



CBS ve makine öğrenmesi ile elektrikli araç şarj istasyonlarının yer seçimine etki eden kriterlerin belirlenmesi

Determination of location selection criteria of electric vehicle charging stations with GIS and machine learning

Muhammed Oğuzhan Mete^{1,*} 

¹ İstanbul Teknik Üniversitesi, Harita Mühendisliği Bölümü, 34469, İstanbul Türkiye

Öz

Elektrikli araç kullanımının dünya genelinde artması, yeni şarj istasyonu kurulumlarının ihtiyacını da ortaya çıkarmaktadır. Bu çalışmanın temel amacı günümüzde içten yanmalı motora sahip araçların yerini alan elektrikli araçların şarj istasyonları için uygun yer seçimi modelinin geliştirilmesidir. Bu amaç doğrultusunda Almanya'nın Münih ile İtalya'nın Milano şehirleri çalışma bölgesi olarak belirlenmiştir. Bu şehirlerin seçilmesinde elektrikli araç şarj istasyonlarının sayısının fazla olması ve ülkelerin trafik ve sürüş kültürü açısından Türkiye'ye benzerliği öne çıkmıştır. Çalışma kapsamında Coğrafi Bilgi Sistemleri (CBS) ile konumsal analizler yapılmış, Açıklanabilir Yapay Zeka (XAI) teknikleri ile regresyon analizi gerçekleştirilerek şarj istasyonları için en uygun yerlerin belirlenmesinde kullanılabilecek bir tahmin modeli geliştirilmiştir. Rastgele Orman yöntemiyle kriterlerin ağırlıkları belirlenmiş ve model doğruluğu Milano şehrinde %27 iken Münih şehrinde %87 olarak gözlemlenmiştir. Sonuç olarak elektrikli araç şarj istasyonları için mevcuttaki istasyonlara ait kullanım verisine dayalı çıkarımlar ile en uygun konumların seçiminde etkin kriterler belirlenmiştir. Böylelikle bu alandaki yatırımların karar destek sistemi ile yönlendirilmesi sağlanarak kaynakların etkin kullanılması, elektrikli araç sahiplerine uygun ulaşım altyapısının sunulması ile fosil yakıtlı araçlardan elektrikli araçlara geçişin kolaylaştırılması amaçlanmıştır.

Anahtar kelimeler: Açıklanabilir yapay zeka, Coğrafi bilgi sistemleri, Elektrikli araç şarj istasyonu, Makine öğrenmesi, Yer seçim analizi

1 Giriş

Fosil yakıtlı araçlar günümüzde yaygın bir şekilde kullanılmaktadır. Bu araçların çevreye yaydığı kirleticiler, şehir yaşamına büyük ölçüde zarar vermektedir. Hava kirliliği, sera gazı emisyonları ve gürültü kirliliği gibi çevresel sorunlar, şehirlerin yaşanabilirliğini ciddi bir şekilde tehdit etmektedir. Sera gazlarının yayılımında rol oynayan en büyük faktörlerden biri de karbondioksit emisyonudur. Ulaşım sektörü dünya genelindeki CO₂ emisyonlarının yaklaşık %28'inden sorumludur [1]. Ulaşım sektöründe kullanılan araçların büyük bir kısmını içten

Abstract

As the use of electric vehicles increases worldwide, the need for new charging station installations arises. The main objective of this study is to develop a suitable location selection model for electric vehicle charging stations, which are replacing vehicles with internal combustion engines nowadays. For this purpose, Munich, Germany, and Milan, Italy, have been selected as the study areas. The selection of these cities is based on the high number of electric vehicle charging stations and the similarity of these cities to Türkiye in terms of traffic and driving culture. Within the scope of the study, spatial analysis is performed with Geographic Information Systems (GIS), regression analysis is performed with Explainable Artificial Intelligence (XAI) techniques, and a model that can be used to determine the most suitable locations for charging stations is developed. The weights of the criteria are determined using the Random Forest method, and the model accuracy is observed to be 27% in Milan and 87% in Munich. As a result, the criteria that are effective for selecting the most suitable locations for electric vehicle charging stations have been determined with inferences based on the utilization data of existing stations. Thus, it aims to facilitate the transition from fossil fuel vehicles to electric vehicles by ensuring the efficient use of resources by directing investments in this field with a decision support system and providing suitable transportation infrastructure for electric vehicle owners.

Keywords: Explainable AI, Geographic information systems, Electric vehicle charging station, Machine learning, Site selection analysis

yanmalı motorlu araçlar oluşturduğu için meydana gelen çevresel sorunlar şehirlerin sürdürülebilirliğini olumsuz yönde etkilemektedir. Bu olumsuz etkileri indirgeyebilmek amacıyla ülkelerin ekonomik modeli açısından önemli bir etken olan enerji verimliliğini arttırmaya yönelik politikalar benimsenmiştir. Şehirlerin sürdürülebilirliğini arttırmak ve daha sağlıklı bir çevrede yaşamayı mümkün kılacak bir alternatif için bazı stratejiler öne sürülmüştür [2]. Bu kapsamda enerji verimliliğini arttırmak, hava ve gürültü kirliliğini azaltmak için içten yanmalı motorlu araçlardan elektrikli araçlara geçişin sağlanması amaçlanmaktadır.

* Sorumlu yazar / Corresponding author, e-posta / e-mail: metemu@itu.edu.tr (M. O. Mete)

Geliş / Received: 24.05.2025 Kabul / Accepted: 03.10.2025 Yayınlanma / Published: 15.10.2025

doi: 10.28948/ngumuh.1705574

Çevresel ve ekonomik anlamda sürdürülebilirliği gerçekleştirebilmek için birçok şehrin kamu idarelerinde fosil yakıtlı araçlar yerine elektrikli araç kullanımının artırılma çabaları gözlemlenmektedir [3]. Enerji Piyasası Düzenleme Kurumu (EPDK)'nın Mart 2025 tarihli verilerine göre Türkiye'deki elektrikli araç sayısı 220 bine ulaşırken, toplam şarj soketi sayısı da hızla artarak 28 binin üzerine çıkmıştır [4]. Elektrikli araç ve şarj altyapısı 2030 projeksiyonuna göre elektrikli araç sayısının ortalama 1.3 milyona, şarj soketi sayısının ise 142 bine ulaşacağı öngörülmektedir [5]. Elektrikli araçların kullanımının artmasıyla şarj istasyonlarına olan gereksinim de artmaktadır. Elektrikli araçların kullanım menzilleri konusunda bulunan kısıt sebebiyle uygun yerlerde kurulacak şarj istasyonlarının konumlarının belirlenmesi bir sorun olarak ortaya çıkmaktadır. Bu sorun ele alınırken olumlu ve olumsuz birçok kriterin değerlendirilmesi gerekmektedir.

Bian vd. [6] şehirlerdeki elektrikli araçların şarj istasyonlarının en uygun konumunu belirlemek için Coğrafi Bilgi Sistemleri (CBS)'yi temel alan bir Karma Tam Sayılı Doğrusal Olmayan Programlama (Mixed-Integer Non-linear Programming - MINLP) yaklaşımı geliştirmiştir. Bu modelde tüm yeni istasyonların toplam kârını maksimuma çıkarmaya yönelik nesnel bir fonksiyon benimsenmiş ve yöntem, İsveç'in Västerås kentinde bir vaka çalışması uygulanarak gösterilmiştir.

Ghodusinejad vd. [7] İran'ın güneyindeki Kiş adasındaki güneş enerjili elektrikli araç şarj istasyonlarının konumunu belirleyebilmek amacıyla CBS'ye dayalı Çok Kriterli Karar Verme (ÇKKV) yaklaşımını içeren AHP yöntemi kullanmıştır.

Karaşan vd. [8] elektrikli araç şarj istasyonlarının konumlarının belirlenmesi için seçilen alternatifleri değerlendirmek amacıyla DEMATEL, AHP ve TOPSIS yöntemlerini kullanmış ve bu yöntemlere entegre bir ÇKKV yaklaşımı uygulamışlardır. Çalışma yapılacak bölge olarak İstanbul seçilmiştir.

Karolemeas vd. [9] elektrikli araçların kamuya açık şarj noktalarının kurulmasında uygunluğu etkileyen ana faktörleri belirlemek amacıyla uzmanlarla görüşme yapılarak AHP'yi de içeren karma bir yöntem yaklaşımını ele almışlardır. Araştırma Yunanistan'da yürütülmüş olsa da daha küresel bir bağlamda geçerli ve genellenebilir olabilecek yöntemler önermeyi amaçlamışlardır.

