

Atf İçin: Aslan, E. (2024). Elektrikli Araçların Enerji Tüketimini Tahmin Etmede Makine Öğrenimi Algoritmalarının Performanslarının Karşılaştırılması. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 14(2), 518-530.

To Cite: Aslan, E. (2024). Comparing The Performance of Machine Learning Algorithms in Predicting Energy Consumption of Electric Vehicles. *Journal of the Institute of Science and Technology*, 14(2), 518-530.

Elektrikli Araçların Enerji Tüketimini Tahmin Etmede Makine Öğrenimi Algoritmalarının Performanslarının Karşılaştırılması

Emrah ASLAN

Öne Çıkanlar:

- Elektrikli araçlar
- Yakıt tüketimi

Anahtar Kelimeler:

- Elektrikli araçlar (EA)
- Enerji tüketimi
- Makine öğrenimi

ÖZET:

Ulaştırma sektörünün hızlı büyümesi ve buna bağlı emisyonlar, çevresel sürdürülebilirliğin sağlanması önem teşkil etmektedir. Bu nedenle, ulaştırma emisyonlarının türetilme faktörünün anlaşılması son derece önemlidir. Artan ulaşım emisyonları karşısında elektrikli araçların (EA) rolü kullanımının yaygınlaştırılması önemlidir. Elektrikli araçların başarılı bir şekilde yaygınlaştırılması, büyük ölçüde enerji tüketimini verimli ve güvenilir bir şekilde tahmin edebilen enerji tüketim modellerine dayanmaktadır. Elektrikli araçların enerji tüketim verimliliğinin artırılması, sürücü endişesinin hafifletilmesine önemli ölçüde yardımcı olacak ve şarj altyapısının işletilmesi, planlanması ve yönetimi için temel bir çerçeve sağlayacaktır. Elektrikli araçların enerji tüketimi tahminindeki zorlukların üstesinden gelmek için veriler Japonya'nın Aichi Eyaletinde toplanmıştır. Çalışmada, elektrikli araçların enerji tüketiminin tahmini için geleneksel makine öğrenimi modelleri, Multi Output, Gradient Boosting, XGBoost ve Random Forest kullanılmıştır. Tahmin modellerinin performansını değerlendirmek için belirleme katsayısı (R^2), kök ortalama kare hatası (RMSE) ve ortalama mutlak hata (MAE) değerlendirme ölçütleri kullanılmıştır. Tahmin sonuçları, Gradient Boosting ve Multi Output birleşimi ile oluşturulan regresyon modeli iyi performans gösterdiğini ortaya koymaktadır. Daha yüksek R^2 değerlerine, daha düşük MAE ve RMSE değerlerine sahip Gradient Boosting ve Multi Output tabanlı modellerin daha doğru olduğu kanıtlanmıştır. Farklı girdi değişkenlerinin elektrikli araçların enerji tüketimi tahmini üzerindeki etkisini ve göreceli etkisini göstermek için ayrıntılı bir önemli özellik analizi gerçekleştirilmiştir. Sonuçlar, gelişmiş bir makine öğrenmesi modelinin elektrikli araçların enerji tüketiminin tahmin performansını artırabileceğini göstermektedir.

Comparing The Performance of Machine Learning Algorithms in Predicting Energy Consumption of Electric Vehicles

Highlights:

- Electric vehicles
- Fuel consumption

Keywords:

- Electric vehicles (EVs)
- Energy consumption
- Machine learning

ABSTRACT:

In order to maintain environmental sustainability, it is crucial to address the transportation sector's explosive growth and the emissions that accompany it. Therefore, understanding the derivation factor of transportation emissions is of utmost importance. In the face of increasing transport emissions, it is important to expand the role of electric vehicles (EVs). An eco-friendly economy and low-carbon economy are made possible by electric automobiles. Energy consumption models that can accurately and consistently forecast energy use are critical to the successful deployment of electric vehicles. Enhancing EVs' energy efficiency will help reduce driver anxiety a great deal and offer a foundation for organizing, operating, and managing the infrastructure for charging. To overcome the challenges in estimating the energy consumption of electric vehicles, data was collected in Aichi Prefecture, Japan. In the study, traditional machine learning models, Multi Output, Gradient Boosting, XGBoost and Random Forest were used to predict the energy consumption of electric vehicles. The prediction models were assessed using the coefficient of determination (R^2), mean absolute error (MAE), and root mean square error (RMSE). The forecasting results reveal that the regression model with the combination of Gradient Boosting and Multi Output performs well. Gradient Boosting and Multi Output based models with higher R^2 values and lower MAE and RMSE values are proved to be more accurate To demonstrate the effect and relative influence of various input variables on the energy consumption forecast of electric vehicles, a thorough important feature analysis is carried out. The findings demonstrate that a sophisticated machine learning model can enhance the accuracy of electric car energy consumption predictions.

GİRİŞ

Ulaşım sektörü, küresel enerjinin önemli bir tüketicisi olarak hava kirliliğinde çok önemli bir rol oynamaktadır. Hali hazırda dünya enerjisinin %30'undan fazlasını tüketmekte ve küresel petrol talebinin %60'ını yönlendirmektedir. Karayolu taşıtları tek başına bu enerji tüketiminin yaklaşık %80'ini katkıda bulunmaktadır (Alves ve ark., 2016; Amin ve ark., 2020). Dünya çapında hükümetler, ulaşımdaki enerji tüketimi ve hava kalitesi sorunlarını ele almak için giderek daha fazla adım atmaktadır. Ulaşımdan kaynaklanan hava emisyonlarını azaltmak için, özellikle de düşük karbonlu bir ekonomiye geçiş için fosil yakıtlara bağımlılığı azaltarak çok yönlü bir yaklaşım gereklidir. Elektrikli araçlar (EA'lar), özellikle yenilenebilir enerji kaynaklarından güç aldıklarında karbondioksit emisyonlarını önemli ölçüde azaltma potansiyeline sahip daha temiz ulaşım sistemlerine giden bir yol sunmaktadır (Xu ve ark., 2020; Koubaa ve ark., 2020). Ülkeler yenilenebilir enerjiyi giderek daha fazla benimsedikçe, elektrikli araçların ekolojik faydaları daha belirgin hale gelmekte ve daha temiz ve sürdürülebilir enerji sistemlerine doğru önemli bir adım atılmaktadır (Vita ve Koumides, 2019). Ayrıca, yenilenebilir enerji kaynaklarının elektrikli araç teknolojisi ile entegrasyonu hem enerji üretiminden hem de ulaşımdan kaynaklanan karbon emisyonlarını azaltmak için bir fırsat sunmaktadır. Birçok ülke elektrikli araçların benimsenmesini teşvik etmek için iddialı hedefler belirlemiş, hatta bazıları benzinli araç satışlarını yasaklamayı düşünmüştür (Chen ve ark., 2023). Örneğin, Norveç 2025 yılına kadar elektrikli araçların yeni araç satışlarının %100'ünü temsil etmesini hedeflerken, Çin aynı yıla kadar yıllık 7 milyon adet elektrikli araç satışı hedeflemektedir. Ayrıca, Amerika Birleşik Devletleri, Fransa ve Birleşik Krallık 2040 yılına kadar benzinli araç satışlarını durdurma planlarını açıklamış olup, otomotiv sektörü 2030 yılına kadar elektrikli araçların pazara hâkim olmasını hedeflemektedir (Hertzke ve ark., 2018).

