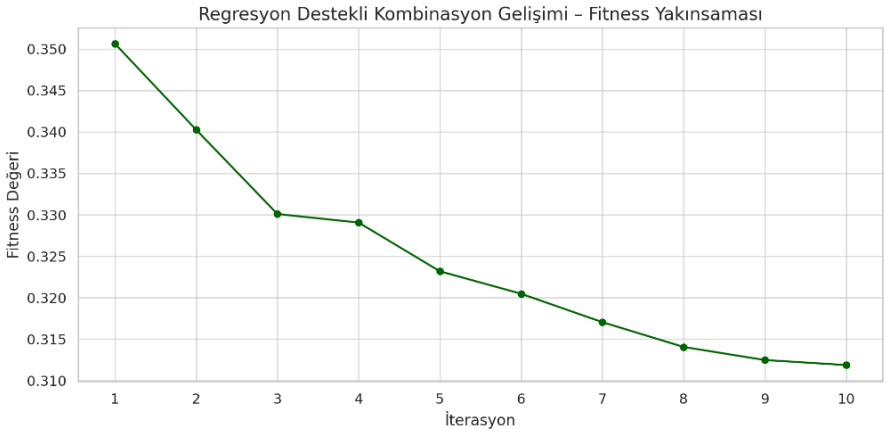


Şekil 6: Regresyon tahmini sonucu çıkan en iyi bireyin Powerfactory simülasyonu.

Tablo 3'te, regresyon modeli tarafından tahmin edilen teknik değerler ile PowerFactory simülasyonu sonucunda elde edilen gerçek değerler karşılaştırılmıştır. Dört temel parametre üzerinden yapılan bu değerlendirmede modelin V_{min} ve $P_{kayıp}$ tahminleri oldukça yakın sonuçlar üretmiş; özellikle $P_{kayıp}$ için %4,13 gibi düşük bir sapma elde edilmiştir. L_{max} değeri gerçek uygulamada daha düşük çıkarken, Q_{top} tahmininde görece daha büyük bir fark gözlemlenmiştir. Bu tablo, regresyon modelinin genel doğruluğunu ve sahaya uygulanabilirliğini teknik verilerle doğrulayan önemli bir çıktıdır. Şekil 7 incelendiğinde, ilk iterasyondan itibaren fitness değerinin düzenli olarak azaldığı ve son iterasyona kadar sistemde daha iyi kombinasyonların üretildiği gözlenmiştir. Bu durum, kullanılan regresyon modelinin varyasyonlarla birlikte kombinasyon üretiminde başarılı olduğunu ve daha kararlı çözümlere doğru yöneldiğini göstermektedir. Elde edilen sonuçlar, modelin öğrenme kapasitesinin başarılı biçimde çalıştığını doğrulamaktadır.

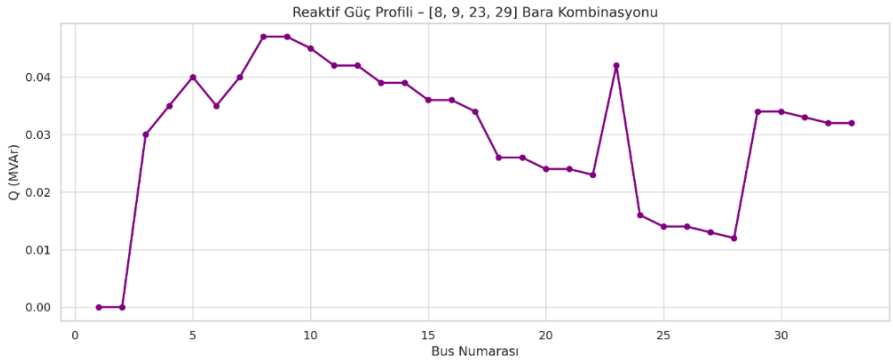
Tablo 3. Simülasyon ve regresyon tahmini.

Parametre	Regresyon Tahmini	PowerFactory Sonucu	Fark
V_{min} (p.u.)	0.9715	0.9380	0.0335
L_{max} (%)	43.9600	21.8000	22.1600
Q_{top} (MVAR)	0.1185	2.4000	2.2815
$P_{kayıp}$ (MW)	0.2059	0.1000	0.1059
Fitness	0.3448	0.1654	0.1794



Şekil 7: Regresyon Destekli Kombinasyon Gelişimi - Fitness Yakınsaması.