Keawthong vd. [10] elektrikli taksiler için yeterli tesisler de dahil olmak üzere, Bangkok'taki taksilerin seyahat düzenleri ve trafik koşullarının bir analizi yoluyla Bangkok'taki elektrikli taksiler için potansiyel şarj yerlerini belirlemeyi amaçlamıştır. Uygulamalar yapılırken Google Haritalar'dan yararlanılmıştır.

Wu vd. [11] elektrikli araçların şarj istasyonları için yer seçiminin belirlenmesi için bulut modeli ile birleştirilmiş PROMETHEE metodunu karar sistemi olarak uygulamıştır. Uygulanan bu metodun desteklenmesi için Çin'in Pekin kentinde bir çalışma gerçekleştirilmiş ve bu yöntemin uygun olduğuna karar verilmiştir.

Csonka ve Csiszár [12] elektrikli araçların yakıt ikmalinin sağlanması için şehir içi ve şehirlerarası olmak üzere iki ayrı şekilde konum belirlemek için inceleme

gerçekleştirmiştir. Şehir içinde bölgeler altıgen şeklinde parsellere ayrılmış ve altıgenin paralel kenarları arasında 250 metre olmasına dikkat edilmiştir. Bu kurallara göre uygun şarj istasyonları yerleştirilmiştir. Şehirlerarasında ise 50 kilometrede bir olacak şekilde dinlenme tesisleri konumlandırma için uygun görülmüş ve bu dinlenme tesisleri belirli kalite gruplarına göre ayrılmıştır. Bu çalışmada uygulamalar Budapeşte ilinde gerçekleştirilmiştir.

Güler ve Yomralıoğlu [3] elektrikli araçlar için yapılan şarj istasyonlarının konumlarının belirlenmesi için AHP ve Bulanık Analitik Hiyerarşi Prosesi (BAHP) yöntemlerini kullanmıştır. Belirlenen konumların sıralanması için TOPSIS kullanılmıştır. Çalışma alanı olarak İstanbul ilinin Üsküdar, Kadıköy ve Ataşehir ilçeleri seçilmiştir.

Micari vd. [13] bir yol ağındaki elektrikli araç şarj istasyonlarının hem sayılarını hesaplamak hem konumlarını belirlemek için bir metodoloji sunmuştur. Araçların özellikleri, elektrikli araç akışı ve şarj istasyonu teknik özellikleri dikkate alınarak problemler ele alınmıştır. İlk olarak şarj istasyonlarının sayıları daha sonra ise konumları olmak üzere iki aşamaya sahip bir model dikkate alınmıştır. Bu makalede çalışma alanı olarak İtalyan otoyolları seçilmiştir.

Erbaş vd. [14] elektrikli araçların şarj istasyonlarının konumlarının belirlenmesi için ilk olarak 15 kriter belirlemiş ve ardından bu kriterlere göre ArcGIS yazılımını kullanarak bir mekansal analiz gerçekleştirmiştir. ArcGIS yazılımıyla haritalandırma işlemi gerçekleştirildikten sonra ise AHP kullanılmıştır. Bu yöntemlerle şarj istasyonları için uygun konumlar belirlenmiştir. Çalışma alanı olarak bu makalede Ankara ili seçilmiştir.

Napoli vd. [15] bir otoyol ağında elektrikli araç altyapılarının en uygun konumlarını sağlamak için ilgi çekici yerler (alışveriş merkezleri, sinemalar, restoranlar, vb.), şehir içi yollar ve halka açık otoparklar, şehir dışı yollar ve otoyollar olmak üzere bu üç faktörün ortak kullanımına atıfta bulunan yeni bir metodoloji önermiş ve test uygulaması yapmıştır. Önerilen metodolojide hem elektrikli araç akışı (talep) hem de karayolu ağı (arz) ile ilgili veriler göz önünde bulundurulmuştur.

Çalışmalarda genel olarak CBS tabanlı ÇKKV yöntemlerinin uygulandığı görülmektedir. İdeale Benzerliğe Göre Sıra Tercihi Tekniği (The Technique for Order of Preference by Similarity to Ideal Solution: TOPSIS), Zenginleştirme Değerlendirmeleri için Tercih Sıraması Organizasyon Yöntemi (Preference Ranking Organization Method for Enrichment Evaluation: PROMETHEE), Karar Verme Deneme ve Değerlendirme Laboratuvarı (Decision making trial and evaluation laboratory: DEMATEL) gibi yöntemler kullanılmıştır. Son yıllarda yapılan çalışmalara bakıldığında özellikle ÇKKV yöntemlerinin elektrikli araç şarj istasyonu konumlarının analizinde kullanıldığı görülmektedir [16-18].

Elektrikli araç şarj istasyonları için uygun yer seçimi yapılırken sosyal, ekonomik ve çevresel birçok kriter göz önünde bulundurulmalıdır. Bu kriterler şehir içi ve şehirlerarası yollarda farklılık göstermektedir. Bu çalışmada CBS ve makine öğrenmesi yöntemleri ile elektrikli araç şarj istasyonları için uygun yer seçimi belirlenmiştir. Bu çalışma

için belirlenen kriterler, şehir içi yollar göz önünde bulundurularak belirlenmiştir. Sosyal, çevresel ve ekonomik olmak üzere farklı kriterlerin değerlendirilmesi için yakınlık ve eğim analizi uygulanmıştır. Elde edilen sonuçlar, makine öğrenmesi modeline aktararak regresyon analizi gerçekleştirilmiştir. Bunun sonucunda şarj istasyonlarının optimum yer seçimi için bir tahmin modeli geliştirilmiş, istasyonların konumlandırılmasında etkin olan faktörlerin önem skorları elde edilmiştir.

Bu çalışmanın temel amacı günümüzde içten yanmalı motora sahip araçların yerini alan elektrikli araçların şarj istasyonları için en uygun yer seçimi modelinin geliştirilmesidir. Böylelikle elektrikli araç kullanıcılarının şehir içi veya şehirlerarasında sorun yaşamaması ve sorunsuz bir yolculuk geçirmesi amaçlanmaktadır. Elektrikli araç şarj istasyonlarının uygun lokasyonlara konumlandırılması, genellikle ÇKKV yöntemleri ile ele alınmaktadır. ÇKKV yaklaşımında karar vericilere (uzman görüşüne ya da ankete dayalı) göre bir tercih durumu söz konusu olmaktadır. Ancak bu tür geleneksel yöntemlerin yerine makine öğrenmesi tabanlı regresyon analizi gerçekleştirilmesi veri odaklı bir yaklaşım sunmakta ve kriterler arasındaki ilişkileri ortaya çıkararak daha doğru sonuçlar elde etme potansiyeline sahiptir. Açıklanabilir yapay zeka tekniklerinin elektrikli araç şarj istasyonları yer seçiminde kullanılması, çalışmanın özgünlüğünü artıran bir unsur olarak öne çıkmaktadır. Makine öğrenmesi sayesinde, elektrikli araç şarj istasyonlarının en etkili yerlerde konumlandırılması, çevresel ve toplumsal faktörlerin daha ayrıntılı bir şekilde analiz edilmesiyle mümkün olmaktadır. Bu yönüyle özgün bir yaklaşım sunan çalışma, çevresel sürdürülebilirliği artırmak ve elektrikli araç kullanımını teşvik etmek amacıyla büyük öneme sahiptir.

2 Materyal ve metot

Çalışma kapsamında şarj istasyonlarının en uygun yer seçimi için şarj istasyonlarını olumlu veya olumsuz yönde etkileyebilecek kriterler belirlenip sosyal, ekonomik ve çevresel kriterlere ait veriler açık veri portalları kullanılarak elde edilmiştir. Bu verilere yakınlık ve eğim analizleri uygulanmış, elde edilen çıktılar makine öğrenmesi modeline aktararak regresyon analizi gerçekleştirilmiştir. Bu çalışmada elektrikli araç şarj istasyonları için en uygun yer seçimi modeli geliştirilmiş, açıklanabilir yapay zeka ile kriter önem skorları hesaplanmıştır. **Şekil 1**'de çalışmanın iş akış şeması gösterilmektedir.

