



AÇIK Derin öğrenme modeli tabanlı araç CO tahmini2Sürdürülebilir çevre için Açıklanabilir AI entegrasyonu ile emisyonlar

Gazi Muhammed İmdadul Alam¹, Şeriat Arfin Tanim², Sumit Kanti Sarker², Yutaka Vatanobe³, Raşidül İslam⁴, MF Mridha² & Kamruddin Nur²

Ulaştırma sektörü, karbondioksit (Ortak²) emisyonları, küresel ısınmayı yoğunlaştırarak sel, kuraklık, sıcak hava dalgaları, buzul erimesi ve deniz seviyelerinin yükselmesi gibi daha sık ve şiddetli hava olaylarına yol açıyor. Bu çalışma, tahmin için kapsamlı bir yaklaşım öneriyorOrtak² eXplainable Artificial Intelligence (XAI) yöntemleriyle geliştirilen derin öğrenme tekniklerini kullanarak araçlardan kaynaklanan emisyonları inceledik. Kanada hükümetinin resmi açık veri portalından bir veri kümesi kullanarak, çeşitli araç özelliklerininOrtak² emisyonlar. Analizimiz, yüksek performanslı motorların yalnızca daha fazla kirlenici yaymadığını, aynı zamanda hem şehir hem de otoyol koşullarında yakıt tüketiminin de daha yüksek emisyonlara önemli ölçüde katkıda bulunduğunu ortaya koyuyor. Farklı üreticiler tarafından üretilen araç sayısındaki çarpık dağılımları ve yakıt türleri arasında yakıt tüketimindeki eğilimleri belirledik. Bu çalışma, bir CO oluşturmak için derin öğrenme tekniklerini kullandımızemisyon tahmin modeli, özellikle CarbonMLP adı verilen hafif çok katmanlı algılayıcı (MLP) mimarisi. Önerilen model hiperparametre ayarı ile optimize edildi ve 0,9938'lik yüksek R kare değeri ve 0,0002'lik düşük Ortalama Kare Hata (MSE) gibi mükemmel performans ölçütleri elde edildi. Bu çalışma, model yorumlama yeteneğini geliştirmek ve özelliklerin önemi hakkında bilgi sağlamak için özellikle SHapley Ekleme Açıklamalar (SHAP) olmak üzere XAI yaklaşımlarını kullanır. Bu çalışmanın bulguları, önerilen metodolojinin CO'yu doğru bir şekilde tahmin ettiğini göstermektediraraçlardan kaynaklanan emisyonlar. Ek olarak, analiz, veri setini artırma, ek kirlenicileri entegre etme, yorumlanabilirliği iyileştirme ve gerçek dünya uygulamalarını araştırma gibi daha fazla araştırma için alanlar önermektedir. Genel olarak, bu çalışma araç CO'sunu azaltmak için etkili stratejilerin tasarlanmasına katkıda bulunmaktadıremisyonlarını azaltmak ve çevresel sürdürülebilirliği teşvik etmek.

Anahtar kelimelerOrtak²emisyonlar, CarbonMLP, Açıklanabilir Yapay Zeka, Araç özellikleri, Yakıt tüketimi, Çevresel sürdürülebilirlik.

21. yüzyılda iklim değişikliği ekosistemleri, ekonomiyi ve insan refahını olumsuz yönde etkilediği için insanlık için önemli bir zorluk oluşturmaktadır. Karbondioksit (CO₂) emisyonu iklim değişikliğinin birincil nedenidir. Ek olarak, bu salgının nedenleri arasında endüstriyel süreçler, enerji üretimi ve ulaşım gibi çeşitli insan faaliyetleri yer alır. CO₂emisyonları küresel bir endişe kaynağıdır, Kanada gibi ülkeler geniş coğrafi manzaralarda fosil yakıt bazlı ulaşım bağımlılıkları nedeniyle benzersiz zorluklarla karşı karşıyadır. Kanada'nın ulaşım sektörü ülkenin genel sera gazı (GHG) emisyonlarının önemli bir bölümünü oluşturur ve bu da onu çevresel etkileri azaltmayı amaçlayan politika müdahaleleri için bir öncelik haline getirir¹. Dahası, bu emisyonlar çevreyi tehdit ediyor ve insan sağlığını olumsuz etkiliyor. Trafikten kaynaklanan hava kirliliğine maruz kalmak astım ve kronik obstrüktif akciğer hastalığı (KOAH) gibi solunum problemlerini kötüleştirebilir ve kalp hastalığı veya felç geliştirme riskini artırabilir².

Taşımacılık, çağdaş toplumun önemli bir temeli olup ekonomik işlemleri, dünya çapında bağlantıları ve bireysel hareketi mümkün kılar. Ancak, fosil yakıtlara bağımlılık önemli ve

¹Doğu Delta Üniversitesi, Bilim, Mühendislik ve Teknoloji Okulu, Chattogram 4209, Bangladeş.²Bilgisayar Bilimleri Bölümü, Amerikan Uluslararası Üniversitesi-Bangladeş (AIUB), Dakka 1229, Bangladeş.

³Bilgisayar Bilimi ve Mühendisliği Bölümü, Aizu Üniversitesi, Aizu-Wakamatsu 965-8580, Japonya.

⁴Bilgisayar Bilimi ve Mühendisliği Bölümü, Asya Pasifik Üniversitesi, Dakka 1216, Bangladeş.-e-posta: rashed.cse@gmail.com ; kamruddin@aiub.edu


artan çevresel sıkıntı, özellikle CO₂'deki artış zemisyonlar. Bu emisyonlar, iklim değişikliğini hızlandıran ve daha yüksek deniz seviyeleri, aşırı hava koşulları ve ekosistemlerde bozulmalar gibi çevresel sorunlara yol açan sera gazlarındaki artışın başlıca nedenlerinden biridir. Motorlu taşıtlar, ulaşım sektöründe önemli bir etkiye sahiptir ve CO₂'ye büyük katkıda bulunur. 2020'de otomobiller küresel CO₂ emisyonunun yaklaşık %23'ünü oluşturuyordu. Ortalama bir binek otomobil yılda 4,6 metrik ton karbondioksit üretir. Farklı taşımacılıklar ayrıca azot oksitleri ve diğer kirleticileri de yayar, bunlar da duman oluşumuna ve asit yağmuruna katkıda bulunur ve ekosistemlere zarar verir. Dünya Sayımları, otomobillerin hava durumu üzerindeki önemli etkisini vurgulayarak, onları hava kirliliğine birincil katkıda bulunan unsur olarak öne çıkarıyor.

Figür 1 CO dağılımını gösterir 2022 yılı için dünya çapında araç türüne göre emisyonlar. Grafik, her araç kategorisinin toplam küresel CO₂ emisyonuna olan yüzdelik katkısını vurgulamaktadır. Emisyonlar, Bu emisyonların anlaşılması ve tahmin edilmesi, iklim değişikliğiyle mücadelede etkili önlemlerin formüle edilmesi açısından önemlidir.

Bu faktörlerin karmaşık etkileşimi araç CO₂ emisyonunu etkiler. En önemli katkıda bulunanlar yakıt türü, motor özellikleri, sürüş davranışı, yol koşulları, araç ağırlığı ve aerodinamiktir. CO seviyesiz Araçların ürettiği emisyonlar kullanılan yakıt türünden doğrudan etkilenmektedir.

Biyoyakıtlar, hidrojen ve elektrik daha az CO üretir; benzin ve dizel gibi fosil yakıtlardan daha fazlası. Biyoyakıtlar daha düşük karbon ayak izine sahipken, hidrojen yakıtlı araçlar yan ürün olarak yalnızca su buharı üretir. Motor hacmi, güç çıkışı ve teknoloji, CO₂'yi etkileyen faktörlerdir. Doğrudan enjeksiyon ve turboşarj gibi motor teknolojilerindeki gelişmeler yakıt verimliliğini artırıp emisyonları azaltabilir de, daha büyük ve daha güçlü motorların genellikle daha yüksek seviyelerde CO ürettiğini unutmamak önemlidir.