Bununla birlikte, elektrikli araçların çevresel faydalarına ve pazardaki hızlı büyümesine rağmen, bazı zorluklar yaygın olarak benimsenmelerini engellemektedir. Bunlar arasında sınırlı sürüş menzili, uzun şarj süreleri, yüksek batarya değiştirme maliyetleri ve yetersiz şarj altyapısından kaynaklanan "menzil kaygısı" yer almaktadır. Bu çalışma, özellikle şarj altyapısını genişleterek ve batarya performansını artırarak ele alınabilecek sınırlı elektrikli araç sürüş menzili sınırlamasına odaklanmaktadır. Ancak, her iki çözüm de yüksek maliyetler getirmekte ve sürücülerin kalan sürüş menzili tahminlerine ilişkin endişelerini tamamen gidermemektedir. Hali hazırda, elektrikli araç menzil tahmin edicileri gerçek dünya araç verilerine dayandıkları için hassasiyetten yoksundur. Bu da önemli tahmin hatalarına yol açmakta ve sürücü güvenini zedelemektedir. Menzil tahmininin doğruluğunun artırılması, enerji tüketim oranlarının ve kalan akü kapasitesinin doğru bir şekilde tahmin edilmesini de içerecek şekilde sürücü güveninin artırılması için çok önemlidir.

Elektrikli araçların enerji tüketimini tahmin etmeye yönelik birçok çalışma, çeşitli metodolojiler kullanarak bu tahminleri gerçekleştirmeye çalışmıştır. Ancak, bu modellerin çoğu, teorik olarak yorumlanabilir olmalarına rağmen, gerçek dünya senaryoları için geçerli olmayabilecek doğrusal varsayımlara ve hata dağılımı terimlerine dayalı sınırlamalardan muzdariptir. Bu sınırlamalar, potansiyel olarak önyargılı tahminlere yol açabilir. Ayrıca, doğrusal olmayan ve karmaşık problemlere uygulandıklarında etkinlikleri azalır. Son yıllarda, hesaplama ve yumuşak hesaplama tekniklerindeki gelişmeler, geleneksel istatistiksel modellerin kısıtlamalarının üstesinden gelmeyi amaçlayan parametrik olmayan yöntemlerin ortaya çıkmasını teşvik etmiştir. Bu parametrik olmayan aileye ait makine öğrenimi (MÖ) modelleri, özellikle büyük veri kümelerini ele alırken üstün uyum yeteneklerinden ve yinelemeli optimizasyon süreçlerinden yararlanarak gerçek dünyadaki doğrusal olmayan ve karmaşık sorunları ele almada etkinlik göstermiştir (Huges ve ark., 2019; Paçal, 2023).

Etkileyici tahmin performanslarına rağmen, makine öğrenimi modelleri opak bilgi işleme ve çıktılarda yorumlanabilirlik eksikliği nedeniyle eleştirilere maruz kalmıştır. Doğruluk arzu edilen bir durum olsa da tahmin değişkenlerinin göreceli önemini anlaşılması birçok uygulamada genellikle çok önemlidir. Önceki araştırmalar ağırlıklı olarak çoklu doğrusal regresyon, karar ağaçları, rastgele ormanlar ve destek vektör makineleri gibi geleneksel makine öğrenimi modellerine dayanmış ve elektrikli araç enerji tüketimini etkileyen iç ve dış faktörler arasındaki etkileşimi sınırlı bir şekilde incelemiştir. Bu araştırma boşluklarını ele alan mevcut çalışma, gelişmiş ve yorumlanabilir makine öğrenimi modelleri kullanarak elektrikli araç enerji tüketiminin tahminini geliştirmeyi amaçlamaktadır. Bu çalışmanın başlıca katkıları aşağıda özetlenmiştir:

Japonya'nın Aichi şehrindeki 38.362 elektrikli araçtan oluşan gerçek dünya verilerini kullanarak elektrikli araçların enerji tüketimini doğru bir şekilde tahmin etmek için sistematik bir makine öğrenimi yöntemi geliştirdik. Multi Output, Gradient Boosting, XGBoost, and Random Forest Regresyonları ile elektrikli araç enerji tüketimi modellenmiştir. Bu gelişmiş MÖ modellerinin tahmin performansını geleneksel MÖ Regresör modelleriyle karşılaştırılmıştır. MÖ tahmin modellerini uygulamadan önce, model doğruluğunu artırmak için veri temizleme, normleştirme ve standardizasyon dahil olmak üzere çeşitli istatistiksel testler gerçekleştirilmiştir. Modelleri belirleme katsayısı (R^2), Ortalama Hatanın Karekökü (RMSE) ve ortalama mutlak hata (MAE) gibi çeşitli istatistiksel ölçütler kullanarak değerlendirilmiştir. Modelleme yaklaşımımız yolculuk hızı, mesafe, ısıtıcı ve klima kullanımı, ortam sıcaklığı ve yol eğimi dahil olmak üzere hem iç hem de dış etki değişkenlerini dikkate almaktadır.

Çalışma şu şekilde yapılandırılmıştır: Bölüm 2'de ilgili literatür gözden geçirilmektedir. Bölüm 3, veri toplama, ön işleme ve MÖ model geliştirmeyi kapsayan EA enerji tüketimini tahmin etmek için önerilen metodolojiler detaylandırmaktadır. Bölüm 4'te bulgular ve tartışma sunulmaktadır. Son olarak, Bölüm 5, temel bilgileri özetleyerek ve gelecekteki araştırmalar için yolları özetleyerek makaleyi sonuçlandırmaktadır.

İlgili Çalışmalar

Literatürde, elektrikli araçların enerji tüketimi için analitik modeller kullanan çeşitli çalışmalar bulunmaktadır. Analitik yöntem, araç boylamsal dinamiklerine ve mevcut enerji verimli haritalardan elektrik motoru kayıplarının tahminine dayalı olarak çalışmaktadır (Hong ve ark., 2016). Araç dinamiği teorisinden hareketle, boylamsal araç dinamiği, karşıt kuvvetlerin üstesinden gelmek için tekerleklerin ihtiyaç duyduğu gücü ölçmek üzere modellenmiştir (Paçal, 2024). Önceki birkaç çalışmada, rejenerasyon mekanizması yokuş aşağı sürüş veya frenleme sırasında geri kazanılan enerjiyi ölçmek için araç hızının doğrusal fonksiyonları olarak modellenmiştir veya yavaşlama oranının bir fonksiyonu olarak tanımlanabilir.