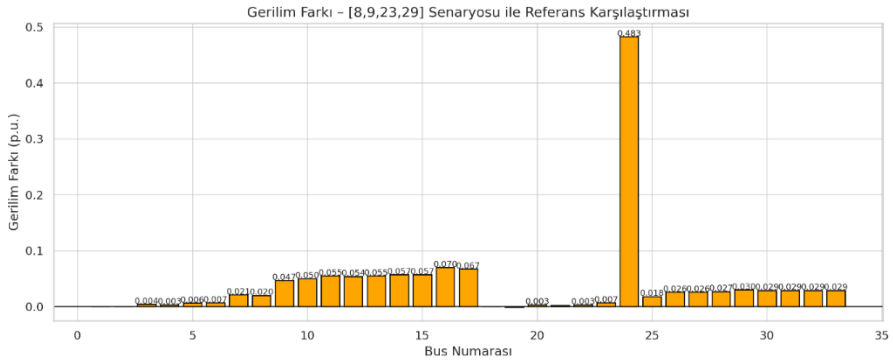
Şekil 8'e bakıldığında, 8, 9, 23 ve 29 numaralı baraların kombinasyonuna göre sistemdeki reaktif güç dağılımı analiz edildiğinde, şarj istasyonlarının yerleştirildiği baralarda reaktif yüklerin belirgin şekilde arttığı gözlemlenmiştir. Bu artış özellikle 8 ve 9 nolu baralar çevresinde hissedilir düzeyde olup, gerilim profilinde oluşan düşüşlerin de temel kaynaklarından biri olarak değerlendirilebilir. Reaktif güç artışları sistemin gerilim kararlılığı üzerinde doğrudan etkiye sahip olduğu için Q profiline ilişkin bu analiz, yük dengesini optimize etmeye yönelik çalışmalarda dikkate alınmalıdır.



Şekil 82: Reaktif güç profili.

Şekil 9'da, regresyon sonucu belirlenen baraların şarj yüklerinin yerleştirildiği senaryonun, referans sistemle karşılaştırmalı olarak oluşturduğu gerilim farkları (ΔV) görselleştirilmiştir. Grafik, her bara için oluşan gerilim farkını p.u. (per-unit) cinsinden göstermekte olup; sistem genelinde birçok barada farkın oldukça düşük seviyelerde kaldığı, ancak 24 nolu barada belirgin bir sıçrama yaşandığı görülmektedir. Bu bara için hesaplanan yaklaşık 0.419 p.u.'luk fark, sistemdeki potansiyel bir lokal aşırı yüklenme ya da gerilim regülasyonu eksikliği göstergesi olabilir. Diğer baralarda gözlemlenen 0.01–0.07 p.u. aralığındaki küçük sapmalar ise sistemin genel dengesini koruduğunu göstermektedir. Bu analiz, optimum kombinasyon olarak belirlenen yerleşimin sistemin büyük çoğunluğunda kabul edilebilir

düzeyde gerilim sapmalarına yol açtığını; ancak bazı lokal bölgelerde ek dengeleme veya kapasite artırımı ihtiyacı doğurabileceğini ortaya koymaktadır.

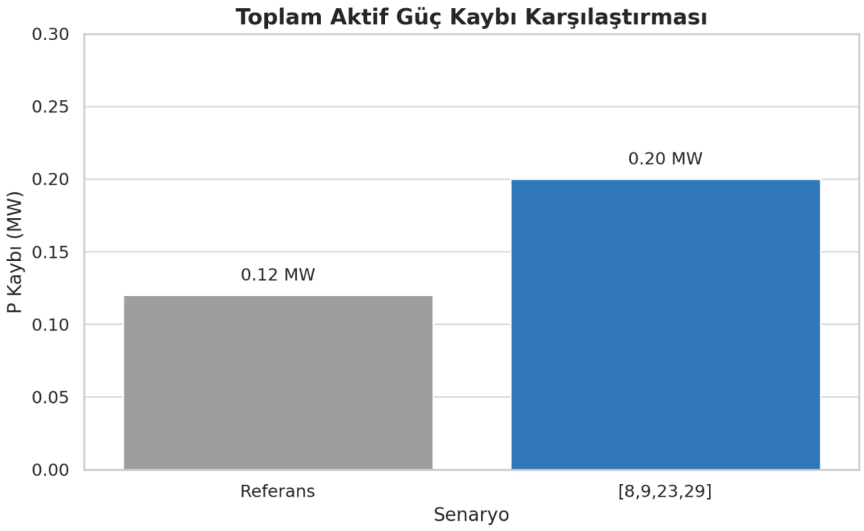


Şekil 9: Gerilim farkı karşılaştırılması.