2. Yakıt tüketimi ve CO₂ emisyonları ayrıca şanzıman mekanizmasının manuel veya otomatik olmasına da önemli ölçüde bağlıdır. Ortak emisyonlar, sabit hızları korumak, trafik ışıklarını etkinleştirmek ve orta düzeyde hızlanmak gibi eko-sürüş stratejileriyle azaltılabilir. Bunun tersine, agresif hızlanma, hızlı frenleme ve sık sık rölantide kalma daha yüksek emisyonlara katkıda bulunur. Araç yakıt tüketimi ve CO₂ emisyonları trafik sıkışıklığı, yol yüzey koşulları ve eğimlerden etkilenir. Dur-kalk trafiği, motor rölantisinin artmasına ve optimum olmayan yakıt kullanımına neden olurken, engebeli yol yüzeyleri ekstra sürtünme yaratabilir ve bu da yakıt verimliliğini etkiler. Ayrıca, şiddetli sıcaklıklar ve rüzgar seviyeleri de yakıt tüketimini ve emisyonları etkiliyor. Daha yüksek araç ağırlığı, daha yüksek CO seviyelerine yol açan daha fazla enerji tüketimi gerektirir. Ayrıca, aerodinamik sürüklenmenin varlığı arabaları etkiler çünkü aerodinamik yapıları daha az hava direnciyle karşılaşır ve bu da daha düşük emisyonlarla sonuçlanır. Politikaların ve stratejilerin geliştirilmesi önemlidir.



Şekil 1. Araç Tipine Göre Taşımacılık Emisyonları Toplam CO₂'ye Katkıda Bulunanlar. Emisyonlar.

Araç CO₂'sini tahmin ederek iklim değişikliğini azaltmakz emisyonları. Daha temiz ve daha yakıt tasarruflı araçları teşvik etmek için CO₂'nin tahmini ve izlenmesiz araçlardan kaynaklanan emisyonlar zor bir görev olmaya devam ediyor. Emisyon faktörleri ve araç testleri gibi emisyonları tahmin etmeye yönelik geleneksel yöntemler, doğruluk, ölçeklenebilirlik ve dinamik sürüş koşullarına uyarlanabilirlik açısından sınırlamalara sahiptir¹⁶. Ayrıca, düzenleyici kuruluşlar araç türü, yakıt türü ve diğer ilgili değişkenler gibi kriterlere dayalı emisyon faktörleri belirlemiştir. Yararlı olsalar da, bu parametreler sıklıkla genel bir yaklaşım sunar ve gerçek dünyadaki gerçek emisyonları etkileyen faktörlerin dinamik etkileşimini dikkate almaz¹⁷.

Bu araştırma, araç emisyonlarının çevresel etkisini ele alma ve emisyonlarda değişikliklere neden olan süreçlere ilişkin anlayışımızı geliştirme konusundaki acil ihtiyaçtan kaynaklanmıştır. Politika yapıcılar, doğru tahmin modelleri oluşturarak emisyon azaltma yöntemleri, sürdürülebilir ulaşım politikaları ve altyapı harcamaları hakkında iyi bilgilendirilmiş kararlar verebilirler.¹⁸ Ayrıca, CO₂'nin kesin tahminleri² Çıkışlar, tüketicilerin araç seçerken net tercihler yapmasını sağlayabilir, çevre dostu sürüş uygulamalarını vurgulayabilir ve sürdürülebilir ulaşımı destekleyebilir.

Bu çalışma, araç CO₂'sini tahmin etmek için mevcut yöntemlerin sınırlamalarını ele almayı amaçlamaktadır.² Gerçek dünya verilerinden yararlanan ve çeşitli önemli avantajlar sunan hafif bir derin öğrenme (DL) modeli geliştirerek emisyonları azaltın:

1. Araç CO₂'sini tahmin etmek için gelişmiş teknikler kullanarak hafif bir DL modeli oluşturun ve eğitimz emisyonları kapsamlı veri kümelerinden doğru bir şekilde hesaplar. En doğru ve sağlam tahminçileri seçmek için birden fazla algoritma karşılaştırılır.
2. Açıklanabilir Yapay Zeka (XAI) entegrasyonu ile derin öğrenme modelini eğitmek için gerçek dünya verilerini entegre ediyoruz, böylece araç CO₂'sini tahmin etmede gerçekçiliği ve doğruluğu artırıyoruz.² emisyonlar.
3. Minimum veri ön işleme ile bir DL modeli geliştirerek hesaplama verimliliğini ve ölçeklenebilirliği sağlayın, böylece yerleşik emisyon tahmini ve düzenleyici kullanımda yaygın olarak benimsenmesi için gerçek dünya uygulanabilirliğini teşvik edin.

Bu çalışmada kullanılan veri seti Kanada araçlarına ve emisyon verilerine özgü olsa da, geliştirilen model ve teknikler genelleştirilebilir ve diğer ülke ve bölgelerdeki benzer veri setlerine uygulanabilir. Araç CO₂ emisyonlar küresel bir sorundur ve motor boyutu, yakıt tüketimi ve araç tipi gibi faktörlerden etkilenir. Bu araştırmadan elde edilen öngörü teknikleri ve içgörüler, evrensel araç özelliklerini kullandıkları için çeşitli coğrafi bağlamlara uygulanır. Ayrıca, bu çalışmada gösterilen yöntemler, emisyon standartları, araç tipleri ve sürüş koşullarındaki bölgesel farklılıkları hesaba katmak için kolayca uyarlanabilen bir çerçeve sunarak, CO₂'yi azaltmaya yönelik ulusal ve uluslararası çabalar için önemli hale getirirz emisyonlar.

Bu çalışma son CO'yu analiz etti² Çeşitli araç tipleri ve birden fazla üreticiden gelen modeller için emisyon eğilimleri. Bu çalışma, çeşitli araç özelliklerinin CO₂'yi nasıl etkilediğini göstermek için Kanada hükümetinin resmi açık veri web sitesinden alınan verileri kullanır.² emisyonları. Veri hazırlama süreci, veri seti kalitesini ve tahmin doğruluğunu artırmak için titiz temizleme, veri mühendisliği ve dönüştürme prosedürlerini içerir. Bu çalışma, CO'nun tahmin doğruluğunu artırmak için gelişmiş derin öğrenme tekniklerini, özellikle çok katmanlı bir algılayıcı (MLP) mimarisini kullanır.² emisyonları. Performans karşılaştırması için geleneksel makine öğrenme modelleri belirtilse de, bu çalışmanın temel odağı, daha doğru CO₂ emisyonları elde etmek için güçlü yönlerinden yararlanan derin öğrenme yaklaşımıdır.² emisyon projeksiyonları. Ayrıca, Shapley Additive exPlanations grafikleri gibi XAI metodolojileri, model yorumlanabilirliğini iyileştirmek için kullanılır. Bu entegrasyonu yalnızca model şeffaflığını artırmakla kalmaz, aynı zamanda çok sayıda araç özelliğinin CO₂ üzerindeki etkisine ilişkin daha ayrıntılı içgörüler sağlarz emisyon tahminleri, daha etkili emisyon azaltma planlarının oluşturulmasına olanak sağlıyor.

Bu makalede, CO tahmininin derinlemesine bir analizini sunuyoruz² Derin öğrenme ve XAI tekniklerini kullanarak araçlardan kaynaklanan emisyonlar. Bölüm'**İlgili Çalışmalar**'Araştırmamız için bir bağlam sağlamak amacıyla konuyla ilgili önemli literatürü gözden geçirir. Bölüm'**Yöntem**'Veri toplama, ön işleme, model geliştirme ve değerlendirme tekniklerini içeren kullanılan yaklaşımı açıklar. Bölüm'**Sonuç Analizi**'önerilen modelin performansını değerlendiren sonuçları ve tartışmaları sunar ve değerli başarıları tartışır. '**Sonuç ve Gelecekteki Çalışmalar**'temel katkıları özetleyerek, eksiklikleri belirleyerek ve gelecekteki araştırma alanları önererek sona ermektedir.