İstatistiksel modeller, elektrikli araçların enerji tüketiminin tahmininde yaygın olarak kullanılır ve gerçek dünya sürüş verilerini kullanarak elektrikli aracın enerji tüketimi ile diğer faktörler arasındaki ampirik ilişkileri araştırır. Bu modeller hem güç aktarma organlarının verimliliğini hem de elektrikli aracın dinamik davranışını hesaba katmak için geliştirilmiştir (De Cauwer ve ark. 2015). Lopez ve Fernandez, bataryalı elektrikli araç enerji tüketimi için bir MÖ modeli kullanmıştır (Lopez ve Fernandez, 2020). Model tahmin doğruluğu ve elde edilen sonuçlar bir vaka çalışması geliştirilerek gösterilmiştir. Bu çalışmada gerçek dünya elektrikli araç enerji tüketim verileri kullanılmamıştır. Liu ve arkadaşları, yol eğiminin elektrikli araçların enerji tüketimi üzerindeki etkisini araştırmak için doğrusal bir regresyon modeli uygulamıştır (Lui ve ark., 2017). Elde ettikleri sonuçlar, yol eğimlerinin enerji tüketimi üzerinde önemli bir etkisi olduğunu göstermiştir. Ancak, doğru modellemeye katkıda bulunabilecek ortam sıcaklığını kullanmamışlardır. Wang ve arkadaşları, elektrikli araçların enerji tüketiminin tahminini

geliştirmek için geleneksel bir doğrusal regresyon ve çok düzeyli karışık etkili doğrusal regresyon yöntemi önermiştir (Wang ve ark., 2017). Çalışmalarının bulguları, önerilen modelin elektrikli araçların enerji tüketimini tahmin etmede kullanılma potansiyeline sahip olduğunu ortaya koymaktadır. Liu ve arkadaşları, elektrikli araçların enerji tüketimi üzerindeki etki faktörlerini tahmin etmek için çok düzeyli karışık etkili bir doğrusal regresyon modeli kullanmıştır (Liu ve ark., 2016). Elde ettikleri sonuçlar, enerji tüketiminin yardımcı yükten etkilendiğini ortaya koymuştur. Yukarıda bahsedilen çalışmalarda elektrikli araçların enerji tüketimi tahmini için istatistiksel yöntemler kullanılmıştır. Büyük hacimli veriler dağınık olabileceğinden, istatistiksel model genellikle iyi performans gösteremez. Öte yandan, makine öğrenimi algoritmaları tahmin doğruluğunu artırmakta ve gerçek veriler ile tahmin edilen veriler arasındaki hatayı azaltmaktadır. Önceki araştırmalar MÖ algoritmalarının istatistiksel yaklaşımlardan önemli ölçüde daha iyi performans gösterdiğine tanık olmuştur. Çünkü makine öğrenimi algoritmaları değişkenler arasındaki doğrusal olmayan ilişkiyi kontrol edebilir ve birçok alanda mükemmel kalibreli tahmin yapmalarını sağlayan daha az model varsayımına sahiptir.

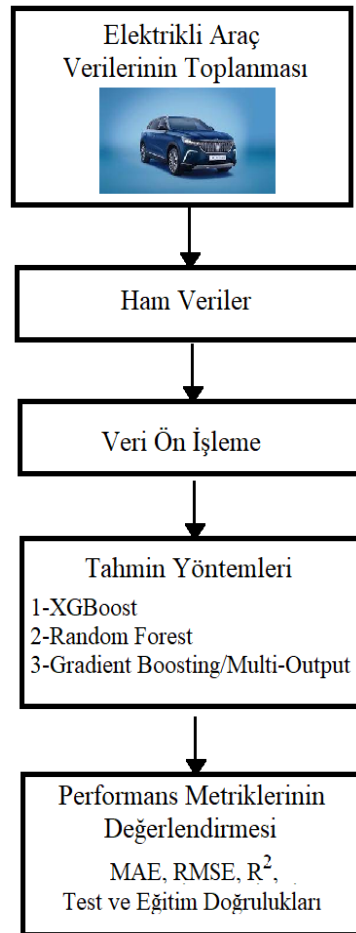
Son zamanlarda, elektrikli araçların enerji tüketimi tahmini için makine öğrenimi tabanlı yaklaşımlar uygulanmaktadır. MÖ'ne dayalı hesaplama modelleri, elektrikli aracın enerji tüketimini etkileyen çeşitli faktörler arasındaki ilişkileri incelemeyi amaçlamaktadır. MÖ modeli, eğitim algoritması tarafından göreceli önemine bağlı olarak her faktör için ağırlığın hesaplandığı girdi değişkenlerinin bir fonksiyonu olarak elektrikli aracın enerji tüketimini tahmin etmek için kullanılabilir. Alvarez ve arkadaşları, elektrikli araçların sürüş davranışını ve enerji tüketimini tahmin etmek için yapay sinir ağı (YSA) modelini kullanmıştır. Araç hızı, hızlanma ve sarsıntı olmak üzere üç girdi değişkeni kullanılmıştır. Ancak, sadece 10 sürücünün verilerini test etmişlerdir ki bu da örneklem özelliklerini yeterince temsil etmemektedir. Bi ve ark. araca özgü beş iç faktör kullanarak elektrikli araçların artık menzil tahmini için bir sinir ağı önermiştir (Bi ve ark., 2018). Elde ettikleri sonuçlar, önerilen modelin iyi bir tahmin doğruluğuna sahip olduğunu ortaya koymuştur. Ancak, iç etki faktörlerini göz ardı etmişlerdir. Bolvinou ve arkadaşları, elektrikli aracın sürüş menzili ve enerji tüketimini tahmin etmek için çeşitli MÖ modellerini araştırmıştır (Bolvinou ve ark., 2014). Bulguları, regresyon modeli yükseklik olmadan ve yükseklikle eğitilmiş bir model üzerinde test edildiğinde, sırasıyla 1,64 km ve 1,95 km MAE elde edildiğini göstermiştir. Modi ve arkadaşları, sürücü menzil kaygısını azaltmak amacıyla elektrikli aracın enerji tüketimini tahmin etmek için bir konvolüsyonel sinir ağı önermiştir (Modi ve ark., 2020). Önerilen teknik, mevcut diğer beş modelle karşılaştırılmıştır. Elde ettikleri sonuç, önerilen tekniğin daha iyi performans gösterdiğini ortaya koymuştur. Bununla birlikte, yazar sadece üç parametre kullanmış ve sıcaklık ile yardımcı yükü göz ardı etmiştir. Felipe ve arkadaşları, aynı YSA modelini kullanarak giriş değişkenleri rota bilgilerini ekleyerek çalışmayı genişletmiştir (Felipe ve ark., 2015). Sonuç olarak, bu modeller sürücüyü akünün kalan enerjisi hakkında yönlendirmek için gerçek zamanlı olarak kullanılamaz. Li ve arkadaşları, elektrikli otobüs enerji tüketimini tahmin etmek için KNN ve RF modellerini kullanmıştır (Li ve ark., 2021). Elde ettikleri sonuçlar, önerilen RF modelinin mevcut modellere kıyasla doğru model tahminine sahip olduğunu göstermiştir. Abdelaty ve arkadaşları, transit elektrikli otobüs enerji tüketimini tahmin etmek için yedi geleneksel MÖ modeli önermiştir (Abdelaty ve ark., 2021). Bulgular, MÖ ve SVR'nin diğer modellerden daha iyi performans gösterdiğini ortaya koymaktadır. Bununla birlikte, özellikle sürüş menzili üzerinde önemli bir etkiye sahip olan yol eğimini göz ardı etmişlerdir. Bu çalışmalarda az sayıda harici ve dahili özel değişken ve küçük veri seti kullanılmıştır. Bununla birlikte, uygulanan MÖ modellerinin nispeten geleneksel olduğu ve zaman içinde giderek geliştiği görülmektedir. Bu nedenle, gelişmiş MÖ modelleri, daha iyi tahmin doğruluğu