2.1 Çalışma bölgesi

Çalışma kapsamında elektrikli araç şarj istasyonu kurulumu için en uygun yer seçimi modelinin geliştirilmesinde gerekli kriter ağırlıklarının CBS ve Makine Öğrenmesi destekli elde edilebilmesidir. Çalışma bölgesi olarak Almanya'nın Münih ve İtalya'nın Milano şehirleri seçilmiştir (**Şekil 2**). Bu şehirler belirlenirken nüfus yoğunluğu, şehirlere ait elektrikli araç sayıları, elektrikli araç şarj istasyonları sayıları ve elektrikli araç satışlarına dikkat edilmiştir. İncelenen bu şehirler sosyoekonomik açıdan birbirlerine benzerlik göstermekte olup ekonomik anlamda gelişmiş şehirlerdir. Öte yandan Almanya ve İtalya yapı itibarıyla ülkemizle benzerlikler taşıdıkları için elektrikli

araç şarj altyapısının gelişiminde örnek uygulamalar geliştirmek amacıyla ele alınmış, mevcut istasyonların konumlandırılmasında etkin olan konumsal faktörlerin araştırılması için kullanım verilerinden yararlanılmıştır.

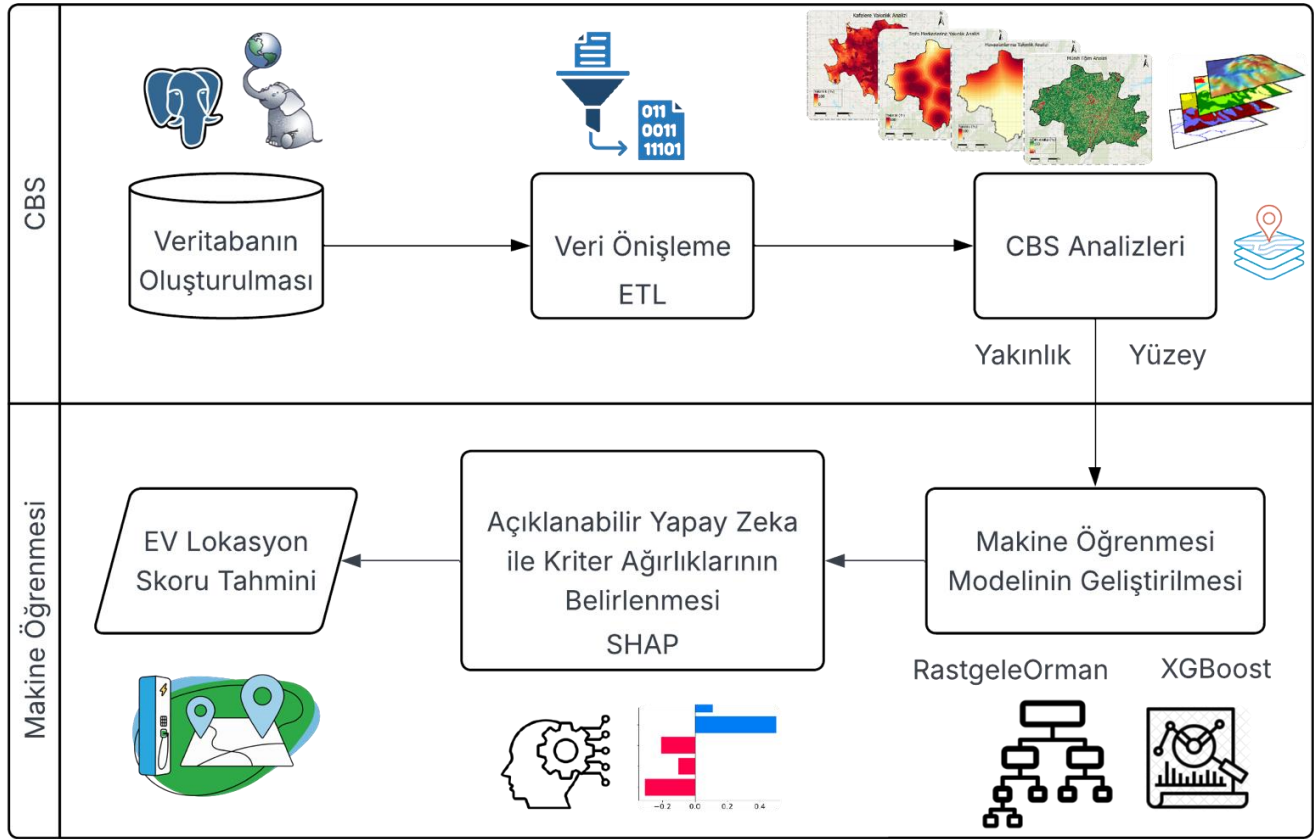
2.2 Şarj istasyonları için uygun lokasyon belirlemede etkin rol oynayan kriterlerin belirlenmesi

Elektrikli araçlar için gerekli olan şarj istasyonlarının optimum lokasyonlarının belirlenmesinde birçok farklı kriter etkili olmaktadır. Kriterlerin seçimi genellikle literatürde yaygın olarak kabul gören önerilere göre belirlenmektedir. Yeşil alanlar, sağlık merkezleri, eğitim kurumları gibi insanların sosyal ve kültürel anlamda daha fazla vakit geçirdikleri alanlarda elektrikli araç şarj istasyonlarının bulunması ya da bu alanlara yakın olması tercih edilmektedir [9], [18].

Elektrikli araç şarj istasyonları otoparklardaki park yeterliliği, halka açık yerlerdeki park imkanları, park edilen araba sayıları ve mevcut şarj istasyonları açısından incelenmiştir [19]. Elektrikli araç şarj istasyonları için uygun yer belirlenmesinde otoparklara olan yürüyüş mesafesi, trafo merkezleri ile park alanları arasındaki uzaklık gibi kriterler de etkili olmuştur [20]. Elektrikli araç şarj istasyonu yer seçiminde kriterlerin doğru bir şekilde belirlenmesi, oluşturulacak modeli etkileyeceği için oldukça önemlidir. Elektrikli araçların ihtiyaç duyduğu şarj istasyonlarının uygun lokasyonlarının belirlenebilmesi için sosyal, ekonomik ve çevresel kapsamda kriterlerin göz önüne alınması ve coğrafi verilerin işlenmesi gerekmektedir [14]. Nüfus yoğunluğunun yüksek olduğu alanlar daha kalabalık alanlar olduğundan bu bölgelerdeki insan faaliyetleri daha fazladır ve bu sebeple ulaşım gereksinim duyulmaktadır [18]. Bu nedenle nüfus yoğunluğu, elektrikli araç şarj istasyonları için yer seçiminde önemli bir kriterdir.

Elektrikli araç şarj istasyonu konumlarının uygunluğuna etki edebilecek potansiyel kriterler literatür araştırması sonucunda belirlenmiştir [21], [22], [23], [24], [25], [26], [27], [28], [29], [30].

Bu kapsamda elektrikli araç şarj istasyonları için uygun yerlerin belirlenmesinde rol oynayan 27 kriter seçilmiştir (**Tablo 1**). Kriterlerin büyük çoğunluğu yakınlık kapsamında değerlendirilmekte olup, alışveriş merkezlerine, benzin istasyonlarına, sağlık merkezlerine, yeşil alanlara yakınlık gibi faktörler seçilmiş, topografik açıdan ise eğim faktörü ele alınmıştır [31-40]. Kriterlere ait mekânsal verilerin elde edilmesinin yanı sıra diğer bir önemli veri kaynağı elektrikli araç şarj istasyonlarına ait gerçek kullanım verileridir. Bunun için literatürde de sıklıkla belirtildiği üzere açık kaynaklı olarak paylaşılan herhangi bir veri seti bulunmamaktadır. Bu kapsamda Amerika Birleşik Devletleri (ABD) ve Avrupa kıtasındaki ülkelerin büyük çoğunluğunda farklı firmalar tarafından işletilen elektrikli araç şarj istasyonlarına ait anlık kullanım verilerinin görüntülenebildiği bir web sayfasının (chargepoint.com) API servisi kullanılmıştır [41].



Şekil 1. Elektrikli araç şarj istasyonu yer seçimi için izlenen iş akış şeması

Python programlama dilinde “requests” kütüphanesi kullanılarak belli kısıtlar dahilinde istasyonlara ait kullanım verilerinin periyodik olarak (Gün-Hafta-Ay) Nisan 2024 ile Ağustos 2024 tarihleri arasında elde edilmesi sağlanmıştır. Kullanım verileri içerisinde istasyon id, port sayısı, kullanım durumu (kullanımda veya müsait), tarih, saat, enlem ve boylam bilgileri yer almaktadır. Milano için 296, Münih için ise 518 şarj soketinden sürekli olarak veri çekilmiş, veriler işlenerek her bir istasyonun yaklaşık bir aylık periyotta kaç kez kullanıldığı hesaplanarak kullanım yoğunluğu elde edilmiştir. Böylelikle kullanım yoğunluğu ve lokasyon arasındaki ilişkinin makine öğrenmesi yöntemleri ile belirlenmesi mümkün hale gelmiştir.