İlgili çalışma

Yapay zeka (AI) modelleri karbondioksit (CO₂) emisyonunu azaltmada umut vadediyor² emisyonları çeşitli mekanizmalar aracılığıyla. Çalışmalar, AI'nın CO₂'yi önemli ölçüde azaltabileceğini göstermiştirz emisyonlar, özellikle gelişmiş endüstriyel yapılara sahip bölgelerde^{19,20} Yapay Zeka algoritmaları, enerji açısından verimli altyapı için Ölçüm ve Doğrulama (MV) protokollerini geliştirerek hem enerji tüketiminde hem de emisyonlarda önemli azalmalara yol açar.²¹ Örneğin, çok genli genetik programlama gibi yapay zeka teknikleri, CO modellemek ve optimize etmek için etkili bir şekilde uygulanmıştır.² kömürle çalışan elektrik santrallerinde yakalama, emisyon tahminlerinde %99'un üzerinde doğruluk elde etme²² Bu AI modelleri, CO'nun tasarımı ve operasyonel stratejilerini iyileştirmek için değerli içgörüler sağlarz yakalama sistemleri, uzun vadeli karbonsuzlaştırma çabalarına katkıda bulunuyor²² Ayrıca, karbon emisyonlarını daha da azaltmak ve karbon nötrlüğü hedeflerini desteklemek için AI stratejileri şehir düzeyinde başarıyla uygulandı.²³

Yapay zekanın kimya endüstrisindeki uygulaması, süreçleri optimize etme, emisyonları tahmin etme ve sürdürülebilir uygulamaları destekleme yeteneği nedeniyle de tanınmaya başladı. Bu katkı, endüstrinin net sıfır emisyonu ve genel olarak²⁴ Yapay zekanın karbon azaltımı üzerindeki etkisi ülkeler arasında değişiklik gösterir ve yüksek karbon emisyonlu ve yüksek gelirli ülkelerde daha belirgin etkiler gözlemlenir. Bu çeşitlilik, emisyon azaltımı stratejileri tasarlarırken endüstriyel ve demografik yapıları dikkate almanın önemini vurgular²⁵ Bu bulgular toplu olarak, yapay zekanın karbon nötrlüğünü ilerletmede oynadığı hayati rolü vurgulamakta ve politika önerileri ve sürdürülebilir kalkınma stratejileri için içgörüler sunmaktadır.

Küresel CO₂ emisyonunun yaklaşık %16,2'sinden sorumlu olan ulaştırma sektörüzemissionları da yapay zeka destekli gelişmelerden faydalandı²⁶Rastgele Orman, Karar Ağacı ve Regresyon Modelleri gibi makine öğrenimi (ML) algoritmaları, CO₂'yu doğru bir şekilde tahmin etmek için kullanılmıştır.²⁷Bunlar arasında Gradient Boosting Regression (GBR)'nin en etkili olduğu kanıtlanmıştır. Bu ML algoritmaları emisyonları tahmin ederken hem sosyoekonomik hem de ulaşım ile ilgili faktörleri dikkate alır²⁸RMSE (Kök Ortalama Kare Hatası) gibi ölçümlerle doğrulanı denetlenen makine öğrenimi regresyon yaklaşımları, CO'nun doğruluğunu artırmak için kullanılmıştır.²⁹Özellikle CO₂'nin gerçek zamanlı tahminizHindistan'daki otomobillerden kaynaklanan emisyonlar, ML modelleri oluşturmanın ve hassas tahminler elde etmek için hiperparametreleri optimize etmenin etkinliğini göstermiştir³⁰.

Derin Sinir Ağları (DNN'ler), CO tahmininde popülerlik kazandı³¹emissionları, büyük veri kümelerindeki karmaşık desenleri ve korelasyonları analiz etme yetenekleri nedeniyle. Uzun Kısa Süreli Bellek (LSTM), Kapalı Tekrarlayan Birimler (GRU) ve Tekrarlayan Sinir Ağları (RNN) gibi gelişmiş derin öğrenme algoritmaları, araç emisyonlarını önemli bir başarıyla tahmin etmek için başarıyla kullanılmıştır.³¹ Bu algoritmaları birleştiren entegre modeller, emisyon tahminlerinin doğruluğunu artırmada umut vadetmektedir. Örneğin, LSTM ve BiLSTM modelleri CO tahmininde etkili bir şekilde kullanılmıştır.³²Motor hacmi, yakıt türü ve tüketim oranları gibi araç özelliklerine dayalı emisyonlar³²Ek olarak, derin sinir ağlarını kullanan topluluk öğrenme tekniklerinin, araç enerji verimliliğini tahmin etmedeki belirsizliği azalttığı, doğruluğu ve sağlamlığı daha da artırdığı öne sürülmüştür.³³


Birden fazla model ve algoritmayı birleştiren topluluk yaklaşımları, karbonla ilgili parametreleri tahmin etmede oldukça yorumlanabilir, doğru ve sağlam olduklarını kanıtladılar. Bu modeller, politika yapıcılar ve çevresel karar alma süreçleri için paha biçilmez araçlardı^{34,35}Örneğin, araçlardaki OBD-II portları aracılığıyla toplanan gerçek zamanlı sensör verileri kullanarak eğitilen modeller, araç düzeyinde emisyonların izlenmesi için ölçeklenebilir ve verimli yöntemler sağlamıştır.³⁶Belirli bir makine öğrenme modeli olan UWS-LSTM, CO'nun kesin tahminlerini göstermiştir³⁷Hibrit araçlardaki emisyonları azaltarak, hızlı ve verimli sonuçlar gerektiren akıllı araç uygulamaları için oldukça etkili hale getirir³⁷.

Açıklanabilir AI modelleri, CO tahmininde farklı düzeylerde hassasiyet göstermiştir³⁸araçlardan kaynaklanan emisyonlar. Çalışmalar, ENGM(1,4) gibi gelişmiş doğrusal olmayan çok değişkenli modellerin, ulaşım sektörü emisyonlarını tahmin etmede geleneksel istatistiksel modellerden daha etkili olduğunu ve üstün doğruluk elde ettiğini göstermiştir.³⁸Ayrıca, ileri beslemeli sinir ağları (FFNN), uyarlanabilir ağ tabanlı bulanık çıkarım sistemleri (ANFIS) ve LSTM gibi gelişmiş AI yaklaşımları, CO₂'yi tahmin etmek için kullanılmıştır.³⁹emissionlar, LSTM'nin özellikle yüksek doğruluk göstermesiyle³⁹Ek olarak, şerit değiştirme kararları için Shapley Ekllemeli Açıklamalarının (SHAP) kullanılması, AI model kararlarını etkileyen faktörler için net ve anlaşılır açıklamalar sunmuş ve böylece bu modellerin yorumlanabilirliğini ve güvenilirliğini artırmıştır.⁴⁰

Özetle, yapay zekanın CO₂ emisyonunu azaltma potansiyelizemissionlar enerji, kimyasallar ve ulaşım gibi çeşitli sektörlerde yaygın olarak tanınmaktadır. Yapay zeka yalnızca süreçleri optimize etmekle ve emisyonları tahmin etmekle kalmaz, aynı zamanda sürdürülebilir uygulamaları destekler ve politika yapımını bilgilendirir. Yapay zekanın emisyon azaltma çabalarına entegrasyonu, karbon nötrlüğüne ulaşma ve küresel ölçekte iklim değişikliğini ele alma yolunda kritik bir yol temsil eder. Literatür İncelemesinin genel görünümü Tablo'da verilmiştir¹