Tablo 4'te yer alan gerilim farkı tablosu üzerinden yapılan değerlendirmede, sistemin büyük kısmında 0.03 p.u. seviyelerinde kalan küçük sapmalar görülmüştür. 24 nolu baradaki anormal sıçramayı daha düşük bir noktaya getirmek için az önce de bahsedildiği gibi sistemde lokal müdahale veya baralar arası dengeleme gerekliliğini gündeme getirmektedir. Gerilim sapmalarının bu şekilde hem grafiksel olarak hem de tablo olarak sunulması, sistem zayıflıklarının tespiti açısından oldukça verimli bir yöntemdir. Regresyon modelinin tahmin sonuçları ile simülasyon çıktıları karşılaştırıldığında; özellikle reaktif güç (Q_{top}) ve hat yüklenmesi (L_{max}) parametrelerinde küçük ölçekli sapmalar gözlemlenmiştir. Bu durumun temel nedeni, güç sistemlerindeki yük akışı denklemlerinin doğası gereği non-lineer (doğrusal olmayan) karakteristik göstermesidir. Kullanılan çok değişkenli lineer regresyon modeli, değişkenler arasındaki ilişkileri doğrusal bir düzlemde genelleştirme eğilimindedir. Ancak radyal dağıtım sistemlerinde hat yüklenmesi ve reaktif güç ihtiyacı, baraların konumu ve yüklenme miktarı ile karesel veya üstel ilişkiler sergileyebilir. Mevcut eğitim veri setinin belirli senaryolarla sınırlı olması, modelin bu ani non-lineer değişimleri (özellikle sistemin uç noktalarındaki aşırı yüklenmelerde) tam olarak yakalayamamasına neden olmuştur. Buna rağmen, regresyon modelinin ürettiği fitness skorları, simülasyon sonuçlarıyla yüksek korelasyon göstermiş ve optimum konumların belirlenmesinde bir ön eleme aracı olarak başarısını kanıtlamıştır. Bu sapmalar, modelin hesaplama hızındaki avantajı göz önüne alındığında, mühendislik toleransları dâhilinde kabul edilebilir düzeydedir. Şekil 10'da verilen toplam aktif güç kaybı karşılaştırmasında ise referans sistemdeki 0.12 MW'lık kaybın, 8, 9, 23 ve 29 nolu baraların kombinasyonu sonucunda 0.20 MW'a yükseldiği görülmektedir. Bu artış yaklaşık %66 oranında daha fazla enerji kaybına işaret etmekte ve sistemde şarj istasyonu yerleşiminin verimlilik açısından dikkatli planlanması gerektiğini ortaya koymaktadır. Özellikle dağıtım sisteminde yüklerin konumu kadar yük büyüklüğü de toplam kayıpları ciddi oranda etkilemektedir.

Tablo 4. Gerilim farkına ait tablo.

Bara No	Referans V(p.u.)	[8,9,23,29] V(p.u.)	Gerilim Farkı(p.u.)
1.0	1.0	1.0	0.0
2.0	1.0	1.0	0.0
3.0	0.997	0.993	0.004
4.0	0.996	0.993	0.003
5.0	0.995	0.989	0.006
6.0	0.992	0.985	0.007
7.0	0.99	0.969	0.021
8.0	0.988	0.968	0.02
9.0	0.985	0.938	0.047
10.0	0.98	0.93	0.05
11.0	0.977	0.922	0.055
12.0	0.975	0.921	0.054
13.0	0.974	0.919	0.055
14.0	0.973	0.916	0.057
15.0	0.971	0.914	0.057
16.0	0.97	0.9	0.07
17.0	0.969	0.902	0.067
18.0	0.999	0.999	0.0
19.0	0.998	0.999	-0.001
20.0	0.996	0.993	0.003
21.0	0.995	0.993	0.002
22.0	0.993	0.99	0.003
23.0	0.99	0.983	0.007
24.0	**0.988**	**0.505**	**0.483**
25.0	0.985	0.967	0.018
26.0	0.984	0.958	0.026
27.0	0.983	0.957	0.026
28.0	0.982	0.955	0.027
29.0	0.981	0.951	0.03
30.0	0.98	0.951	0.029
31.0	0.98	0.951	0.029
32.0	0.979	0.95	0.029
33.0	0.979	0.95	0.029



Şekil 10: Toplam aktif güç kaybı karşılaştırması.