2.3 Veri tabanının oluşturulması

Veri tabanının oluşturulması, projenin ihtiyaç duyduğu verilerin düzenli bir şekilde depolanmasını, erişilmesini ve yönetilmesini sağlar. Veri tabanı, projenin farklı bileşenleri arasında veri alışverişini kolaylaştırır ve veri bütünlüğünü korur. Bu çalışma kapsamında belirlenen kriterlere uygun bir şekilde veriler bir araya getirilerek coğrafi veri tabanı oluşturulmuştur. Coğrafi verilerin saklanması için veri tabanı olarak QGIS yazılımıyla entegre olan PostgreSQL/PostGIS veri tabanı kullanılmış, veriler ve analiz sonuçları veri tabanında tutulmuştur. QGIS yazılımında QuickOSM eklentisi üzerinden OpenStreetMap (OSM) verileri çalışma bölgesi için temin edilerek veri tabanına aktarılmıştır. Yakınlık analizi kapsamında yapılan ağ analizinde yol verisi

olarak da OSM’ye ait yol verileri kullanılmıştır. Eğitim analizlerini gerçekleştirebilmek için USGS Earth Explorer üzerinden açık veri olarak paylaşılan 30 metre mekânsal çözünürlüğe sahip Shuttle Radar Topography Mission (SRTM) sayısal yükseklik modeli kullanılmıştır [42]. Son olarak elektrikli araç şarj istasyonlarının anlık kullanım verilerinin on dakikalık aralıklarla çekilen kullanım verileri de PostGIS veri tabanına aktarılmıştır.

2.4 CBS analizleri

CBS analizleri kapsamında kriterlerin değerlendirilmesi amacıyla yakınlık ve yüzey analizleri gerçekleştirilmiştir. Yakınlık analizi için QGIS yazılımında ağ tabanlı yakınlık analizi gerçekleştirilmiştir. Ağ tabanlı yakınlık analizi, yol ağlarını gerçekçi bir şekilde modelleyerek bu modeller ile güzergah, servis bölgesi, en yakın tesis gibi çeşitli ağ tabanlı yakınlık analizleri yapılmasını sağlar. Bu kapsamda çalışmada yakınlık kriterleri için ağ analizi ile servis bölgeleri oluşturulmuştur. Servis bölgesi, belirli bir seyahat süresi veya seyahat mesafesi içindeki bir konumdan ulaşılabilen bölgeyi ifade etmektedir. Servis alanlarının elde edilmesinin ardından arazi türü, nüfus, altyapı gibi çeşitli özniteliklerle bütünleştirilerek lokasyona ait sosyo-demografik özellikler tespit edilebilmektedir.



(a)



(b)

Şekil 2. Çalışma bölgesi: a) Münih ve b) Milano şehirleri

Tablo 1. Çalışmada kullanılan kriterler

Kriter No	Kriter Adı	Veri Kaynağı
1	Alışveriş merkezleri	OSM
2	ATM	OSM
3	Benzin istasyonları	OSM
4	Dinlenme tesisleri	OSM
5	Eczaneler	OSM
6	Eğim	USGS
7	Hastaneler	OSM
8	Havaalanı	OSM
9	Kafeler	OSM
10	Kamu binaları	OSM
11	Metro durakları	OSM
12	Meydanlar	Google Maps
13	Okullar	OSM
14	Oteller	OSM
15	Otobüs durakları	OSM
16	Otogar	OSM
17	Otoparklar	OSM
18	Otoyol kavşağı	OvertureMaps
19	Parklar	OSM
20	Restoran	OSM
21	Sinema	OSM
22	Stadyum	OSM
23	Trafo merkezleri	OSM
24	Tramvay durakları	OSM
25	Tren istasyonları	OSM
26	Üniversiteler	OSM
27	Yeşil alanlar	EEA Copernicus

Çalışma kapsamında seçilen kriterlerin yollara olan uzaklıkları dikkate alınarak gerçekleştirilen ağ analizinde kullanılan veriler vektör formatındadır. Kriterlerin ilgili servis bölgelerine olan uzaklıkları baz alınarak bir puanlandırma yapılmış ve mesafeye dayalı normalizasyon yaklaşımı izlenmiştir (Tablo 2). Normalizasyon işlemi literatürdeki çalışmalardan faydalanılarak 0'dan 10.000 metreye kadar 1.000 metre aralık olacak şekilde, mesafe aralıkları 0-100 arasında 10 puanlık farklarla yeniden sınıflandırılmıştır [43-45]. Yola en yakın aralık olarak belirlenen 0-1.000 metre aralığı en yüksek puan olan 100 puan ile ifade edilmiştir, 10.000 metreye kadar 10 puan azalacak şekilde belirlenmiştir. Şekil 3'te Münih şehrinin metro duraklarına yakınlık analizi gibi görülmektedir.

Tablo 2. Kriter puanlarının mesafeye dayalı normalizasyonu


Min. Mesafe (m)	Maks. Mesafe (m)	Kriter Puanı
0	1000	100
1000	2000	90
2000	3000	80
3000	4000	70
4000	5000	60
5000	6000	50
6000	7000	40
7000	8000	30
8000	9000	20
9000	10000	10
10000	∞	0

Eğim, bir yüzeydeki iki nokta arasındaki yükseklik farkının, bu noktalar arasındaki yatay mesafeye oranı olarak tanımlanabilir [46]. Eğim, bir yüzeyin veya arazinin ne kadar engebeli veya düz olduğunu belirten bir ölçüdür. Eğim genellikle derece veya yüzde cinsinden ifade edilir. Bir bölgede eğim analizi yapabilmek için yükseklik bilgisine ihtiyaç duyulur. Bu sebeple eğim analizi için sayısal yükseklik modeli gereklidir. Bu çalışmada QGIS yazılımı üzerinden eğim analizlerini gerçekleştirmek için “Slope” aracı kullanılmıştır. İki şehre ait sayısal yükseklik modelleri kullanılarak gerçekleştirilen analizler sonucunda eğim değerleri yüzde olarak elde edilmiş, yeniden sınıflandırma işlemine tabi tutularak elektrikli araç şarj istasyonu lokasyonlarına etkisini yansıtmak için kriter puanına dönüştürülmüştür (Şekil 4). Böylece eğimli arazilerin skorlarının düz arazilere göre daha düşük olması sağlanmıştır. Tablo 3'te literatürdeki çalışmalar dikkate alınarak yeniden sınıflandırma işlemi yapılan eğim analizi kriter puan aralıkları gösterilmektedir [47-49].


Konumsal analiz skorlarına göre sınıflandırılan tüm kriterler bir araya getirilerek konumsal birleştirme işlemine tabi tutulmuştur. Konumsal birleştirme işlemi sonrasında yakınlık analizi skorları istasyonların kullanım verileri ile QGIS Python konsolu üzerinden bütünleştirilerek makine öğrenmesi analizlerinde kullanılmaya hazır hale getirilmiştir.

Tablo 3. Eğim aralıklarının yeniden sınıflandırılması

Min. (%)	Maks. (%)	Kriter Puanı
0	1	100
1	2	90
2	3	80
3	4	70
4	5	50
5	7	30
7	12	10
12	∞	0



Şekil 3. Münih şehri: Metro duraklarına yakınlık analizi



Şekil 4. Milano şehri: Eğim analizi

2.5 Makine öğrenmesi yöntemleriyle regresyon analizi

Makine öğrenmesinde sıkça kullanılan regresyon analizi bağımlı ve bağımsız değişkenler arasındaki bağlantıyı modelleyebilmek ve analiz işlemlerini gerçekleştirmek için kullanılır [30]. Bu kapsamda regresyon analizi, elektrikli araç şarj istasyonlarının yerlerinin belirlenmesinde gereken kriter önem skorlarını belirlemek için kullanılmıştır. Bu çalışmada makine öğrenmesi yöntemi olan regresyon analizi CBS ile entegreli bir şekilde uygulanmıştır. Çalışma kapsamında Milano ve Münih şehirlerine ait OSM açık veri kaynağından elde edilen verileri kullanarak CBS analizleri gerçekleştirilmiş ve bu analizler Python ile Scikit-learn kütüphanesinden yararlanılarak çeşitli regresyon modellerine tabii tutulmuş, doğrulukları karşılaştırılmıştır. Uygulanan regresyon analizi yöntemlerinden en doğru sonuca ulaşılan model belirlenerek CBS analizlerinde kullanılan kriterlerin önem dereceleri belirlenmiş ve bu kriterlerin elektrikli araç şarj istasyonlarının konumlarının belirlenmesi amacıyla oluşturulan model ile önem dereceleri ortaya çıkartılmıştır.