Referans	Veri seti	Örnek	Kesinlik	Sınırlama
32	Kanada hükümetinin açık veri portalı	LSTM ve BiLSTM	R ² = %93,78	Mevcut veri kümelerine dayanır, gerçek zamanlı veya çeşitli veri kaynaklarının yakalanmasını zorlaştırır, dinamik emisyon senaryolarına uyumu etkiler.
41	PEMS sistemi ve OBDII arayüzü kullanılarak yol testlerinden toplanan veriler	Gradient Arttırma	R ² = %61,26	Doğrulama katsayıları (R ² = 0,61, MSE = 0,77), tahmin performansında iyileştirmeye ihtiyaç olduğunu göstermektedir.
42	Otomotiv endüstrisi veri seti, NEDC ve WLTP testlerine dayalı yakıt tüketimi	Çok kanallı	R ² değeri < 98.00%	İçten yanmalı motorlara sahip binek otomobillere odaklanılarak, kapsam bu araç tipiyle sınırlandırılmıştır.
43	Japonya'daki elektrikli araçlardan gerçek dünya GPS izleme verileri	LightGBM, XGBoost, ANN ve LR	R ² =%98,00	Modelde ek yükler, sürücü davranışları ve trafik koşulları gibi faktörler göz ardı ediliyor.
44	Sabit durum koşullarında akışkan yataklı gazlaştırmacı kapsayan literatürden veriler	Gradient Arttırma	R ² =%84,68	Açıklanabilir Yapay Zeka (XAI) ihtiyacını vurgular ancak XAI'yi benimsemenin daha geniş kapsamlı etkilerine değinmez.
37	Hibrit araç performansından ve 20'den fazla operasyonel parametreden SprintR-R 20 CO kullanılarak toplanan veriler ³⁷ sensör	UWS-LSTM	R ² =%97,50	Veri seti standardizasyonu ayrıntılı değil, bu da yeniden üretilebilirliği etkiliyor.
45	Kanada Hükümeti'nin hafif hizmet araçlarına ilişkin veri seti (2017–2021)	Tek değişkenli polinom Gerileme	R ² =%98,60	Tahmini yakıt tüketimi için daha yüksek performanslı bir model ve daha fazla özelliğe sahip veri kümesinden yoksundur.
46	Çin'in Hangzhou kentindeki 103.831 hafif hizmet tipi benzinli aracın I/ M kayıtlarına karayolu uzaktan algılama ölçümleri bağlandı	NN, RF, XGBoost ve Ensemble modeli	R ² =%88,00	Yalnızca ORRS verilerine dayanmaktadır ve bu da yüksek/düşük emisyonlu araçları yanlış tanımlayabilir.
47	Dünya Bankası, Türkiye Karayolları Genel Müdürlüğü ve Türkiye İstatistik Kurumu verileri	MLP, XGBoost ve SVM	R ² =%98,86	Giriş değerlerinin korelasyon etkisine dayalı sadece dört senaryo incelendi.
48	Taşınabilir Emisyon Ölçüm Sisteminden (PEMS) NO _x , CO kaydı verilerizve dizel araçlardan kaynaklanan diğer kirlenmeler	Gradient Arttırma Gerileme	R ² =%99,00	Tahmin doğruluğu, minimum giriş özellikleriyle sınırlıdır.
49	Çeşitli frenleme olaylarının gerçek dünya sürüş koşullarından toplanan veriler	Kedi Güçlendirme	R ² =%83,00	Veri seti 600 frenleme olayıyla sınırlıdır ve tüm senaryoları tam olarak temsil etmemektedir.
50	Açık Enerji Veri Girişimi (OEDI) veri kümesi	ML Topluluk Modeli	94.70%	Model maliyeti ve hesaplama yoğunluğu gerektiren bir modeldir.

Tablo 1Literatür taramasının genel görünümü.



Şekil 2. Makalede anlatılan tüm süreci, veri toplamadan model değerlendirme ve yorumlamaya kadar gösteren metodoloji diyagramı.

Değişken	Tanım	Örnek Değerler
Yapımcı	Araç üreticisi	ACURA, TOYOTA, FORD
Örnek	Araçın belirli modeli	ILX, MDX 4WD, RDX Dört Tekerlekten Çekiş
Araç Sınıfı	Araç tipinin sınıflandırılması	KOMPAKT, SUV - KÜÇÜK, ORTA BOY
Motor Boyutu (DM ³)	Motor hacmi (desimetre küp)	2, 2.4, 3.5
Silindirler	Motor silindir sayısı	2, 4, 6
Bulaşma	Araç şanzıman tipi	AS5, M6, AV7
Yakıt Türü	Kullanılan yakıt türü	Z (Belirli bir türü belirtir, örneğin benzin, dizel)
Yakıt Tüketimi Şehir (L/100 km)	Şehir içi yakıt tüketim oranı litre/100 km	9.9, 11.2, 6
Yakıt Tüketimi Karayolu (L/100 km)	100 km'de litre cinsinden karayolu yakıt tüketim oranı	8,5, 9,6, 5,9
Yakıt Tüketimi Comb (L/100 km)	100 km'de litre cinsinden kombine yakıt tüketim oranı	6.7, 7.7, 5.8
Yakıt Tüketimi Comb (mpg)	Mil başına galon cinsinden kombine yakıt tüketim oranı	33, 29, 48
OrtakEmisyonlar (g/km)	Kilometre başına karbondioksit emisyonları	196, 221, 136

Tablo 2. Veri kümesi özelliklerinin açıklaması.

Yöntemler ve materyaller

Bu çalışmanın metodolojisi, CO₂'yi kapsamlı bir şekilde tahmin etmek için yalnızca derin öğrenme tekniklerine odaklanmaktadır.2 araçlardan kaynaklanan emisyonlar. Süreç ön işleme ve veri toplama ile başladı, ardından MLP modeli oluşturuldu. Ek olarak, tahminlerin yorumlanabilirliğini ve güvenilirliğini artırmak için açıklanabilir AI (XAI) yöntemleri, özellikle Shapley Eklmeli Açıklamalar (SHAP) kullanıldı. Bu çalışmada kullanılan metodolojinin genel bir görünümü Şekil'de gösterilmiştir2.

Veri toplama ve keşfi

Kaggle'dan elde edilen bu çalışmanın veri seti, CO'nun nasıl çalıştığına dair kapsamlı bilgiler sunmaktadır.2 emisyonlar çeşitli araç parametrelerine bağlı olarak değişir. Veri seti, yedi yıllık bir dönemi kapsayan Kanada hükümetinin resmi açık veri web sitesinden veri derlerVeri seti7 yıllık bir zaman diliminde 12 sütun ve 7385 satır içeren veri seti kapsamlı bir bilgi kaynağıdır. Araç modelleri, yakıt türleri, şanzımanlar, şehir ve otoyol yakıt tüketim derecelendirmeleri ve CO hakkında bilgilerzemisyon seviyeleri hepsi dahildir. Tablo2 Veri setinin özelliklerine, açıklamalarına ve ilişkili değerlerine genel bir bakış sunar.

Veri setindeki "uel Consumption Comb (mpg)" sütunu başlangıçta yakıt tüketimini galon başına mil (mpg) olarak göstermek için eklenmiştir. Ancak, ek analizler bildirilen değerlerin 100 km başına litre (L/100 km) ile galon başına mil (mpg) arasındaki normal dönüşümle eşleşmediğini ortaya koymuştur51Doğru dönüşüm formülü şu şekildedir:

$$\text{mpg} = \frac{235.215}{L/100km} \quad (1)$$

Bildirilen "Yakıt Tüketimi Comb (mpg)" değerleri ile dönüştürme prosedürü kullanılarak tahmin edilen beklenen değerler arasındaki tutarsızlık nedeniyle, bu sütun veri setinden kaldırıldı. Bunun yerine, 100 km başına litre (L/100 km) cinsinden yakıt kullanımını yansıtan sütun ek analiz ve modelleme için kullanılacaktır.

CO analizinden belirgin bir desen ortaya çıktı: araç modeline göre emisyonlar: SRT, Rolls Royce ve Lamborghini gibi yüksek performanslı motorlara sahip araçlar en yüksek emisyonlara sahipken, Smart ve Honda gibi yakıt tasarruflu modeller en düşük emisyonları sergiledi. Bu gözlem, büyük motorların daha fazla CO ürettiği teorisine tutarlıdır.

Bu gözlemleri ölçmek için ortalama CO₂'yu hesapladık. Görselleştirmede gösterilen 41 farklı araç modeli için emisyonlar. Ortalama, veri setini araç üreticisine göre gruplandırarak ve aşağıdaki formülü uygulayarak tahmin edildi:

$$\text{Ortalama CO}_2\text{Emisyonlar} = \frac{1}{N} \sum_{Ben=1}^N \text{Ortak}_{2,Ben} \quad (2)$$


Neresi? Belirli bir araç modeli için toplam giriş sayısını temsil eder ve Ortak_{2,Ben} CO₂'yu belirtir. Her giriş için emisyonlar.

Şekilde gösterilen bu analiz, araç tasarımının çevresel etkiyi nasıl etkilediğine dair bilgilendirici bilgiler sunuyor ve tahmini analiz için özellik seçiminde emisyonların dikkate alınmasının önemini vurguluyor.


Kanada'da yedi yıllık bir süre boyunca toplanan veri setini analiz ederken, her şirket tarafından üretilen araçların dağılımı çarpıktı. Ford en fazla arabaya (623) sahipti; ancak ortalama CO₂ emisyonlar nispeten ılımlıydı. Bu ayrım, Ford'un büyük araç sayısının (623 araba) × 270 g/km/araba = 168.210 g/km CO₂ emisyonlar toplam emisyonlara önemli ölçüde katkıda bulunur, araç başına en yüksek ortalama emisyonu açmaz. Buna karşılık, SRT veri setinde en az otomobile sahipken, Chevrolet araç sayısı bakımından ikinci en büyük üreticiydi. Şekil 4 Her üreticinin ürettiği araç sayısına genel bir bakış sunarak, bunların toplam CO₂ emisyonuna katkılarını gösterir emisyonlar.