için tahmin hatasını en aza indirmek amacıyla elektrikli araçların enerji tüketimi tahmininde kullanılabilir.

MATERYAL VE METOT

Elektrikli Araçların Enerji Tüketimi Tahmini İçin Önerilen Metodoloji

Bu çalışmanın temel amacı, elektrikli araçların enerji tüketiminin daha iyi tahmin doğruluğu için bir tahmin modeli geliştirmektir. Bu çalışmada, elektrikli araçların enerji tüketimini tahmin etmek için hem istatistiksel hem de makine öğrenimi modellemesine dayalı bir yöntem sunulmaktadır. Modelin geçerliliğini ve rasyonelliğini sağlamak için, regresyon analizine dayanan yerleşik tahmin modeli, bir dizi istatistiksel test (veri temizleme, normalleştirme ve standardizasyon) kullanılmıştır. Önerilen yöntemi; veri toplama ve değişken tanımlama, ön işleme, MÖ algoritması ve tahmin modelinin değerlendirilmesi olmak üzere dört ana aşamaya ayrılmıştır. Veri toplama aşamasında, araştırma çalışmasında kullanılan kapsamlı verileri ele alınmıştır. Ön işleme aşamasında, veri gürültüsü, aykırı değerlerin temizlenmesi, normalleştirme ve standardizasyon gerçekleştirilmiştir. Tahmin aşamasında, farklı MÖ algoritmaları kullanılmıştır. Performans değerlendirmesinde, tahmin algoritmalarının performansını ölçmek için MAE, RMSE ve R² performans ölçütleri kullanılmıştır. Şekil 1 önerilen yöntemin yapısını göstermektedir.



Şekil 1. Önerilen EA enerji tüketimi tahmin işlem yapısı

Uygulamada kullanılan veri setine Kaggle üzerinden açık erişimli olarak <https://www.kaggle.com/datasets/ahmedramadanmephi/battery-electric-vehicles/data> url adresinden erişim sağlanmaktadır. Çizelge 1, EA'ların enerji tüketimi veri setini göstermektedir.

Çizelge 1. EA'ların enerji tüketimi veri-seti

DEĞER	AÇIKLAMA
Transmission	Otomatik şanzıman 1-10 vites sayısı
Fuel Type	Yakıt tipi elektrik
C_City	Şehir içi sürüş yakıt tüketimi
C_Hwy	Otoban sürüş yakıt tüketimi
C_Com	Karma yakıt tüketimi
CO2 Emission	Karma şehir içi ve otoyol sürüşü için karbondioksit egzoz emisyonları (kilometre başına gram cinsinden).
CO2 Rating	Karbondioksit egzoz emisyon derecelendirmesi. 1'den (en kötü) 10'a (en iyi) kadar.
Smog rating	Duman oluşturan kirleticilerin egzoz borusu emisyon derecelendirilmesi. 1'den (en kötü) 10'a (en iyi) kadar.
Range	Tam şarjlı bir batarya ile tahmini sürüş mesafesi (kilometre cinsinden)
Recharge time	Aküyü tamamen şarj etmek için tahmini süre (saat olarak)
Make	Araç firması
Model	Aracın modeli
Model_Year	Aracın üretim yılı
Motor	Araç motorunun gücü (kW)

Veri Ön İşleme

Veri ön işleme, MÖ algoritmalarından önce verileri yönetmek için önemli bir adımdır. Modelin öngörü performansını artırmak için, veri hazırlama işlemi her model geliştirilmeden önce gerçekleştirilmiştir. İşlem, veri gürültüsü, aykırı değer temizliği, normalleştirme ve standartlaştırma gibi birkaç aşamadan oluşur. Veri hazırlığında, ilk adım elde edilen veri setinden aykırı değerlerin çıkarılmasıdır. Aykırı değerler nedeniyle veri setinde belirsizlik ve hata olabilir, bu da doğrusal regresyon yaklaşımının etkinliğini azaltabilir. İlgili değişkenler seçildikten sonra, ön işleme, aykırı değerlerin kaldırılması ve veri setinin normalleştirilmesi de dahil olmak üzere önemlidir. Bu çalışmada, veri normalleştirme işlemi gerçekleştirilmiş ve veri setinin aykırı değerleri elemine edilmiştir. Aykırı değerlerin kaldırılması için kutu grafikleri gibi uygun bir grafik tekniği seçilmiştir.

EA'lerin Enerji Tüketimini Tahmin Etmek İçin MÖ Algoritması

EA'lerin enerji tüketimini tahmin etmek için birkaç MÖ algoritması kullanılmıştır. Veri seti iki aşamaya ayrılmıştır (eğitim ve test setleri). Bu aşama, önerilen MÖ algoritmasının etkinliğini kontrol etmek için önemlidir. Veri setlerinin eğitim kısmı kullanılarak, önerilen algoritmalar eğitilir ve ardından ikinci kısım test amaçları için kullanılır. Bu, kurulan modelin yeni verilere ilk kez işlenmiş yanıtını göstermek açısından önemlidir. Bu çalışmada, veri seti %80 eğitim ve %20 test için bölünmüştür. Sonraki bölüm, bireysel model özelliklerini ve uygulama sürecini açıklar.