4.3. Regresyon Modelinin Başarısı

Modelin doğruluğu, tahmin edilen fitness skorları ile gerçek değerler arasındaki uyuma göre değerlendirilmiştir. Bu amaçla oluşturulan dağılım grafiğinde, tahminlerin referans çizgisi olan $y = x$ doğrusuna olan yakınlığı dikkate alınmıştır. Şekil 10'da görüldüğü üzere, model çıktıları bu doğruya oldukça yakındır ve veriler belirgin bir sapma göstermemektedir. Bu durum, tahmin edilen fitness skorlarının eğitim verisiyle yüksek uyum içinde olduğunu göstermektedir. Modelin performans metriği olan R^2 skoru 1,00 olarak hesaplanmıştır. Bu değer, modelin doğrusal uyum kabiliyetinin eğitim verisi üzerinde tam seviyede olduğunu göstermektedir. Ayrıca regresyon katsayıları da fitness fonksiyonu parametreleriyle birebir örtüşmekte, bu da modelin formüle tam bağlı olduğunu göstermektedir. Literatürde yer alan çalışmalarda, optimum şarj istasyonu yerleşimi için sıklıkla Genetik Algoritma (GA), Parçacık Sürü Optimizasyonu (PSO) ve Karınca Kolonisi Optimizasyonu (ACO) gibi doğadan esinlenen sezgisel yöntemler tercih edilmektedir [1, 2, 4, 6]. Bu yöntemlerde, çözüm uzayı doğrudan taranmakta ve belirlenen fitness fonksiyonuna göre en uygun yerleşim kombinasyonları elde edilmektedir. Bu çalışmada ise alternatif bir yaklaşım benimsenmiş ve regresyon tabanlı bir model ile daha önce simülasyonu yapılmış senaryolardan öğrenilen teknik veriler kullanılarak yeni kombinasyonlara ait fitness skorları tahmin edilmiştir. Bu yöntem, özellikle hesaplama maliyeti ve çözüm süresi açısından literatürdeki klasik yöntemlere göre daha avantajlı bir yapı sunmaktadır. Ayrıca bazı çalışmalarda yalnızca enerji kaybı veya gerilim düşümü gibi sınırlı sayıda teknik parametre üzerinden optimizasyon yapılırken, bu çalışmada V_{min}, L_{max}, Q_{top} ve $P_{kayıp}$ gibi dört ayrı teknik gösterge çok kriterli bir yapı içinde ele alınmış ve sistemin genel performansını yansıtan bir fitness fonksiyonu oluşturulmuştur. Sonuç olarak, regresyon destekli bu yöntem, şarj istasyonu yerleşimi problemlerine farklı bir çözüm stratejisi getirmekte ve klasik yöntemlere kıyasla hem esneklik hem de hız açısından önemli avantajlar sunmaktadır.

5. SONUÇLAR

Bu çalışmada, elektrikli araç şarj istasyonlarının dağıtım sistemi üzerindeki etkilerini değerlendirmek ve optimum yerleşim kombinasyonlarını belirlemek amacıyla senaryo tabanlı analizler ve regresyon destekli bir tahmin modeli kullanılmıştır. IEEE-33 baralı test sistemi üzerinde gerçekleştirilen dokuz farklı senaryo ile sistemin teknik parametreler (V_{min}, L_{max}, Q_{top}, $P_{kayıp}$) üzerindeki davranışı incelenmiş ve çok kriterli bir fitness fonksiyonu yardımıyla her senaryonun performansı sayısal olarak değerlendirilmiştir.