Çeşitli yakıt türleri için yakıt kullanım eğilimlerinin analizi, Şekil 1'de gösterildiği gibi bazı dikkate değer kalıpları ortaya çıkardı. Yakıt türleri arasında etanol ("E" olarak gösterilir) en yüksek yakıt tüketimini gösterdi. Bu artan tüketim, etanolün benzine kıyasla daha düşük enerji yoğunluğuna bağlanabilir. Buna karşılık, "X" (normal benzin), "Z" (premium benzin) ve "D" (dizel) olarak etiketlenen yakıtlar daha düşük yakıt tüketim seviyeleri gösterdi. "N" ile gösterilen doğal gaz veri setine dahil edilmiş olsa da, yalnızca bir araç bu yakıtı kullandı ve bu nedenle Şekil'de belirgin bir şekilde gösterilmedi. Sınırlı temsiliyetinden dolayı.


Figür 6 etanolün daha yüksek yakıt tüketimine rağmen CO₂ emisyonunun daha yüksek olduğunu göstermektedir. Emisyonları diğer yakıtların, özellikle benzin ve dizelin emisyonlarıyla karşılaştırılabilir. Bu, etanolün daha fazla yakıt gerektirebileceğini gösterirken



Şekil 3 Ortalama CO₂ Araç Markasına Göre Emisyonlar: Bu şekil, araç modelleri ile CO₂ arasındaki ilişkiyi göstermektedir. Emisyonlarını belirlemek, daha yüksek emisyonlara katkıda bulunan tasarımları belirlemeye yardımcı olmak ve tahmini analizimizde özellik seçimine rehberlik etmek.



Şekil 4 Üreticiye (Şirkete) Göre Üretilen Araç Sayısı: Bu rakam, araçların üreticiye göre dağılımını gösterir ve genel CO₂ üzerindeki etkilerini vurgular. Bu içgörü, modelleme aşamasında üreticiyle ilgili kategorik değişkenlerin ele alınmasına rehberlik eder.




Şekil 5 Yakıt Türüne Göre Yakıt Tüketiminin Histogramı: Bu şekil, yakıt türlerinin CO₂'nin temel bir öngörücüsü olan yakıt tüketimini nasıl etkilediğini göstermektedir. Bu eğilimleri analiz etmek, yakıt türü seçimlerinin model tahminleri ve emisyonlar üzerindeki etkisine ilişkin anlayışımızı geliştirir.

kilometre, orantılı olarak daha yüksek CO₂ üretmez. Veri setindeki araçların çoğu CO₂ yayar. Yakıt tipinden bağımsız olarak 200 ila 300 g/km aralığında, etanol ise bu aralığı biraz aşıyor.

CO₂'nin özet Tabloda gösterilen emisyon veri seti tanımlayıcı istatistikler kullanılarak sağlanır. Motor hacmi (ES) litre, silindir sayısı, şehir içi, otoyol, kombinasyon yakıt tüketimi (FC) (100 km'de litre), CO₂ gibi önemli ayrıntılar emisyonlar (kilometre başına gram) ve toplam gözlem sayısı tabloda listelenmiştir. Gördüğümüz gibi, 1,35 litrelik bir standart sapma ve 3,16 litrelik bir ortalama motor boyutu vardır. İstatistikler ayrıca 0,9 litreden 8,4 litreye kadar değişen çeşitli motor boyutlarını da göstermektedir. Bu tablo ayrıca CO₂'daki farklılıklar hakkında bilgi sağlar emisyonları ve farklı arabalar arasındaki yakıt kullanımını. Bu özet, CO₂'yu etkileyen değişkenlere yönelik ek araştırma için çerçeveyi oluşturur.

Şekildeki korelasyon ısı haritası kullanılarak özellikler arasındaki bağlantılar (nesne özellikleri hariç) analiz edilerek ilginç eğilimler bulundu. Motor hacmi, silindir sayısı (0,93) sağlam bir pozitif korelasyon ve yakıt tüketimi ölçümleriyle orta derecede güçlü bir korelasyon göstermektedir: şehir (0,83), otoyol (0,75) ve kombine (0,81) ve CO₂ emisyonları (0,85). Bu, daha fazla silindire sahip daha büyük motorların



Şekil 6. CO Dağılım Grafiği; Yakıt Tüketimine Göre Emisyon: Bu rakam CO2 emisyonunu karşılaştırır; Yakıt türlerine göre emisyonların dağılımını ve bunların çevresel etkilerini vurgulamaktadır.

İstatistik	İngilizce (D)	Silindirler	FC Şehir (L/100 km)	FC Otoyolu (L/100 km)	FC Comb. (L/100 km)	Ortalama Emisyonlar (g/km)
Saymak	7385	7385	7385	7385	7385	7385
Anlam	3.160	5.610	12.55	9.040	10.98	250.6
Standart Sapma	1.350	0001	3.500	2.220	2.900	58.51
Asgari	0.900	0003	4.200	0004	4.100	0096
Medyan	0003	0006	12.10	8.700	10.60	0246
Maksimum	8.400	0016	30.60	20.60	26.10	0522

Tablo 3. Araç parametrelerinin tanımlayıcı istatistikleri.

(0,93) genellikle daha yüksek yakıt tüketimine yol açar, şehir içi tüketim en güçlü ilişkiyi gösterir. Ek olarak, daha yüksek şehir içi yakıt tüketimine sahip araçlar genellikle daha yüksek otoyol ve kombine yakıt tüketimine sahiptir, bu da bu ölçümler arasındaki yüksek korelasyonlarla gösterilmiştir (hepsi 0,94'ün üzerindedir). Bu, şehir içi sürüş sırasında daha fazla yakıt tüketiminin otoyollarda ve genel olarak daha yüksek tüketimle ilişkili olduğu fikrini güçlendirir. Korelasyon analizi Python kullanılarak, veri işleme için Pandas ve ısı haritası oluşturmak için Seaborn kullanılarak yürütülmüştür.

Veri Ön İşleme

Veri ön işleme, modelin tahminlerinin kalitesini doğrudan etkilediği için herhangi bir derin öğrenme modellemesinde önemli bir adımdır. Bu çalışmada, veri setinin temiz, yapılandırılmış ve analize hazır olduğundan emin olmak için kapsamlı ve metodik bir ön işleme aşaması gerçekleştirildi. Ön işleme, eksik değerleri ele almayı, değişkenleri dönüştürmeyi, aykırı değerleri ele almayı ve verileri derin öğrenme kanalı için hazırlamayı içerir. Bu sürecin amacı, modelin performansını engelleyebilecek tutarsızlıkları veya anormallikleri ortadan kaldırmaktır. Ön işleme iş akışı, aşağıda ana hatları verilen birkaç önemli adımı içeriyordu:


Veri temizleme

- Eksik ve boş değerler:** Veri kümesindeki eksik veya boş değerler, özellikle önemli değişkenler eksik olduğunda, model eğitimi önyargıya veya yanlışlıklara yol açabilir. Veri kümesi her iki değer için de kontrol edildi.
- Yinelenen Değerler:** Veri setindeki yinelenen kayıtlar sonuçları çarpıtabilir ve belirli gözlemleri aşırı temsil ederek yanlış model sonuçlarına yol açabilir. Yinelenen satırları belirlemek için kapsamlı bir kontrol yapıldı. Verilerdeki herhangi bir girdinin yinelenen olup olmadığı belirlendikten sonra değerler elendi. Bu, analizin çarpıtılmasını önler ve her veri noktasının farklı bir gözlemi temsil etmesini garanti eder.

Veri mühendisliği ve dönüşümü

Veri mühendisliği, derin öğrenme modellerinin tahmin yeteneğini geliştirmek için çok önemlidir. Çalışmamızda, veri setini hazırlamak ve değiştirmek için çeşitli stratejiler kullandık ve modelin CO₂'yu doğru bir şekilde tahmin edebilmesini sağladık. 2 Farklı araç özelliklerine dayalı emisyonlar. Veri setini hazırlamak için aşağıdaki yöntemler uygulandı:

- Aykırı Değer Tespiti ve Kaldırılması:** Z-puanı analizi kullanılarak aykırı değerler belirlendi ve veri setinden çıkarıldı. Bu aşama, aşırı değerler tarafından tetiklenen çarpık model tahminlerinden kaçınmak için kritik öneme sahiptir.