Multi output regressor

Multi Output Regressor, çoklu çıkışlı regresyon problemleri için kullanılan bir yöntemdir. Bu yöntem, her bir çıkışı tek başına ele alan bir dizi regresyon modelini bir araya getirerek çoklu hedefli problemleri çözmeyi amaçlar. Bu regressor scikit-learn kütüphanesinde yer alır ve çoklu hedeflerin bir arada ele alınması sağlar. Multi Output Regressor kullanımında, bir temel regresyon algoritması belirlenir (örneğin, Lineer Regresyon). Ardından, her çıkış için ayrı bir regresyon modeli oluşturulur. Bu modeller, belirtilen temel regresyon algoritması kullanılarak eğitilir. Sonuç olarak, bu yöntem, çoklu hedefli regresyon problemlerinde kullanılan çeşitli modelleri bir araya getirerek genel bir tahmin yapma yeteneği sunar. Bu, özellikle birçok bağımlı değişkenin bulunduğu karmaşık regresyon problemleri için kullanışlı bir tekniktir.

XGBoost

Son zamanlarda makine öğrenimi yarışmalarında ve endüstriyel uygulamalarda büyük başarı elde etmiş bir öğrenme algoritmasıdır. Gradient Boosting yöntemlerine dayanır, ancak özellikle

ölçeklenebilirlik, hız ve doğruluk açısından geliştirilmiştir. XGBoost'un temel çalışma prensibi, birçok zayıf tahmin ediciyi (genellikle karar ağaçları) bir araya getirerek güçlü bir tahminci oluşturmaktır. Model, önceki tahminlerin hatalarını düzeltmeye odaklanarak ardışık olarak bu tahmin edicileri eğitir. Bu, bir sonraki tahmin ediciyi eğitmek için kullanılan veri setindeki hataları minimize etmek için bir gradyan inişi yaklaşımıdır. XGBoost'un bazı önemli özellikleri şunlardır:

Ölçeklenebilirlik: Büyük veri setleriyle başa çıkabilir ve çoklu işlemcileri veya dağıtılmış sistemleri kullanarak hızlı bir şekilde eğitim yapabilir.

Hız: Optimizasyonları sayesinde diğer gradient boosting kütüphanelerine göre daha hızlıdır.

Regülerizasyon: Aşırı öğrenmeyi önlemek için çeşitli regülerizasyon tekniklerini destekler.

Esneklik: Sınıflandırma, regresyon, sıralama ve diğer birçok problem türünü destekler.

XGBoost, birçok endüstriyel uygulamada ve yarışmalarda liderlik eden modellerin geliştirilmesinde sıkça kullanılmaktadır.

Random forest

Karar ağaçları üzerine kurulu bir topluluk öğrenme algoritmasıdır. Temelinde birden çok karar ağacının bir araya getirilmesiyle oluşan bir topluluk yöntemidir. Random Forest, her bir ağacı farklı bir şekilde eğitir ve ardından tahminlerini bir araya getirerek daha güçlü ve dengeli bir tahminci oluşturur. Random Forest'in ana özellikleri şunlardır:

- **Rastgele Örneklem (Bootstrap):** Her bir karar ağacı, rastgele olarak veri setinden örneklem alır. Bu, her bir ağacın farklı bir alt küme üzerinde eğitilmesini sağlar.

- **Rastgele Özellik Seçimi:** Her bir karar ağacı, her düğümde özelliklerin bir alt kümesini kullanarak eğitilir. Bu, her ağacın farklı özellikler üzerinde eğitilmesini sağlar.

- **Ağaçların Birleştirilmesi:** Her bir karar ağacı eğitildikten sonra, tahminler bir araya getirilir. Sınıflandırma durumunda, sınıfların çoğunluğu alınırken, regresyon durumunda ortalama değer alınır.

- **İyi Performans:** Genellikle diğer sınıflandırma ve regresyon algoritmalarından daha iyi performans gösterir.

- **Aşırı Öğrenmeyi Önleme:** Birden çok ağacın birleştirilmesi, aşırı uyum riskini azaltır.

- **Dengeli Sonuçlar:** Çeşitli veri setleri ve özellikler üzerinde iyi bir performans gösterir.

Random Forest, sınıflandırma, regresyon ve özellik seçimi gibi birçok makine öğrenimi probleminde başarıyla kullanılmaktadır.

Gradient boosting regressor

Gradient Boosting, ensemble learning adı verilen bir yöntemi temsil eder. Bu yöntem, bir dizi zayıf öğreniciyi (genellikle karar ağaçları) birleştirerek, karmaşık ve güçlü bir öğrenici elde etmeyi amaçlar. Gradient Boosting Regressor, özellikle regresyon problemleri için kullanılan bir uygulamadır. İlk aşamada, algoritma, veri setindeki değerlerin ortalamasını tahmin eden bir başlangıç modeli oluşturur. Daha sonra, her aşamada önceki modelin hatalarını düzeltmeye odaklanan yeni bir model eklenir.

Bu algoritmanın temelinde, gradyan iniş (gradient descent) kullanılarak bir kayıp fonksiyonu minimize edilir. Her model eklenirken, hedef, mevcut modelin tahminlerinden oluşan bir artık (hata) vektörüdür. Sonraki model, bu artığı minimize etmeye çalışarak güçlü bir tahmin yapmaya çalışır. Bu süreç, belirlenen bir iterasyon sayısına veya belirli bir hata eşliğine ulaşıncaya kadar devam eder. Sonunda, tüm modellerin tahminleri ağırlıklı olarak birleştirilerek nihai regresyon tahmini elde edilir. Gradient Boosting Regressor, esnekliği, dayanıklılığı ve yüksek performansı nedeniyle birçok regresyon probleminde tercih edilen bir yöntemdir.

Tahmin Doğruluğu Ölçümü

Tahmin modelinin uygunluğunu değerlendirmek için performans metriği kullanıldı. Başlangıç model varsayımlarının doğrulanmasından ve değerlendirilmesinden sonra, regresyon modelinin etkinliği ve tahmin yeteneğinin analiz edilmesi önemlidir. Tahmin modelinin etkinliğini nicel olarak karşılaştırmak için üç istatistiksel matris kullanıldı: R^2 , MAE ve RMSE. Matematiksel denklemler aşağıda yazılmıştır (Ullah ve ark., 2022).