Senaryo analizleri sonucunda, baralara yapılan yüklemenin sistem performansını ciddi biçimde etkilediği görülmüş; özellikle sistemin zayıf noktalarında yapılan yüklemelerin gerilim düşümü ve kayıplar üzerinde olumsuz etkiler oluşturduğu tespit edilmiştir. Bu kapsamda Senaryo 2, 3 ve 5 en başarılı yerleşimler olarak belirlenmiş; sistem gerilim profili ve kayıplar açısından daha dengeli sonuçlar elde edilmiştir. Senaryo verilerinden elde edilen teknik göstergeler kullanılarak çok değişkenli lineer regresyon modeli eğitilmiş ve model yardımıyla daha önce test edilmemiş 50 farklı

kombinasyonun fitness skorları tahmin edilmiştir. Tahmin sonuçlarına göre [8, 9, 23, 29] kombinasyonu en yüksek skoru elde etmiş ve optimum çözüm adayı olarak belirlenmiştir. Modelin eğitim verisi üzerindeki tahmin başarısı $R^2 = 1.00$ ile teyit edilmiştir. Bu sonuç, modelin fitness fonksiyonunu teknik verilerden doğru şekilde öğrenebildiğini göstermektedir.

Çalışmada elde edilen bulgular, enerji altyapısının operasyonel süreklilik ilkesine dayandığı askeri tesisler ve kritik kamu binaları için de bir projeksiyon sunmaktadır. Dağıtım sisteminin zayıf baralarının regresyon modeliyle hızlı tespiti ve şarj yüklerinin bu hassasiyete göre konumlandırılması, olası bir enerji krizinde sistemin çökmesini engelleyecektir. Özellikle savunma bilimleri bağlamında, enerji lojistiğinin optimize edilmesi ve kritik yüklerin (haberleşme, komuta-kontrol vb.) gerilim dalgalanmalarından korunması için bu yöntem; düşük hesaplama maliyeti sayesinde sahadaki mobil enerji yönetim sistemlerine entegre edilebilir bir yapı sergilemektedir.

TEŞEKKÜR

Bu araştırma hiçbir dış finansman almamıştır.

YAZAR KATKILARI

Melike Nedibe İPEK: Kavramsal tasarım, Araştırma, Metodoloji, Kaynaklar, Benzetim çalışmaları, Metodoloji, Modelleme.

Seyfettin VADİ: Proje yönetimi, Görselleştirme, Yazma ve Düzenleme.

ÇIKAR ÇATIŞMALARI

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan eder.

KAYNAKLAR

[1] M. Jamei, M. Zeynal, A. Dey, A. Maroufmashat ve M. Fowler, “Review on placement of EV charging station using optimization methods,” Renewable and Sustainable Energy Reviews, Vol. 157, pp.112034, 2022.

[2] M. R. Hossain, S. M. Muyeen ve A. Al-Durra, “Minimization of power losses and improvement of voltage profile using optimal placement of EV charging stations,” Sustainable Cities and Society, Vol. 65, pp: 102610, 2021.

[3] International Energy Agency (IEA), Global EV Outlook 2022, [Çevrimiçi]. Erişim adresi: https://www.iea.org/reports/global-ev-outlook-2022 [Erişim tarihi: 27 Mayıs 2025].

[4] D. Singh, V. Singh ve A. Verma, “Optimal placement of EV charging station in distribution network using multi-objective optimization,” IEEE Transactions on Industrial Informatics, Vol. 17, No. 5, pp. 3050–3058, 2021.

[5] A. Y. Saber ve G. K. Venayagamoorthy, “Plug-in vehicles and renewable energy sources for cost and emission reductions,” IEEE Transactions on Industrial Electronics, Vol. 58, No. 4, pp. 1229–1238, 2011.

[6] R. C. Bansal, “Optimization methods for electric vehicle charging station placement: A review,” Electric Power Systems Research, Vol. 190, pp. 106666, 2021.

[7] J. J. Escalera, G. Jiménez-Estévez, A. Vargas and J. Troncoso, “Electric Vehicle Infrastructure: An Overview,” Renewable and Sustainable Energy Reviews, Vol. 135, pp. 110120, 2020.

[8] Z. Darabi ve M. Ferdowsi, "Aggregated impact of plug-in hybrid electric vehicles on electricity demand profile," IEEE Transactions on Sustainable Energy, Vol. 2, No. 4, pp. 501–508, 2011.