Makine öğrenmesi algoritmalarından biri olan regresyon, sürekli değişkenlere sahip olan örneklerin girdi-çıkı değerleriyle modellenmesini sağlayan ve tahmin gerçekleştiren denetimli öğrenme yaklaşımı olarak ifade edilebilir. Regresyon analizi gerçekleştirilirken çoğunlukla mevcut verilerden öğrenerek istatistiksel ve sayısal verilerin tahmin edilmesi amaçlanır. Regresyon, doğrusal veya doğrusal olmayan regresyon olarak ikiye ayrılır. Doğrusal olmayan regresyon analizlerinin doğrusal regresyondan farkı yinelemeli tahmin algoritmalarının kullanılmasıdır. Doğrusal regresyon, bağımlı değişken sayısına göre basit doğrusal regresyon ve çoklu regresyon olarak iki gruba ayrılır.

Rastgele Orman (Random Forest), sınıflandırma ve regresyon problemlerini yüksek doğrulukla gerçekleştirebilen güçlü bir topluluk öğrenme yöntemidir. Birçok karar ağacından oluşan Rastgele Orman yönteminde veri kümesindeki özellikler kullanılarak regresyon analizi gerçekleştirilmektedir. Regresyon uygulaması için karar toplama yaklaşımı, verilen tüm kararların ortalaması olarak hesaplanmaktadır. Her bir karar ağacı için rastgele örnekler kullanıldığı için model karmaşıklığı (varyansı) azaltılarak aşırı uyum eğiliminin (overfitting) önüne geçilmektedir. Gradyan Artırma Yöntemlerinden (Gradient Boosting Method) olan XGBoost, makine öğrenmesi alanında sıklıkla kullanılan ve yüksek doğruluğa sahip algoritmalarındandır. XGBoost yöntemi hızlı ve etkili çalışmakta ancak kategorik değişkenleri otomatik olarak işleyememektedir.


Makine öğrenmesinde sıkça kullanılan regresyon analizi bağımlı ve bağımsız değişkenler arasındaki bağlantıyı modelleyebilmek ve analiz işlemlerini gerçekleştirmek için kullanılır [50]. Bu kapsamda regresyon analizi, elektrikli araç şarj istasyonlarının yerlerinin belirlenmesinde gereken kriter önem skorlarını belirlemek için kullanılmıştır. Bu çalışmada bir makine öğrenmesi yöntemi olan regresyon analizi CBS ile entegreli bir şekilde uygulanmıştır. Çalışma kapsamında iki şehre ait OSM kaynaklı veriler ile CBS

analizleri gerçekleştirilmiş ve bu analizler Python yazılımında Scikit-learn kütüphanesinden yararlanılarak Rastgele Orman ve XGBoost yöntemleriyle çeşitli regresyon modellerine tabii tutulmuştur. Uygulanan regresyon analiz yöntemlerinin metrik doğrulukları karşılaştırılarak en doğru sonuca ulaşılan model belirlenmiş, CBS analizlerinde kullanılan kriterlerin önem dereceleri ve bu kriterlerin elektrikli araç şarj istasyonlarının konumlarının belirlenebilmesi için gereken modeli oluşturulmuştur.

CBS yardımıyla analizler gerçekleştirildikten sonra toplanan veriler bir tahmin modeli geliştirmek amacıyla makine öğrenmesi ile regresyon analizine tabii tutulmuştur. API üzerinden elde edilen şarj istasyonu kullanım verileri bağımlı değişken olarak belirlenirken konumsal kriterler de bağımsız değişken olarak belirlenmiştir. Topluluk Öğrenmesi (Ensemble Learning) yöntemlerinden biri olan Rastgele Orman modeli kullanılarak bağımlı ve bağımsız değişkenler arasındaki ilişkiler analiz edilmiştir (Denklem 1). Burada $\hat{y}$ bağımlı değişken, X_n bağımsız değişken, b_0 sabit değeri, b_n ise katsayılar olarak ifade edilmektedir.

$$\hat{y} = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (1)$$

İlk olarak veriler Jupyter Notebook Python ortamına Pandas DataFrame olarak aktarılmış, veriler hakkında detaylı bilgilerin öğrenilmesi için Keşifsel Veri Analizi (Exploratory Data Analysis - EDA) gerçekleştirilmiştir. EDA, verilerin istatistik ve çeşitli görselleştirme teknikleri kullanılarak daha iyi anlaşılmasını sağlayan, veri bilimi projeleri için olmazsa olmaz bir adımdır. Bu aşamada tanımlayıcı istatistikler (minimum, maksimum, ortalama, standart sapma vb.) hesaplanmış, verideki boş değerler kontrol edilerek korelasyon matrisi, histogram, kutu grafiği, dağılım grafiği, ikili karşılaştırma grafikleri kontrol edilmiştir. Özellik mühendisliği aşamasında aykırı değer tespiti, eksik verilerin tamamlanması, kategorik verilerin kodlanması ve özellik seçimi gibi işlemler yapılmıştır. Aykırı değerler verilerde sapmalara sebep olarak regresyon analizinde zayıf uyuma neden olmaktadır. Çalışmada Çeyrekler Arası Aralık (Interquartile Range - IQR) yöntemi uygulanarak aykırı değerler tespit edilmiş ve veri setinden kaldırılmıştır. Ayrıca ortalama ve ortalama değer istatistikleri kullanılarak verideki eksik değerler makul değer yaklaşımı ile doldurulmuştur. Korelasyon analizi iki rastgele değişkenin birbirleriyle olan doğrusal bir şekilde oluşturulan bağlantısının kalitesini ve yönünü hesaplayan istatistiksel bir ölçümdür. Analizlerden sağlanan veriler, bağımlı ve bağımsız değişkenlerin doğruluklarını kontrol edebilmek ve birbirleri arasındaki ilişkiyi anlamak için Pearson Korelasyon analizine tabii tutulmuş, kriterlere ait korelasyon matrisi oluşturulmuştur (Şekil 5). Elde edilen veriler Python'da scikit-learn kütüphanesinin train_test_split metodu kullanılarak rastgele bir şekilde %70 eğitim ve %30 test verisi olarak bölünmüştür. Bu kapsamda veriler XGBoost ve Rastgele Orman analizlerine tabi tutularak yeni modeller üretilmiştir. Modellerin doğruluklarını ve performanslarını inceleyebilmek amacıyla başlangıçta regresyon modeli varsayılan parametreler ile eğitilmiştir.



Şekil 5. Değişkenlere ait korelasyon matrisi

Hiperparametre optimizasyonu kapsamında k-katlı çapraz doğrulama yöntemi (k-fold cross validation) randomized search ve grid search ile birlikte uygulanmış, geliştirilebilir bir model elde edilmesi sağlanmıştır. Model doğruluklarını ölçümleyip karşılaştırmak için R^2 , Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve Kök Ortalama Karesel Hata (Root Mean Square Error - RMSE) gibi çeşitli doğruluk metrikleri kullanılmıştır. Belirtme katsayısı R^2 , regresyon analizinde değişkenlerin ilişkisini belirtmektedir (Denklem 2). Bu değer, 0 ile 1 arasında bir değere sahiptir ve 1'e ne kadar yakınsa model o kadar iyidir. MAE, tahminlerin ortalama mutlak hatasını göstermektedir. Bu değer ne kadar düşüğe model o kadar iyidir (Denklem 3). RMSE, tahminlerin karekök ortalama karesel hatasını hesaplamaktadır. Bu değer düşük olması modelin daha doğru sonuçlar verdiğini göstermektedir (Denklem 4).

$$R^2 = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$


$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Yapılan coğrafi analizlerden meydana gelen veriler yardımıyla eğitilen regresyon modelleri kullanılarak tahmin modeli oluşturulmuş ve bu tahmin modellerine ait farklı doğruluk metrikleri hesaplanmıştır. Ortaya çıkan regresyon modelleri doğruluk metriklerine göre kıyaslandığında en doğru sonucun Rastgele Orman yöntemine ait olduğu gözlemlenmiştir (Tablo 4). Rastgele arama ve grid arama çapraz doğrulama yaklaşımları sonucuna göre hiperparametreler şehirlere göre farklılık göstermiştir. Milano şehri için geliştirilen model parametreleri


max_depth=70, min_samples_leaf=5, min_samples_split=5 ve n_estimators=200 iken; Münih şehri için geliştirilen modelde max_depth=50, min_samples_leaf=4, min_samples_split=5 ve n_estimators=800 olarak kullanılmıştır. Kriter önem skorları, tahmin sürecinde bir değişkenin etkisini yorumlamaya olanak sağlamaktadır. Rastgele Orman modeline göre CBS analizlerinde kullanılan kriterlerin önem skorları da hesaplanmıştır (Şekil 6, Şekil 7).