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_{i,m} - Y_{i,e})^2}{\sum_{i=1}^n (Y_{i,m} - \bar{Y}_{i,m})^2} \quad (1)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_{i,m} - Y_{i,e}| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_{i,m} - Y_{i,e})^2} \quad (3)$$

Burada $Y_{i,m}$ ölçülen EA'ların enerji tüketimini, $Y_{i,e}$ tahmini EA'ların enerji tüketimini, $\bar{Y}_{i,m}$ ortalama ölçülen EA'ların enerji tüketimini ve n gözlemlerin sayısını temsil eder. Düşük MAE ve RMSE değeri, daha iyi model etkinliğini tercih ederken, tersine, daha yüksek bir R^2 değeri (1'e daha yakın) regresyon çizgisinin verilere iyi uydurulduğunu ve modelin daha iyi performans gösterdiğini gösterir.

BULGULAR VE TARTIŞMA


MÖ Algoritma Değerlendirmesi

EA'ların enerji tüketimini tahmin etmek için dört MÖ algoritması kullanıldı. Bunlar; Multi Output, Gradient Boosting, XGBoost ve Random Forest regresörleridir. Veri seti eğitim ve test setleri olarak iki gruba ayrıldı ve tüm modeller aynı veri setine dayanarak geliştirildi. Bu çalışmada, veri seti %80 eğitim ve %20 test için ayrıldı. Farklı algoritmalar için parametre seçimleri belirlendi. Her MÖ algoritması bazı parametre ayarlarına sahiptir. Her yöntem için en uygun parametreleri belirlemek için bir çapraz doğrulama testi kullanılır. Sonuç olarak, her yöntem için en iyi performansa katkıda bulunan en uygun parametreler belirlenir.


Çalışmada farklı yıllara ve modellere ait EA yakıt tüketimi bilgisi bulunmaktadır. Veri seti içerisinde yer alan şehir içi tüketim (C_City) ve Şehirlerarası (C_Hwy) değerlerine ait histogram ve kutu grafikleri Şekil 2'de verilmiştir.

Çizelge 2'de XGBoost Regressora ait hiperparametreler verilmiştir. Eğitimler sonucunda elektrikli araçların yakıt tüketimi tahmin etmede XGBoost Regressor algoritması %99.94 eğitim başarımları ve %93.17 test başarımları elde etmiştir. Kök Ortalama Kare Hatası (RMSE) 0.80, Ortalama Mutlak Hata (MAE) 0.63, R^2 Score 93.17 olarak hesaplanmıştır. C_City için RMSE 0.86 ve C_Hwy için 0.74 olduğu görülmüştür. XGBoost Regressor algoritması ile C_City ve C_Hwy tahmin edilen EA yakıt tüketimi ve gerçek yakıt tüketimi değerlerinin tahminini gösteren grafik Şekil 3'de verilmiştir.


Çizelge 3'de Random Forest Regressora ait hiperparametreler verilmiştir. Eğitimler sonucunda elektrikli araçların yakıt tüketimi tahmin etmede Random Forest Regressor algoritması %98.20 eğitim başarımları ve %91.84 test başarımları elde etmiştir. Kök Ortalama Kare Hatası (RMSE) 0.89, Ortalama Mutlak Hata (MAE) 0.50, R^2 Score 91.84 olarak hesaplanmıştır.




a)C_City histogram grafiği



b) C_City kutu grafiği



a)C_Hwy histogram grafiği



b) C_Hwy kutu grafiği

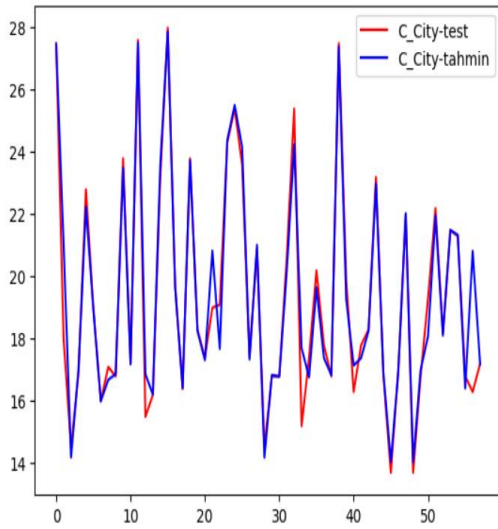
Şekil 2. Eğitim setinde bulunan C_City ve C_Hwy parametrelerinin histogram ve kutu grafikleri

Çizelge 2. XGBoost Regressor Parametreleri


Parametreler	Değerler
booster	gbtree
verbosity	1
eta	0.3
learning_rate	0.99
max_dept	6
n_estimators	50

Çizelge 3. Random Forest Regressor Parametreleri

Parametre	Değer
n_estimators	1000
criterion	log_loss
max_depth	6
max_iter	10
random_state	10




a) C_City yakıt tüketim tahmini




b) C_Hwy yakıt tüketim tahmini

Şekil 3. XGBoost Regressor ile doğru yakıt tüketimi ve tahmin edilen değerlerin karşılaştırılması

C_City için RMSE 0.88 ve C_Hwy için 0.90 olduğu görülmüştür. Random Forest Regressor algoritması ile C_City ve C_Hwy tahmin edilen EA yakıt tüketimi ve gerçek yakıt tüketimi değerlerinin tahminini gösteren grafik Şekil 4'de verilmiştir.



a) C_City yakıt tüketim tahmini



b) C_Hwy yakıt tüketim tahmini

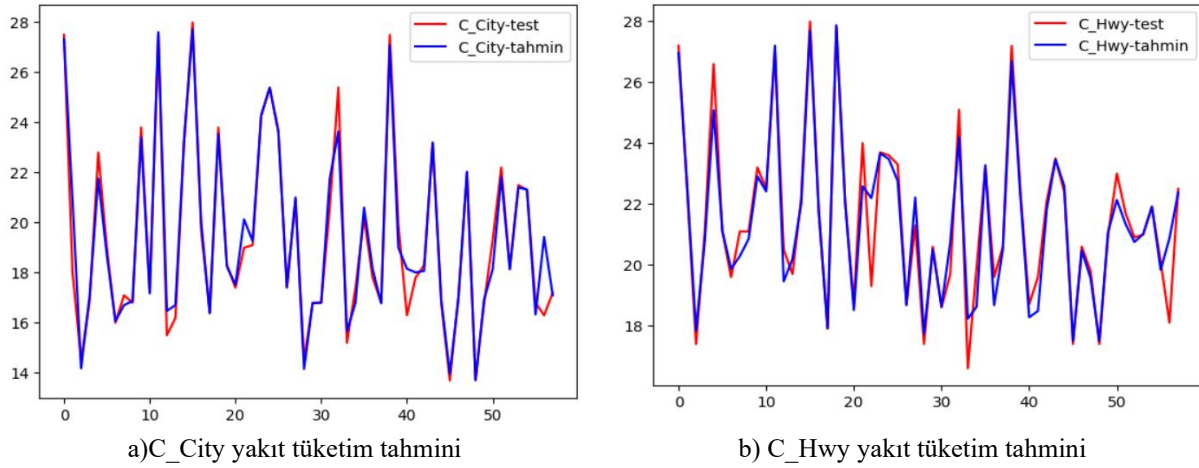
Şekil 4. Random Forest Regressor ile doğru yakıt tüketimi ve tahmin edilen değerlerin karşılaştırılması