Şekil 7. Araç Özelliklerinin Korelasyon Isı Haritası: Korelasyon ısı haritası, özellikle motor boyutu, silindir sayısı ve yakıt tüketimi ölçümleri olmak üzere temel sayısal özellikler arasında güçlü ilişkiler olduğunu göstermektedir. Bu, model performansını etkileyebilecek çoklu doğrusallığa işaret ediyor ve daha iyi yorumlanabilirlik için özellik seçiminde yardımcı oluyor.

öğrenme sürecini etkiler. 2,6'dan büyük bir z puanına sahip veri noktaları aykırı değerler olarak ilan edildi ve elendi, böylece modelin temiz veriler üzerinde eğitilmesi sağlandı.

$$Z_{Ben} = \frac{X_{Ben} - \mu}{\sigma} \quad (3)$$

Nerede X_{Ben} bireysel bir veri noktasıdır, μ verilerin ortalamasıdır ve σ standart sapmadır.

- **Kategorik Özellik Kodlaması:** Kategorik değişkenleri (marka, model, araç sınıfı, şanzıman ve yakıt türü gibi) modele uygun sayısal gösterimlere dönüştürmek için önce tek sıcak kodlamayı kullandık. Bu yaklaşım her kategoriye ikili sütunlara bölerek modelin bu değişkenlerden etkili bir şekilde öğrenmesini sağlar. Ancak, her kategori için ortalama hedef değerini hesaplayan ve bunu ortalama değerlerle değiştiren hedef kodlamayı da değerlendirdik. Hedef kodlama boyutsallığı azaltılabilir de, tek sıcak kodlamanın modellerimizdeki SHAP değerlerinin yorumlanabilirliğini iyileştirdiğini keşfettik.
- **Normalizasyon ve Ölçekleme:** Her özelliğin modelin performansına eşit katkıda bulunmasını sağlamak için, sayısal özellikler min-maks ölçeklendirildi. Bu ölçeklendirme yöntemi, her özelliği ortak bir aralığa (0 ile 1) dönüştürerek, değişen birimlerin ve büyüklüklerin etkisini azaltır. Bu, özellikle farklı ölçeklere sahip yakıt tüketimi ve motor boyutu gibi özellikler için çok önemlidir. Min-maks ölçeklendirme denklemi şudur:

$$X_{\text{ölçeklendirilmiş}} = \frac{X - X_{\text{dakika}}}{X_{\text{maksimum}} - X_{\text{dakika}}} \quad (4)$$

Neresi $X_{maksimum}$ Ve X_{dakika} sırasıyla minimum ve maksimum değerlerdir.

Özetle, veri mühendisliği süreci kapsamlıydı ve modelin tahmin yeteneklerini geliştirmeyi amaçlıyordu. Veri hazırlamada kullanılan yöntemleri ve bunların veri kümesi üzerindeki etkilerini ayrıntılı olarak açıklayarak, bu tekniklerin genel analiz ve modelleme çabalarına nasıl katkıda bulunduğuna dair daha net bir anlayış sağlıyoruz.

Veri kümesinin bölünmesi ve doğrulanması

Bu çalışmada modelin performansı ve sağlamlığı 5 katlı çapraz doğrulama tekniği kullanılarak titizlikle değerlendirildi. Bu yaklaşım modeli görülmemiş verilere başarılı bir şekilde genelleştirerek aşırı uyum olasılığını azaltır ve bulgularımızın doğruluğunu artırır. Veri seti sistematik olarak beş eşit bölüme ayrıldı ve şu şekilde gösterildi: D_1, D_2, D_3, D_4, D_5 . Çapraz doğrulama sürecinin her yinelenmesinde, bu bölümlerden dördü modeli eğitmek için kullanıldı ve kalan bölüm doğrulama kümesi olarak hizmet etti. Bu süreç matematiksel olarak aşağıdaki gibi temsil edilebilir:

$$\text{Eğitim Seti} = D_{Ben} \quad \text{için } Ben \in \{1, 2, 3, 4, 5\} \quad (5)$$

$$\text{Doğrulama Seti} = D_j \quad \text{için } j \in \{1, 2, 3, 4, 5\}, \quad j \neq \text{Ben} \quad (6)$$

Bu çapraz doğrulama prosedürü, her alt kümenin doğrulama kümesi olarak bir kez kullanıldığından emin olmak için beş kez tekrarlandı. Genel süreç aşağıdaki gibi özetlenmiştir:

1.Tekrar 1:

- Eğitim D_2, D_3, D_4, D_5
- Doğrulama açık D_1

2.Tekrar 2:

- Eğitim D_1, D_3, D_4, D_5
- Doğrulama açık D_2

3.Tekrar 3:

- Eğitim D_1, D_2, D_4, D_5
- Doğrulama açık D_3

4.Tekrar 4:

- Eğitim D_1, D_2, D_3, D_5
- Doğrulama açık D_4

5.5. Tekrar:

- Eğitim D_1, D_2, D_3, D_4
- Doğrulama açık D_5

5 katlı çapraz doğrulama yöntemi, birden fazla veri bölümünü test ederek model genellemenin daha meşru bir tahminini sağlar ve böylece aşırı uyum olasılığını azaltır. Beş yinelemenin tamamında performans ölçümlerini ortalama alarak, modelin performansını kapsamlı bir şekilde değerlendirdik. Bu yaklaşım, bulguların belirli bir eğitim-test bölünmesinden aşırı derecede etkilenmemesini sağlayarak, modelin öngörücü yeteneklerinin daha güvenilir bir değerlendirmesine sunar.

Model yapımı

Derin öğrenme, yapay sinir ağlarını kullanan makine öğrenmesinin bir alt kümesidir ve verilerdeki karmaşık desenleri ve ilişkileri keşfetmek için yararlı bir yöntemdir.⁵³ Derin öğrenme modelleri, ham verilerden anlamlı özellikleri otomatik olarak çıkarmalarına olanak tanıyan, birbirine bağlı nöronların çok sayıda katmanından oluşması bakımından tipik makine öğrenme algoritmalarından farklıdır.⁵⁴ Derin öğrenme modelleri özellikle CO'da faydalı olabilir: emisyon tahmini, araç özellikleri ve emisyonlar arasındaki doğrusal olmayan ilişkileri yönetme kapasiteleri nedeniyle. Çok katmanlı mimarileri nedeniyle, derin öğrenme modelleri bu karmaşık etkileşimleri geleneksel makine öğrenme modellerinden daha verimli bir şekilde yakalayabilir, bu da bu tür karmaşıklıkların ele alınmasını zorlaştırır.⁵⁵ CO gibi regresyon problemleri için çeşitli derin öğrenme mimarileri uygundur: emisyon tahmini.⁵⁶ Bu bölümde önerilen mimari ve geliştirme prosedürleri sunulmaktadır.

Önerilen model geliştirme

Bu çalışma CO₂'yu tahmin etmek için yeni bir yaklaşım ortaya koyduz.Araç niteliklerinden kaynaklanan emisyonlar. Çok katmanlı algılayıcı (MLP) mimarisi kullanarak hafif bir derin öğrenme modeli oluşturduk. Sinir ağı olan MLP'ler

temeller, birbirine bağlı nöronal katmanlardan oluşur. Bu yöntem, giriş özellikleri ile hedef değişken (CO) arasındaki karmaşık bağlantıları belirlemek için derin öğrenmenin gücünden yararlanır (emisyonlar).

Giriş Biçimi: Önerilen derin öğrenme modeli için giriş verileri, Tablo'da açıklandığı gibi araç nitelikleriyle ilgili birden fazla özelliğe sahip bir veri kümesinden oluşur. Bu özellikler, Marka (araç üreticisi), Model, Araç Sınıfı (VC), Motor Hacmi (ES), Silindir Sayısı ve Yakıt Tipi (FT) gibi niteliklerin yanı sıra, şehir içi yakıt tüketimi (FCCity), otayol yakıt tüketimi (FCH) ve kombine yakıt tüketimi (FCcomb) gibi çeşitli ölçümleri içerir.

Bu çalışmada, her biri doğrusal olmayanlık için ReLU aktivasyonuna sahip, yoğun şekilde bağlanmış çoklu katmanlar kullanıldı. Tasarım, bir giriş katmanından, her biri 128, 64 ve 32 nörona sahip üç gizli katmandan ve son çıktı katmanında tek bir regresyon (doğrusal aktivasyon) nöronundan oluşur.