Tablo 4. Makine öğrenmesi regresyon modellerinin performans metrikleri.

Şehir	Yöntem	R^2	MAE	RMSE
Milano	XGBoost	0.2646	7.0914	9.2863
	RastgeleOrman	0.2774	6.1107	7.8092
Münih	XGBoost	0.8602	7.8091	13.2165
	RastgeleOrman	0.8724	6.5837	11.8067




Şekil 6. Milano şehrine ait öznelilik önem skorları



Şekil 7. Münih şehrine ait öznelilik önem skorları

2.6 Açıklanabilir Yapay Zeka (eXplainable AI – XAI)

Açıklanabilir yapay zeka (eXplainable AI – XAI), yapay zeka modellerinin tahmin ve karar verme aşamalarını, bu süreçteki çalışma mekanizmalarını insanlar tarafından anlaşılabilir hale getirme yaklaşımıdır. Açıklanabilir yapay zeka algoritmalarından biri olan SHAP (SHapley Additive exPlanations), makine öğrenmesi modellerini açıklayıp yorumlamak için kullanılmaktadır. SHAP yöntemi, oyun teorisinden ilham alınarak geliştirilen Shapley değerlerini kullanmaktadır. SHAP yöntemi sayesinde özneliliklerin modeli olumlu veya olumsuz hangi yönde etkilediği gözlemlenir. SHAP, makine öğrenmesi sonucu elde edilen modellerin daha kolay anlaşılması ve yorumlanması için kullanılan açıklanabilir yapay zeka algoritmalarından biridir. SHAP yöntemi, elde edilen tahmin modeline her değişkenin etkisini hesaplayan ve değişkenler ile kullanılan Shapley değerleri arasındaki bağımsızlığı temel alan bir yaklaşımdır [51]. Bu çalışmada SHAP analizi özneliliklere uygulanarak özneliliklerin modele olan pozitif veya negatif etkilerini öne çıkarmıştır (Şekil 8, 9).



Şekil 8. Milano şehrine ait SHAP grafiği


3 Bulgular ve tartışma

Regresyon analizi sonucunda üretilen özellik önem skorları ve SHAP grafiklerine bakıldığında, konumsal kriterlerin elektrikli araç şarj istasyonları ile arasında pozitif bir ilişki bulunmaktadır. Stadyum, alışveriş merkezleri, hastaneler diğer kriterlere oranla daha fazla öne çıkmaktadır. Münih şehrine ait SHAP grafiğine bakıldığında stadyumlara yakınlık kriterinin modeli oldukça güçlü ve pozitif yönde etkilediği, fakat bazı negatif tarafta da modele etki ettiği verilerin de bulunduğu görülmektedir. Özellikle maç günlerinde stadyumlarda yoğun bir kullanım olduğu için diğer günlerde modele etkisinin az olması sebebiyle bu şekilde bir durumun meydana geldiği sonucuna varılmıştır. Öte yandan etkinlik günlerine ait kullanım verilerinin veri setinden çıkarılmasıyla yapılacak analizler ile ilgili kriterin özel günlerdeki durumu daha net bir şekilde ortaya çıkarılabilir.

CBS analizleri için gereken kriterler belirlenmiş ve bu kriterler makine öğrenmesiyle çeşitli regresyon analizlerine sokularak kriter ağırlıkları elde edilmiştir. Regresyon modelleri olarak XGBoost ve Rastgele Orman yöntemleri kullanılmış, gerçekleştirilen analizlerinden sonra Rastgele Orman yönteminin daha yüksek doğruluğa eriştiği görülmüştür. Rastgele Orman yaklaşımının Milano örneğinde R^2 0.2774, MAE 6.1107, RMSE 7.8092 olarak hesaplanırken; Münih örneğinde R^2 0.8724, MAE 6.5837, RMSE ise 11.8067 olarak hesaplanmıştır.

Rastgele Orman yöntemiyle kriterlerin ağırlıkları belirlenmiş ve model doğruluğu Milano’da %27 iken Münih’te %87 olarak gözlemlenmiştir. Bu sebeple

çalışmanın Münih modelinde daha verimli sonuçlar alınmıştır. Elektrikli araç şarj istasyonlarına ait kullanım verilerine, API kısıtlanması sebebiyle limit dahilinde erişim sağlanabilmektedir. Milano şehrinde istasyon sayısının yetersiz kalması (veri azlığı), model başarısını olumsuz yönde etkilemiştir. Öte yandan OSM gibi açık kaynaklı coğrafi verilerin de veri kalitesi anlamında kısıtları modelin başarısını etkileyen diğer bir unsur olarak öne çıkmaktadır.



Şekil 9. Münih şehrine ait SHAP grafiği

Model oluşturulurken kullanılan kriterler SHAP analizine sokulmuş ve kriterlerin modele olan olumlu veya olumsuz katkıları SHAP grafiği ile incelenmiştir. SHAP analizi sayesinde bu kriterlerin kolay bir şekilde yorumlanabildiği görülmüştür. Öznitelik önem skorlarına ve SHAP grafiklerine bakıldığında Münih şehrinde öne çıkan öznitelikler 0.16’ya yakın önem skoruyla stadyumlar ve 0.10’a yakın önem skoruyla meydanlar olmuştur. Bahsedilen özniteliklerin SHAP değerlerine bakıldığında ise modele olumlu yönde katkı sağladıkları tespit edilmektedir. Milano şehrine bakıldığında öznitelik önem skorlarına göre öne çıkan öznitelikler 0.09’a yakın önem skoruyla meydanlar ve 0.08’e yaklaşan değer ile AVM’ler olmuştur. Bu özniteliklerin SHAP grafiğindeki değerlerine bakıldığında modele katkılarının olumlu derecede ve yüksek olduğu gözlenmektedir.

Kullanım verilerinin makine öğrenmesi modeli ile değerlendirilmesi sırasında sağlıklı bir çıkarım yapılabilmesi için uzun süreli periyotta verilerin elde edilmesi gereklidir. Birkaç aylık kullanım verileri güncel durumu göstermek için faydalı olsa da mevsimsellik etkisinin daha uzun süreli veri

ile analiz edilebileceği, şarj istasyonu yer seçimi modelinde konumsal kriterlere ait ağırlıkların daha yüksek doğrulukla belirlenebileceği ortaya çıkmaktadır.

4 Sonuçlar

Çalışma kapsamında elektrikli araç şarj istasyonları için optimum lokasyonların belirlenmesine yönelik CBS destekli bir karar-destek sistemi geliştirilmiştir. Bu konuda dünya genelinde gerçekleştirilmiş çalışmalar olmakla birlikte, yapay zeka ve makine öğrenmesi yöntemlerinin henüz bu konulara tam olarak uygulanmadığı görülmektedir. Elektrikli araç şarj istasyonları için optimum yer belirlenmesinde ÇKKV yöntemleriyle birçok çalışma bulunmasına rağmen hata payını en aza indirmek ve doğru sonuçlar alabilmek için bu çalışmada makine öğrenmesi yöntemleri kullanılmıştır. Böylece hem dünyada hem de ülkemizde ilk kez bu yöntemlerle kullanım verisine dayalı, bilimsel bir yaklaşımla elektrikli araç şarj istasyonu için yer seçimi modeli geliştirilmiştir.

Münih ve Milano şehirlerinde gerçekleştirilen analizler sonucunda elde edilen makine öğrenmesi modelinde sinema, hastane, otobüs durağına yakınlık gibi kriterlerin ağırlıkları iki şehir için aynı hesaplanmış; üniversite, stadyum, otel, meydan gibi kriterlerin yakınlık analizleri sonucundaki ağırlıkları ise farklılık göstermiştir. Bu sonuç şehirlerin özgün dokuları sebebiyle meydana gelebilmektedir.