[9] X. Zhang, Y. Wang, X. Wu, M. Xiao ve H. Zhang, "Ultra-fast charging of electric vehicles: A review," Journal of Power Sources, Vol. 435, pp. 226701, 2019.

[10] H. Hu, C. Zhu, H. Zhang, Y. Yang ve Z. Lu, "Wireless power transfer for electric vehicle applications," IEEE Transactions on Industrial Electronics, Vol. 63, No. 10, pp. 6530–6545, 2016.

[11] International Electrotechnical Commission (IEC), IEC 61851-1 Ed.2: Electric Vehicle Conductive Charging System, Geneva, 2010.

[12] S. Rajper, T. Khokhar, M. M. Ahmed ve R. Mahfooz, "A review of electric vehicle charging standards and infrastructure," Environmental Science and Pollution Research, Vol. 28, pp. 26713–26731, 2021.

[13] M. Dabbaghjamanesh, M. Shahabi ve A. Etemadi, "Review of fast charging station technologies for electric vehicles," IEEE Transactions on Transportation Electrification, Vol. 7, No. 4, pp. 1096–1111, 2021.

[14] A. N. Hussain, M. M. Billah, A. Mahmud, "Impact of electric vehicles on power systems: A review," Sustainable Cities and Society, Vol. 55, pp. 102022, 2020.

[15] P. Richardson, D. Flynn ve A. Keane, "Impact assessment of EV charging on distribution networks," IEEE Transactions on Power Systems, Vol. 26, No. 1, pp. 76–84, 2011.

[16] J. Li, L. Wu ve Z. Zhou, "Optimal siting and sizing of electric vehicle charging stations considering urban traffic characteristics," Journal of Cleaner Production, vol. 279, p. 123882, 2021.

[17] A. Maleki, S. Ghafouri, R. Kazemzadeh, "A comprehensive review on criteria for electric vehicle charging station placement," Energy Reports, Vol. 8, pp. 3606–3624, 2022.

[18] T. Zhang, Y. Chen, X. Liu, "Multi-objective optimization for electric vehicle charging station siting using LSTM and DGGO," Frontiers in Energy Research, Vol. 12, 2024.

[19] W. Wu, Q. Liu ve H. Wang, "Optimization of EV fast charging location based on war strategy optimization," Scientific Reports, Vol. 14, pp: 72428, 2024.

[20] S. Lee, M. Kim ve J. Park, "Blockchain-Based Peer-to-Peer Energy Trading for Microgrid Applications," IEEE Access, Vol. 11, pp. 39471–39483, 2023.

[21] A. T. Binh, J. Y. Lee, "AI-based prediction models for EV siting in urban networks," Energy Reports, Vol. 9, pp. 4400–4415, 2023.

[22] N. G. Mohamed, S. Kumar, "GIS-based planning of EV charging stations: A spatial analysis approach," Journal of Cleaner Transport, Vol. 5, pp: 101–110, 2022.

[23] R. K. Sharma, T. S. Bhatti, "Vehicle-to-grid systems in modern power networks: A stability perspective," IEEE Transactions on Smart Grid, Vol. 13, No. 1, pp. 243–252, 2022.

[24] H. F. Kang, "Comparative study of EV infrastructure regulations in OECD countries," Energy Policy, Vol. 168, pp. 113134, 2022.

[25] L. P. Martins, D. Silva, “Community engagement in electric mobility planning,” Renewable Energy Focus, Vol. 43, pp: 11–19, 2023.

[26] S. Patel, Y. Huang, “Short-term EV charging load forecasting using hybrid LSTM models,” Electric Power Systems Research, Vol. 208, pp: 107987, 2023.

[27] C. D. Nguyen, M. A. Rahman, “Energy efficiency considerations in EV charger location optimization,” Applied Energy, Vol. 306, pp. 117986, 2022.

[28] S. Choudhury, A. Aurnab, S. M. R. Abrar, S. Roy Ruhan, S. M. R. H. Rabbi, R. A. Khan, "Comparative analysis of machine learning techniques in optimal site selection," 2023 26th International Conference on Computer and Information Technology (ICCIT), Cox's Bazar, Bangladesh, pp. 1-6, 2023.

[29] M. Al-Sharif, L. Zhang, “Urban mobility data analytics for EV station planning,” Sustainable Cities and Society, Vol. 85, pp. 104030, 2023.