Model, özellikle büyük ölçekli modellerde etkinliğiyle bilinen oldukça verimli bir araç olan Adam optimizier kullanılarak oluşturulmuştur. Ortalama karesel hata (MSE) kayıp fonksiyonu da kullanılmıştır. Tasarım, TensorFlow'un Keras Uygulama Programlama Arayüzü (API) kullanılarak kolaylaştırılmıştır. Şekil 8 Önerilen derin öğrenme modelinin mimarisinin görsel bir temsiliyi sağlar.

Önerilen modelin amacı CO₂'yi tahmin etmektir. Sağlanan veri setini kullanarak emisyonlar. Formüle edilmiş haliyle form, model mimarisi şu şekildedir:

$$\text{Giriş: } X_{\text{tren}} \quad (\text{şekil: } (n, m)) \quad (7)$$


$$\text{Gizli 1: } H_{(1)} = \text{ReLU} \left(X_{\text{tren}} \cdot B_{(1)} + B_{(1)} \right) \quad (\text{şekil: } (N, 128)) \quad (8)$$

$$\text{Gizli 2: } H_{(2)} = \text{ReLU} \left(H_{(1)} \cdot B_{(2)} + B_{(2)} \right) \quad (\text{şekil: } (N, 64)) \quad (9)$$

$$\text{Gizli 3: } H_{(3)} = \text{ReLU} \left(H_{(2)} \cdot B_{(3)} + B_{(3)} \right) \quad (\text{şekil: } (N, 32)) \quad (10)$$

$$\text{Çıktı: } \text{Eve tahmin} = H_{(3)} \cdot B_{(4)} + B_{(4)} \quad (\text{şekil: } (N, 1)) \quad (11)$$

Verilen sinir ağı mimarisinde, girdiden çıktıya kadar tüm süreç, her biri belirli bir katmanı veya işlemi ayrıntılandıran çeşitli denklemler aracılığıyla izlenebilir. Denklemden tanımlanan girdi katmanı (7), eğitim verilerini kullanır. X_{tren} sahip olan örnekler ve özellikler. Denklem (8) ilk gizli katmanı tanımlar. $H_{(1)}$ ReLU aktivasyon fonksiyonu, girdilerin ağırlıklarla birleştirilmesinden sonra kullanılır. $B_{(1)}$ ve önyargılar $B_{(1)}$



Şekil 8. Önerilen CarbonMLP Modelinin Mimari Diyagramı: Üç gizli katmana (sırasıyla 128, 64 ve 32 nöron) sahip giriş katmanını ve tek bir regresyon nöronuna sahip çıkış katmanını gösterir. Her katman, doğrusal aktivasyon kullanan son çıkış katmanı hariç, ReLU aktivasyon fonksiyonlarını kullanır.

. Sonraki gizli katmanlarda daha fazla dönüşüm meydana geldi. İkinci gizli katman H_2 Denklem (9) ile temsil edilir, yine ReLU fonksiyonunu kullanarak. Ancak, ilk gizli katmandan gelen çıktılar yeni bir ağırlık kümesiyle işlenir B_2 ve önyargılar B_2 . Üçüncü gizli katman, Denklem (10) de ayrıntılı olarak açıklandığı gibi benzer bir deseni izledi. B_3 ve önyargılar B_3 . Ağ çıktısı E_{tahmin} tahmin ediyor Ortak emisyonları, Denklem (11) kullanılarak hesaplandı. Bu çıktı, son ağırlık kümesini kullanarak üçüncü gizli katmanın aktivasyonunun işlenmesinin sonucudur. B_4 ve önyargılar B_4 . Her adım ağırlıklara dayanır B_{Ben} ve önyargılar B_{Ben} . Her katman için, ağırlık öğrenme ve girdi verilerine dayalı doğru tahminler yapma yeteneğini ileri taşımak.

Optimize edilmiş parametreler

Derin öğrenme modelimiz, güvenilir ve tutarlı CO sağlamak için çeşitli hiperparametreler kullanılarak kapsamlı bir inceleme yapıldı. Birden fazla yapılandırmayı değerlendirdikten sonra, önerilen mimari için en uygun ayarları belirledik. Seçilen tasarım, doğrusal olmayanlık için ReLU aktivasyonunu kullanır ve verimlilik ile karmaşıklık arasında etkili bir denge kuran üç gizli katmandan oluşur. Ortalama Karesel Hata (MSE) kayıp fonksiyonu, regresyon hedeflerimizle iyi uyum sağlarken, Adam optimize edici eğitim verimliliğini artırır.

Aşırı uyumu azaltmak için, model, verilerden etkili öğrenmeyi garantilemek için 5 katlı çapraz doğrulama yaklaşımı kullanılarak 8'lik bir toplu boyutla 100 dönem için eğitildi. Bu dikkatlice seçilmiş hiperparametreler, CO'yu tahmin etmede modelin sağlamlığını ve doğruluğunu önemli ölçüde iyileştirdi. Tablo 4 Model optimizasyon sürecinde yer alan çeşitli hiperparametreleri ayrıntılı olarak açıklayarak, performansı optimize etmek için kullanılan stratejilere ilişkin kapsamlı bir genel bakış sağlar.

Açıklanabilir AI yorumu

açıklanabilir AI (XAI) yöntemleri, modellerin yorumlanabilirliğini artırmak ve tahminleri etkileyen unsurlara ilişkin içgörüler sağlamak için tasarlanmıştır. Bu çalışmada, özelliklerin CO üzerindeki etkisine ilişkin içgörü elde etmek için sağlam XAI tekniklerini, özellikle SHapley Eklemeli açıklamaları (SHAP) kullandık. SHAP Özeti, şelale, kuvvet ve bağımlılık grafikleri dahil olmak üzere bir dizi görselleştirme kullandık.

SHAP (SHapley Katkısal Açıklamaları)

SHAP değerleri, her birinin katkısını nicelleştirerek bireysel tahminleri açıklamak için sağlam bir çerçeve sunar. $SHAP_{\text{Ben}}$ modelin çıktısına özellik. Özellik için SHAP değeri aşağıdaki denklem kullanılarak hesaplanır:

$$SHAP_{\text{Ben}} = \phi_0(F) + \sum_{j=1}^M \frac{(M-j)!j!}{M!} (\phi_j(F) - \phi_{j-1}(F)) \quad (12)$$

Neresi; $SHAP_{\text{Ben}}$ SHAP değerini temsil eder $SHAP_{\text{Ben}}$ özellik, $\phi_0(F)$ model çıktısının temel katkısını belirtir, F Giriş özelliklerini öngörülen CO'ya eşleyen önerilen CarbonMLP modelidir. Özelliklerin toplam sayısıdır.

Özelliklerin katkısını hesaplamak için SHAP yöntemi, özellik değerlerinin ve ilgili çıktılarının tüm olası kombinasyonlarını dikkate alarak, modelin tahmininin girdi özellikleri arasında adil bir dağıtımını sağlar. Bu, her özelliğin katkısının diğer tüm özellikler bağlamında değerlendirildiği ve etkileşimlerin düzgün bir şekilde hesaba katıldığı anlamına gelir. Bu çalışmada kullanılan özellikler ve açıklamaları Tablo'da listelenmiştir. Bunlar, araç özelliklerinin CO'yu nasıl etkilediğini anlamak için önemli olan marka (araç üreticisi), model, araç sınıfı, motor hacmi, silindirler ve yakıt tipi gibi niteliklerin yanı sıra çeşitli yakıt tüketimi ölçümlerini (şehir, otoyol, kombine) içerir. SHAP değeri, her bir özelliğin model çıktı tahminleri üzerindeki etkisini açıklar. SHAP değerleri yalnızca bireysel özelliklerin katkılarını nicelleştirmekle kalmaz, aynı zamanda araç özelliklerinin emisyonları nasıl etkilediğine dair daha derin bir anlayışa da olanak tanır. Ortak emisyon

Hiperparametre	Değer
Gizli Katman Sayısı	3
Gizli Katman Başına Nöron Sayısı	128, 64, 32
Aktivasyon Fonksiyonu	ReLU (Gizli Katman) Doğrusal (Çıkış Katmanı)
Optimizasyoncu	Adam
Kayıp Fonksiyonu	Ortalama Karesel Hata
Çağlar	100
Toplu Boyut	8
Doğrulama Bölmesi	5-Katlı

Tablo 4 Önerilen CarbonMLP modelinin optimize edilmiş hiperparametreleri.

tahminler. Bu metodoloji model şeffaflığını artırır ve paydaşların analize dayalı bilinçli kararlar almasına yardımcı olur.