Konum tabanlı analizler gerçekleştirilirken yakınlık ve eğitim analizleri Milano ve Münih üzerinde uygulanmış olup bu analizlerden elde edilen çıktılar konumsal birleştirme ile tek bir tablo haline getirilmiş ve regresyon analizinde kullanılmıştır. Mekansal analizler gerçekleştirildikten sonra elde edilen verilerin daha sonra makine öğrenmesinde kullanılmak üzere PostgreSQL veri tabanında tutulması veri kaybı olmaması açısından önemli bir rol oynamış ve çalışmanın hızlı bir şekilde gerçekleşmesine olanak sağlamıştır. Proje çalışmasında kullanılan makine öğrenmesi algoritmaları Python ortamında yazılmıştır ve Jupyter Notebook ortamında bölümlü bir şekilde çalışılıp model doğrulukları kontrol edilerek hazırlanmıştır. Bu çalışmada, üzerinde çalışılan Münih ve Milano modelinin geliştirilmesi, çalışmanın Türkiye modeli için yol gösterici nitelikte olacaktır. Ülkemizdeki şarj istasyonlarının yaygınlığının artmasıyla birlikte kullanım verileri analiz edilerek bu çalışmada önerilen modelin uygulanması mümkün olabilecek, şarj istasyonları ile konum ilişkisi değerlendirilerek optimizasyon yapılması mümkün hale gelecektir.

Dünya genelinde enerji dönüşümü ve sürdürülebilirlik hedefleri artmaktadır. Elektrikli araçlar da fosil yakıtlı araçlara göre daha çevre dostu bir seçenek sunmaktadır. Bu nedenle, elektrikli araç kullanımını teşvik etmek ve desteklemek için şarj altyapısına olan ihtiyaç giderek artmaktadır. Bu anlamda yapılan çalışma enerji sektörüne sürdürülebilirlik alanında da önemli bir katkı sunmaktadır. Akıllı ulaşım alanında büyük veri analizi ve veri madenciliği tekniklerini kullanarak, kullanıcı davranışları, trafik yoğunluğu ve enerji tüketimi gibi önemli verilerin entegrasyonu sonucunda güvenli, verimli ve ekonomik çözümler geliştirilebilmektedir. Bu verilerin analizi,

gelecekteki şarj istasyonu ihtiyaçlarını tahmin etmek için kullanılabilir. Kullanıcıların şarj istasyonlarını bulmaları, kullanmaları ve ödeme yapmaları için kullanıcı dostu bir mobil uygulama veya web tabanlı platform geliştirme, kullanıcı deneyimini iyileştirmek ve elektrikli araçları yaygınlaştırma için önem arz etmektedir. Ayrıca gelecekteki elektrikli araç kullanım eğilimlerini ve talebini tahmin etmek, veri analitiği ve yapay zeka yaklaşımları ile şarj istasyonu yerleşimlerini daha doğru bir şekilde planlamak için yenilikçi bir yaklaşım sunmaktadır. Otonom araçların gelişimi göz önünde bulundurularak, bu araçların şarj ihtiyaçlarını karşılamak için akıllı ulaşım sistemine entegrasyonu konusunda da katkı sağlama potansiyeli bulunmaktadır.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %12

Kaynaklar

- [1] International Energy Agency (IEA), CO₂ emissions in 2022. <https://www.iea.org/data-and-statistics/charts/transport-sector-co2-emissions-by-mode-in-the-sustainable-development-scenario-2000-2030>, Accessed 23 May 2025.
- [2] S. S. Bilgilioğlu, Coğrafi bilgi sistemleri ve bulanık analitik hiyerarşi süreci ile elektrikli araç şarj istasyonu yer seçimi. Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi, 22(1), 2022. <https://doi.org/10.35414/akufemubid.1013244>.
- [3] D. Guler and T. Yomralioglu, Suitable location selection for the electric vehicle fast charging station with AHP and fuzzy AHP methods using GIS. Annals of GIS, 26(2), 169–189, 2020. <https://doi.org/10.1080/19475683.2020.1737226>.
- [4] Enerji Piyasası Düzenleme Kurumu (EPDK), Şarj hizmeti piyasası aylık istatistikleri - Mart 2025. <https://www.epdk.gov.tr/Detay/Icerik/3-0-222/enerji-donusumusarj-hizmeti-piyasasi--istatistik#>, Erişim tarihi 23 Mayıs 2025.
- [5] Enerji Piyasası Düzenleme Kurumu (EPDK), ELEKTRİKLİ araç ve şarj altyapısı projeksiyonu. <https://www.epdk.gov.tr/Detay/Icerik/4-14379/elektrikli-arac-ve-sarj-altyapisi-projeksiyonu->, Erişim tarihi 23 Mayıs 2025.
- [6] C. Bian, H. Li, F. Wallin, A. Avelin, L. Lin and Z. Yu, Finding the optimal location for public charging stations – a GIS-based MILP approach. Energy Procedia, 158, 6582–6588, 2019. <https://doi.org/10.1016/j.egypro.2019.01.071>.
- [7] M. H. Ghodusinejad, Y. Noorollahi and R. Zahedi, Optimal site selection, sizing of solar EV charge stations. Journal of Energy Storage, 56, 105904, 2022. <https://doi.org/10.1016/j.est.2022.105904>.
- [8] A. Karaşan, İ. Kaya and M. Erdoğan, Location selection of electric vehicles charging stations by using a fuzzy MCDM method: a case study in Turkey. Neural Computing and Applications, 32(9), 4553–4574, 2020. <https://doi.org/10.1007/s00521-018-3752-2>.

- [9] C. Karolemeas, S. Tsigdinos, P. G. Tzouras, A. Nikitas and E. Bakogiannis, Determining electric vehicle charging station location suitability: A qualitative study of greek stakeholders employing thematic analysis and analytical hierarchy process. *Sustainability*, 13(4), 2021. <https://doi.org/10.3390/su13042298>.
- [10] P. Keawthong, V. Muangsins and C. Gowanit, Location selection of charging stations for electric taxis: a Bangkok case. *Sustainability*, 14(17), 2022. <https://doi.org/10.3390/su141711033>.
- [11] Y. Wu, M. Yang, H. Zhang, K. Chen and Y. Wang, Optimal site selection of electric vehicle charging stations based on a cloud model, the PROMETHEE Method. *Energies*, 9(3), 2016. <https://doi.org/10.3390/en9030157>.
- [12] B. Csonka and C. Csiszár, Determination of charging infrastructure location for electric vehicles. *Transportation Research Procedia*, 27, 768–775, 2017. <https://doi.org/10.1016/j.trpro.2017.12.115>.
- [13] S. Micari, A. Polimeni, G. Napoli, L. Andaloro and V. Antonucci, Electric vehicle charging infrastructure planning in a road network. *Renewable, Sustainable Energy Reviews*, 80, 98–108, 2017. <https://doi.org/10.1016/j.rser.2017.05.022>.
- [14] M. Erbaş, M. Kabak, E. Özceylan and C. Çetinkaya, Optimal siting of electric vehicle charging stations: A GIS-based fuzzy Multi-Criteria Decision Analysis. *Energy*, 163, 1017–1031, 2018. <https://doi.org/10.1016/j.energy.2018.08.140>.
- [15] G. Napoli, A. Polimeni, S. Micari, L. Andaloro and V. Antonucci, Optimal allocation of electric vehicle charging stations in a highway network: Part 1. Methodology, test application. *Journal of Energy Storage*, 27, 101102, 2020. <https://doi.org/10.1016/j.est.2019.101102>.
- [16] C. B. Aybirdi, Elektrikli araç şarj istasyonu lokasyonlarının çok ölçütlü karar verme teknikleri ile seçilmesi: Ankara’da vaka çalışması. Yüksek Lisans Tezi, TOBB Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü, 2021.
- [17] M. A. Anwarzai and K. Nagasaka, Utility-scale implementable potential of wind and solar energies for Afghanistan using GIS multi-criteria decision analysis. *Renewable and Sustainable Energy Reviews*, 71, 150–160, 2017. <https://doi.org/10.1016/j.rser.2016.12.048>.
- [18] A. Ghosh, N. Ghorui, S. P. Mondal, S. Kumari, B. K. Mondal, A. Das, and M. S. Gupta, Application of hexagonal fuzzy MCDM methodology for site selection of electric vehicle charging station. *Mathematics*, 9(4), 2021, <https://doi.org/10.3390/math9040393>.
- [19] J. Raposo, A. Rodrigues, C. Silva and T. Dentinho, A multi-criteria decision aid methodology to design electric vehicles public charging networks. *AIP Advances*, 5(5), 057123, 2015, <https://doi.org/10.1063/1.4921087>.
- [20] B. Yagcitekin and M. Uzunoglu, A double-layer smart charging strategy of electric vehicles taking routing, charge scheduling into account. *Applied Energy*, 167, 407–419, 2016, <https://doi.org/10.1016/j.apenergy.2015.09.040>.
- [21] C. Csiszár, B. Csonka, D. Földes, E. Wirth and T. Lovas, Urban public charging station locating method for electric vehicles based on land use approach. *Journal of Transport Geography*, 74, 173–180, 2019, <https://doi.org/10.1016/j.jtrangeo.2018.11.016>.
- [22] G. Dong, J. Ma, R. Wei and J. Haycox, Electric vehicle charging point placement optimisation by exploiting spatial statistics and maximal coverage location models. *Transportation Research Part D: Transport and Environment*, 67, 77–88, 2019. <https://doi.org/10.1016/j.trd.2018.11.005>.
- [23] D. Guler and T. Yomralioglu, GIS and fuzzy AHP-based area selection for electric vehicle charging stations. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLII-4, pp. 249–252, 2018. <https://doi.org/10.5194/isprs-archives-XLII-4-249-2018>.
- [24] S. Guo and H. Zhao, Optimal site selection of electric vehicle charging station by using fuzzy TOPSIS based on sustainability perspective. *Applied Energy*, 158, 390–402, 2015. <https://doi.org/10.1016/j.apenergy.2015.08.082>.
- [25] Y. He, K. M. Kockelman and K. A. Perrine, Optimal locations of U.S. fast charging stations for long-distance trip completion by battery electric vehicles. *Journal of Cleaner Production*, 214, 452–461, 2019. <https://doi.org/10.1016/j.jclepro.2018.12.188>.
- [26] J. Liu, J. Peper, G. Lin, Y. Zhou, S. Awasthi, Y. Li and C. Rehtanz, A planning strategy considering multiple factors for electric vehicle charging stations along German motorways. *International Journal of Electrical Power & Energy Systems*, 124, 106379, 2021. <https://doi.org/10.1016/j.ijepes.2020.106379>.
- [27] A. Mazza, A. Russo, G. Chicco, A. Di Martino, C. G. Colombo, M. Longo, P. Ciliento, M. De Donno, F. Mapelli and F. Lamberti, Categorization of attributes and features for the location of electric vehicle charging stations. *Energies*, 17(16), 2024. <https://doi.org/10.3390/en17163920>.
- [28] P. Soczówka, M. Lasota, P. Franke and R. Żochowska, Method of determining new locations for electric vehicle charging stations using GIS tools. *Energies*, 17(18), 2024. <https://doi.org/10.3390/en17184546>.
- [29] I. Ullah, J. Zheng, A. Jamal, M. Zahid, M. Almoshageh and M. Safdar, Electric vehicles charging infrastructure planning: A review. *International Journal of Green Energy*, 21(7), 1710–1728, 2024. <https://doi.org/10.1080/15435075.2023.2259975>.
- [30] Y. Zhang, Q. Zhang, A. Farnoosh, S. Chen and Y. Li, GIS-based multi-objective particle swarm optimization of charging stations for electric vehicles. *Energy*, 169, 844–853, 2019. <https://doi.org/10.1016/j.energy.2018.12.062>.
- [31] K. H. Mhanna and H. A. Awad, An ideal location selection of electric vehicle charging stations: Employment of integrated analytical hierarchy process