Çizelge 4. Gradient Boosting Regressor Parametreleri

Parametre	Değer
n_estimators	1000
loss	huber
criterion	squared_error
max_depth	6
random_state	10

Çizelge 4'de Gradient Boosting Regressora ait hiperparametreler verilmiştir. Gradient Boosting Regressora ait ayarlamalar yapıldıktan sonra Multi Output Regressor içerisinde çalıştırılarak sonuçlar elde edilmiştir. Eğitimler sonucunda elektrikli araçların yakıt tüketimi tahmin etmede Gradient Boosting ve Multi Output Regressor algoritması %99.99 eğitim başarımı ve %95.86 test başarımı elde etmiştir. Kök Ortalama Kare Hatası (RMSE) 0.59, Ortalama Mutlak Hata (MAE) 0.44, R² Score 95.86 olarak

hesaplanmıştır. C_City için RMSE 0.59 ve C_Hwy için 0.59 olduğu görülmüştür. Gradient Boosting ve Multi Output Regressor algoritması ile C_City ve C_Hwy tahmin edilen EA yakıt tüketimi ve gerçek yakıt tüketimi değerlerinin tahminini gösteren grafik Şekil 5'de verilmiştir.



Şekil 5. Gradient Boosting ve Multi Output Regressor ile doğru yakıt tüketimi ve tahmin edilen değerlerin karşılaştırılması

MÖ Algoritmasının Karşılaştırmalı Performansı

Bu çalışmanın amacı, EA'ların enerji tüketimini tahmin etmek için en son MÖ algoritmalarının etkililiğini karşılaştırmaktır. Eğitim doğruluğu, test doğruluğu, R^2 , Ortalama Mutlak Hata (Mean Absolute Error - MAE) ve Ortalama Karesel Hata Kökü (Root Mean Squared Error - RMSE), metrikleri üzerinden karşılaştırmalar gerçekleştirilmiştir. Farklı modeller için EA'ların enerji tüketimi tahminleri Çizelge 5'te gösterilmiştir. Tablo 5'de görüldüğü gibi, tüm modeller yakıt tüketimini iyi sonuçlar ile tahmin etmektedir.

Çizelge 5. Tüm modellerin sonuçlarının karşılaştırılması

Regresyon Modelleri	Performans değerlendirme metrikleri				
	Eğitim Doğruluğu	Test Doğruluğu	MAE	RMSE	R^2
XGBoost	99.94	93.17	0.80	0.63	93.17
Random Forest	98.20	91.84	0.50	0.89	91.84
Gradient Boosting ve Multi Output	99.99	95.86	0.44	0.59	95.86

Verilen çizelgede, üç regresyon modeli XGBoost, Random Forest ve Gradient Boosting/Multi Output Regressor elektrikli araçlarda yakıt tüketimini tahmin etmek için performans metriklerine göre değerlendirilmiştir. Eğitim ve test doğruluk yüzdeleri, her modelin verileri ne kadar iyi tahmin ettiğini gösterir. Çizelge 5'de görüldüğü gibi XGBoost %99,94 ile en yüksek eğitim doğruluğunu göstererek eğitim verilerine neredeyse mükemmel bir şekilde tahmin etmiştir. Ancak %93,17'lik test doğruluğunda görüldüğü gibi üstün bir genelleme anlamına gelmemekte ve belirli bir düzeyde aşırı uyuma işaret etmektedir. XGBoost için Ortalama Mutlak Hata ve Ortalama Karesel Hata Kökü sırasıyla 0,80 ve 0,63'tür. Bu değerler modelin tahminlerdeki hataların ortalama büyüklüğünü yansıtır. R^2 skorunun %93,17 olması da modelin hedef değişkendeki varyansı açıklama kabiliyetinin altını çizmektedir.

Öte yandan Random Forest, %98,20 ile biraz daha düşük bir eğitim doğruluğu sergileyerek XGBoost'a kıyasla eğitim verilerine marjinal olarak daha az karmaşık bir uyum göstermektedir. Test doğruluğu %91,84'tür. Random Forest, XGBoost'a kıyasla daha düşük bir MAE 0,50'ye sahiptir. Ancak daha yüksek bir RMSE 0,89 değerini göstermektedir. Bu da hassasiyet ve doğruluk arasında potansiyel bir değiş tokuşa işaret eder. Random Forest için R^2 skoru %91,84'tür ve bu da modelin güçlü bir açıklayıcı gücü olduğunu göstermektedir. Son olarak, Gradient Boosting/Multi Output Regressor

%99,99 ile en yüksek eğitim doğruluğuna ulaşarak eğitim verilerindeki karmaşık örüntüleri yakalama yeteneğini vurgulamaktadır. En düşük MAE 0,44 ve RMSE 0,59 ile birlikte %95,86 test doğruluğu ile üç model arasında en iyi genellemeyi göstermektedir. R^2 skoru %95,86'dır ve elektrikli araçlar için yakıt tüketimi tahminindeki varyansı açıklamada sağlam bir performansa işaret etmektedir. Genel olarak, seçilen regresyon modelleri kabul edilebilir tahminlerde bulunmuştur. Sonuç olarak, gelişmiş MÖ modellerinin daha iyi tahmin doğruluğuna sahip olduğunu ve Gradient Boosting/Multi Output Regressor EA'ların enerji tüketimi tahmininde daha etkili olduğunu göstermektedir.

SONUÇ

Bu çalışma, elektrikli araçların yakıt tüketimini tahmin etmek için makine öğrenimi algoritmalarının uygulanmasına yöneliktir. Elektrikli araçlar için yakıt tüketiminin tahmin edilmesi bağlamında, makine öğrenimi yöntemlerinin uygulanması üç önde gelen regresyon modeli kullanılarak araştırılmıştır: XGBoost, Random Forest ve Gradient Boosting/Multi-Output. Bu modeller çeşitli performans ölçütlerine göre değerlendirilerek güçlü ve zayıf yönleri gösterilmiştir. %99,99'lük etkileyici bir eğitim doğruluğuna sahip olan XGBoost, %93,17'lik daha düşük bir test doğruluğu ile kanıtlandığı üzere potansiyel aşırı uyum konusunda endişelere yol açmaktadır. Orta düzeyde MAE ve RMSE değerleriyle makul bir hassasiyet göstermesine rağmen, yeni verilere zayıf genelleme riski nedeniyle dikkatli olunması gerekmektedir. %98,20'lik biraz daha düşük bir eğitim doğruluğu ile karakterize edilen Random Forest, hassasiyet ve doğruluk arasında bir denge kurmaktadır. Model, %91,84'lük bir test doğruluğu sergilemekte ve %91,84'lük R^2 puanına yansıyan güçlü bir açıklama gücünü korumaktadır. Random Forest, daha düşük MAE ile hassasiyet ve daha yüksek RMSE ile doğruluk arasında bir denge bulundurmaktadır. Değerlendirilen modeller arasında en iyi performansı Gradient Boosting/Multi-Output Regressor göstermektedir. %99,99'lük en yüksek eğitim doğruluğu ile %95,86'lık bir test doğruluğu elde ederek genelleme konusunda üstünlük sağlamıştır. Model, en düşük MAE ve RMSE değerlerinin gösterdiği gibi üstün bir hassasiyet sergilemektedir. Makine öğrenimi yöntemlerinin, özellikle de Gradient Boosting/Multi-Output Regressor yönteminin, elektrikli araçlarda yakıt tüketimini doğru tahmin ettiği görülmektedir. Bu durum, enerji kullanımının optimize edilmesi, kaynakların planlanması ve ulaşım sektöründeki sürdürülebilirlik çabalarına katkıda bulunulması açısından önemli sonuçlar doğurmaktadır. Bu bulgular, gelişmiş makine öğrenimi tekniklerinden yararlanmanın elektrikli araçlarda doğru yakıt tüketimi tahminine önemli ölçüde katkıda bulunabileceğini ve ulaşım sektöründe optimizasyon, kaynak planlaması ve sürdürülebilirlik için potansiyel faydalar sunabileceğini göstermektedir.

KAYNAKLAR

- Abdelaty, H., Al-Obaidi, A. & Mohamed, M. (2021). Machine learning prediction models for battery-electric bus energy consumption in transit. *Transportation Research Part D: Transport and Environment*, 96, 102868.
- Alves, J., Baptista, P. C. & Gonçalves, G. A. (2016). Indirect methodologies to estimate energy use in vehicles: Application to battery electric vehicles. *Energy Conversion and Management*, 124, 116–129.
- Amin, A., Altinoz, B. & Dogan, E. (2020). Analyzing the determinants of carbon emissions from transportation in European countries: The role of renewable energy and urbanization. *Clean Technology and Environmental Policy*, 22, 1725–1734.
- Bi, J., Wang, Y. & Shao, S. (2018). Residual range estimation for battery electric vehicle based on radial basis function neural network. *Measurement*, 128, 197–203.

- Bolovinou, A., Bakas, I. and Amditis, A.(2014). Online prediction of an electric vehicle remaining range based on regression analysis. In: 2014 IEEE International Electric Vehicle Conference (IEVC), pp. 1–8. IEEE.
- Chen, Y., Wu, G. & Sun, R. (2020). A Review and Outlook of Energy Consumption Estimation Models for Electric Vehicles. *ArXiv Preprint ArXiv200312873*.
- De Cauwer, C., Van Mierlo, J. & Coosemans, T. (2015). Energy consumption prediction for electric vehicles based on real-world data. *Energies*, 8, 8573–8593.
- Felipe, J., Amarillo, J. C. & Naranjo, J. E. (2015). Energy consumption estimation in electric vehicles considering driving style. In: 2015 IEEE 18th International Conference on Intelligent Transportation Systems, pp. 101–106. IEEE.
- Hertzke, P., Müller, N. & Schenk, S.(2018). The global electric-vehicle market is amped up and on the rise. *McKinsey Center for Future Mobility*, 1–8.
- Hong, J., Park, S. & Chang, N. (2016). Accurate remaining range estimation for electric vehicles. In: 2016 21st Asia and South Pacific Design Automation Conference (ASP-DAC), pp. 781–786. IEEE.
- Hughes, S., Moreno, S. & Yushimito, W. F. (2019). Evaluation of machine learning methodologies to predict stop delivery times from GPS data. *Transportation Research Part C: Emerging Technologies*, 109, 289–304.
- Koubaa, R., Yoldas, Y. & Goren, S. (2020). Implementation of cost-benefit analysis of vehicle to grid coupled real Micro-Grid by considering battery energy wear: Practical study case. *Energy & Environment*, 0958305X20965158.
- Li, P., Zhang, Y. & Zhang, Y. (2021). Prediction of electric bus energy consumption with stochastic speed profile generation modelling and data-driven method based on real-world big data. *Applied Energy*, 298, 117204.
- Liu, K., Wang, J., Yamamoto, T., et al. (2016). Modelling the multilevel structure and mixed effects of the factors influencing the energy consumption of electric vehicles. *Applied Energy*, 183, 1351–1360.
- Liu, K., Yamamoto, T. & Morikawa, T. (2017). Impact of road gradient on energy consumption of electric vehicles. *Transportation Research Part D: Transport and Environment*, 54, 74–81.
- López, F. C., and Fernández, R. Á. (2020). Predictive model for energy consumption of battery electric vehicle with consideration of self-uncertainty route factors. *Journal of Cleaner Production*, 276, 124188.
- Modi, S., Bhattacharya, J. & Basak, P. (2020). Estimation of energy consumption of electric vehicles using Deep Convolutional Neural Network to reduce driver's range anxiety. *ISA Transactions*, 98, 454–470.
- Paçal, İ. (2024). MaxCerVixT: A novel lightweight vision transformer-based Approach for precise cervical cancer detection, *Knowledge-Based Systems*, 289, 111482.
- Paçal, İ. (2023). Göğüs röntgeni görüntülerinden otomatik covid-19 teşhisi için görü transformatörüne dayalı bir yaklaşım. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 13, 2, 778–791.
- Ullah, I., Liu, K. Yamamoto, T. Al Mamlook, R. E. & Jamal, A. (2022). A comparative performance of machine learning algorithm to predict electric vehicles energy consumption: A path towards sustainability. *Energy & Environment*, 33 (8), 1583-1612.
- Vita, V., & Koumides, P. (2019). Electric vehicles and distribution networks: Analysis on vehicle to grid and renewable energy sources integration. In: 2019 11th Electrical Engineering Faculty Conference (BulEF), pp. 1–4. IEEE.
- Wang, J., Liu, K. & Yamamoto, T. (2017). Improving electricity consumption estimation for electric vehicles based on sparse GPS observations. *Energies*, 10, 129.
- Xu, G., Wang, S. & Li, J. (2020). Moving towards sustainable purchase behavior: Examining the determinants of consumers' intentions to adopt electric vehicles. *Environmental Science and Pollution Research*, 1–12.