- with geographical information system. Sustainable Cities and Society, 107, 105456, 2024. <https://doi.org/10.1016/j.scs.2024.105456>.
- [32] H. Iravani, A multicriteria GIS-based decision-making approach for locating electric vehicle charging stations. Transportation Engineering, 9, 100135, 2022. <https://doi.org/10.1016/j.treng.2022.100135>.
- [33] D. Guler and T. Yomralioglu, Suitable location selection for the electric vehicle fast charging station with AHP and fuzzy AHP methods using GIS. Annals of GIS, 26(2), 169–189, 2020. <https://doi.org/10.1080/19475683.2020.1737226>.
- [34] M. Mahdy, A. S. Bahaj, P. Turner, N. Wise, A. S. Alghamdi and H. Hamwi, Multi criteria decision analysis to optimise siting of electric vehicle charging points—Case study Winchester District, UK. Energies, 15(7), 2497, 2022. <https://doi.org/10.3390/en15072497>.
- [35] G. J. Carlton and S. Sultana, Electric vehicle charging station accessibility, land use clustering: A case study of the Chicago region. Journal of Urban Mobility, 2, 100019, 2022. <https://doi.org/10.1016/j.urbmob.2022.100019>.
- [36] S. Çelik and Ş. Ok, Electric vehicle charging stations: Model, algorithm, simulation, location, and capacity planning. Heliyon, 10(7), 2024. <https://doi.org/10.1016/j.heliyon.2024.e29153>.
- [37] P. Gauglitz, D. Geiger, J. Ulfers and E. Zauner, Modeling public charging infrastructure considering points of interest and parking potentials. Advances in Geosciences, 56, 1-12, 2021. <https://doi.org/10.5194/adgeo-56-1-2021>.
- [38] K. A. Momin, A. M. Sadri, K. K. Muraleetharan, R. Campos and P. S. Harvey, Application of multi-criteria decision analysis for optimal siting of electric vehicle charging stations in Oklahoma. Transportation Engineering, 20, 100325, 2025. <https://doi.org/10.1016/j.treng.2025.100325>.
- [39] J. Banegas and J. Mamkhezri, A systematic review of geographic information systems based methods and criteria used for electric vehicle charging station site selection. Environmental Science and Pollution Research, 30(26), 68054–68083, 2023. <https://doi.org/10.1007/s11356-023-27383-6>.
- [40] B. Hualing, Y. Gu, F. Lu and S. Mahreen, Site selection of electric vehicle charging station expansion based on GIS-FAHP-MABAC. Journal of Cleaner Production, 145557, 2025. <https://doi.org/10.1016/j.jclepro.2025.145557>.
- [41] Chargepoint, ChargePoint EV Data API. <https://www.chargepoint.com>, Accessed 21 February 2025.
- [42] U.S. Geological Survey (USGS), Shuttle Radar Topography Mission (SRTM) 1 Arc-Second Global. 2018. <https://doi.org/10.5066/F7PR7TFT>.
- [43] U. M. Durdağ, M. S. Şen ve Z. Usta, Analitik Hiyerarşi Yöntemi ile En Uygun Okul Yer Seçim Analizi: Elazığ Merkez Örneği. Türk Uzaktan Algılama ve CBS Dergisi, 6(1), 82–95, 2025. <https://doi.org/10.48123/rsgis.1603131>.
- [44] M. O. Mete ve T. Yomralioglu, CBS ile nominal taşınmaz değer haritası üretiminde çözünürlük araştırması. Türkiye Arazi Yönetimi Dergisi, 1(1), 16–23, 2019.
- [45] B. Taştan ve E. Z. Bozkan, Rüzgâr enerji santrallerinin kuruluş yeri seçiminde CBS, çok kriterli karar verme analizi ve bulanık mantık yönteminin kullanılması: Kastamonu ili örneği. Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 30(1), 172–190, 2025. <https://doi.org/10.53433/yyufbed.1563665>.
- [46] M. O. Mete and T. Yomralioglu, A hybrid approach for mass valuation of residential properties through geographic information systems and machine learning integration. Geographical Analysis, 55(4), 535–559, 2023. <https://doi.org/10.1111/gean.12350>.
- [47] F. Ocak ve M. Bahadır, Örnek taşkın risk modeli oluşturulması ve Ünye şehrindeki derelere ait taşkın risk analizleri. Journal of Academic Social Science Studies, 13(80), 2020.
- [48] N. Duman ve M. R. İrcan, Coğrafi bilgi sistemleri ve uzaktan algılama tabanında Çankırı Merkez ilçesinin erozyon risk analizi, Coğrafi Bilimler Dergisi, 20(1), 220–245, 2022. <https://doi.org/10.33688/aucbd.1074770>.
- [49] M. Özcanlı, A. Güzel ve B. Akgün, Şanlıurfa İli'nde kurulu GES'lerin topoğrafik özellikler (yükselti, eğim, bakı) açısından uygunluk analizi. Türk Coğrafya Dergisi, (78), 127–144, 2021. <https://doi.org/10.17211/tcd.997146>.
- [50] K. Tyagi, C. Rane, Harshvardhan, M. Manry, Regression Analysis. in Artificial Intelligence and Machine Learning for EDGE Computing, R. Pandey, S. K. Khatri, N. K. Singh, and P. Verma, Eds. Academic Press, pp. 53–63, 2022. <https://doi.org/10.1016/B978-0-12-824054-0.00007-1>.
- [51] J. H. Park, H. S. Jo, S. H. Lee, S. W. Oh and M. G. Na, A reliable intelligent diagnostic assistant for nuclear power plants using explainable artificial intelligence of GRU-AE, LightGBM and SHAP. Nuclear Engineering and Technology, 54(4), 1271–1287, 2022. <https://doi.org/10.1016/j.net.2021.10.024>.