SHAP özet grafiği

SHAP özet grafiği, her özelliğin ortalama mutlak SHAP değerinin önemine ilişkin genel bir görünüm sağlar. Bu, önemli öngörücülerin ve model öngörülerindeki özel etkilerinin tanımlanmasını sağlayarak model yorumlama ve doğrulamaya yardımcı olur. Denklemde (13), Nerede N özelliklerin sayısını temsil eder. Grafik aşağıdaki gibi hesaplandı:

$$\text{SHAP Özeti Grafiği} = \sum_{Ben=1}^N |ŞAP_{Ben}| \quad (13)$$

SHAP şelale arsası

SHAP şelale grafiği, her bir özelliğin temel değerdeki değişime nasıl katkıda bulunduğunu göstererek, bireysel tahminlere ilişkin ayrıntılı içgörüler sunar. Bu, model çıktılarını ve olası geliştirme alanlarını etkileyen değişkenleri vurgulayarak belirli tahminleri yorumlamayı kolaylaştırır. Denklemden (14), aşağıdaki şekilde hesaplanır:

$$\text{SHAP Şelale grafiği} = \text{Temel Değer} + \sum_{Ben=1}^N \varphi_{APBen} \quad (14)$$

SHAP kuvvet grafiği

SHAP kuvvet grafiği, her bir özelliğin tek bir tahmini nasıl etkilediğini gösterir ve modelin belirli bir örnek için çıktısı nasıl belirlendiğini gösterir. Bu, özellik etkilerinin incelenmesine, her birinin nihai tahmine nasıl katkıda bulunduğunun vurgulanmasına ve model şeffaflığının iyileştirilmesine olanak tanır. Denklemden (15), kuvvet grafiği için şu şekilde hesaplanır:

$$\text{SHAP Kuvvet grafiği} = \text{Temel Değer} + \sum_{Ben=1}^N \varphi_{AP_{Ben}} \quad (15)$$

SHAP bağımlılık grafiği

SHAP bağımlılık grafiği, diğer değişkenlerle ilişkileri göz önünde bulundurur ve bir özellik ile model çıktı tahmini arasındaki ilişkiyi gösterir. Karmaşık desenlerin ve doğrusal olmayan ilişkilerin keşfine yardımcı olarak özellik davranışı ve model performansı hakkında önemli içgörüler sağlar. Grafik, Denklem (kullanılarak hesaplanmıştır¹⁶):

$$\zeta / k t P \text{ redüksiyonu} = f(x) + \sum_{Ben=1}^N \zeta A P_{Ben} \quad (16)$$

Değerlendirme ölçütleri

Değerlendirme metrikleri, pratik uygulamadaki tahmin modellerinin etkinliğini ve performansını değerlendirmek için çok önemlidir. Bu bileşen, önerilen modelin performansını değerlendirmek için kullanılan metrikleri içeriyordu. Metrikler arasında Ortalama Karesel Hata (MSE), Kök Ortalama Karesel Hata (RMSE), R-kare (R2) ve Ortalama Mutlak Yüzde Hata (MAPE) yer alıyordu.

Ortalama Kareysel Hata (MSE)

Modelin etkinliği, tahmin edilen ve gözlenen sonuçlar arasındaki ortalama karesel farkı ölçen Ortalama Karesel Hata (MSE) kullanılarak değerlendirildi. Bu hesaplama aşağıdaki denklemle ifade edilir:

$$\text{MSE} = \frac{1}{N} \sum_{Ben=1}^N (y_{Ben})^2 \quad (17)$$

Neresi, N örnek sayısı, ve_{Ben} hedef değeri temsil eder ve $\hat{y}_{Ben}$ sırasıyla hedef değeri belirtir.

Kök Ortalama Karesel Hata (RMSE)

Ortalama Karesel Hata'nın (MSE) karekökü, aynı zamanda Kök Ortalama Karesel Hata (RMSE) olarak da bilinir, gözlenen ve tahmin edilen sonuçlar arasındaki ortalama farktır. RMSE aşağıdaki şekilde hesaplanmıştır:

$$RMS = \sqrt{\frac{1}{N} \sum_{Ben=1}^N (V_{Ben})^2} \quad (18)$$

$R \text{ kare } (R_2)$

R kare (R^2) istatistiği, bağımsız değişkenlerin bağımlı değişkendeki varyansı ne ölçüde açıkladığını gösterir. Sıfırdan bire kadar giden ölçekte, daha yüksek sayılar daha iyi bir model uyumunu gösterir. R^2 formül şu şekildedir:

$$R_2 = 1 - \sum_N \frac{\sum (\frac{y_{Ben=1}^{velen} - \hat{y}_{Ben}}{\sqrt{Ben}})^2}{\sum (\sqrt{Ben})^2} \quad (19)$$

Neresi, $\bar{y}$ gözlenen değerlerin ortalamasını temsil eder.

Ortalama Mutlak Yüzde Hata (MAPE)

Gerçek ve beklenen değerler arasındaki ortalama yüzdelik değişim, gerçek değer in büyüklüğünün tahminlerinin doğruluğuna ışık tutan Ortalama Mutlak Yüzde Hatası (MAPE) ile ölçülür. Şu şekilde hesaplanır:

$$MAPE = \frac{1}{N} \sum_{Ben=1}^N \frac{|y_e - \hat{y}|}{\frac{y_{Ben} - y_{Ben}}{y_{Ben}}} \times 100 \% \quad (20)$$

Neresi, ve_{Ben} gerçek değeri belirtir, $\hat{y}_{Ben}$ öngörülen hedef değeri Ben_{inci} örnek, N örnek sayısı.


Deneysel sonuçlar

Donanım kurulumu ve model eğitimi

Önerilen derin öğrenme modeli, işleme verimliliğini artırmak için bir Kaggle notebook ortamında güçlü bir GPU P100 hızlandırıcısı kullanılarak eğitildi. Bu platform, derin sinir ağı eğitimi de dahil olmak üzere hesaplama açısından yoğun görevler için ölçeklenebilir bir çözüm sunar. Model eğitimi için Keras API kullanıldı.

Önceden işlenmiş veri grupları eğitim sırasında modele beslendi ve Ortalama Karesel Hata (MSE) kayıp fonksiyonunu en aza indirmek için Adam optimize edici kullanıldı. Çeşitli hiperparametreler ince ayarlandıktan sonra, en uygun değerler seçildi: 8'lik bir grup boyutu ve sağlam genellemeyi sağlamak ve aşırı uyumu önlemek için 5 katlı çapraz doğrulama ile 100 dönem için eğitim. Bu dikkatlice tasarlanmış eğitim prosedürü, modelin araç nitelikleri ile CO yarındaki karmaşık ilişkileri etkili bir şekilde yakalamasını sağlarzemisyonları, son derece güvenilir tahmin yetenekleriyle sonuçlanır. Eğitilebilir parametre sayısı ile ölçülen modelin zaman içindeki karmaşıklık Şekil'de gösterilmiştir9.

Eğitim ilerledikçe, Şekil 9'daki iki dönemde eğitilebilir parametre sayısında önemli bir başlangıç düşüşü gösterir, ardından sonraki dönemlerde stabilizasyon görülür. Bu, modelin



Şekil 9. CarbonMLP modelinin zaman içindeki model karmaşıklığı.

araç nitelikleri ile CO arasındaki ilişkileri en iyi şekilde temsil edecek şekilde hızla ayarlandızemisy onları, yapıyı fazla karmaşıklıktan koruyarak.

Model karmaşıklığındaki bu kademeli azalma, aşırı uyumu önlemeye yardımcı olur ve modelin gereksiz parametreleri artırmadan verilerden etkili bir şekilde öğrendiğini gösterir. İlk birkaç dönemdeki eğitilebilir parametrelerdeki mütevazı artış, modelin karmaşık desenleri temsil etme yeteneğini yansıtır ve ardından modelin sağlamlığını güçlendirerek sabitlenir.

Hesaplama verimliliği karşılaştırması

Önerilen CarbonMLP modelini seçmemizi daha da haklı çıkarmak için, daha karmaşık LSTM ile ayrıntılı bir hesaplama verimliliği karşılaştırması gerçekleştirdik⁵⁷ve BiLSTM⁵⁸modeller. Karşılaştırma, eğitim süresi, çıkarım süresi, bellek kullanımı, parametre sayısı ve gecikme gibi önemli performans ölçülerine dayanıyordu. LSTM ve BiLSTM modellerini seçtik çünkü bunlar hem zaman zamanlı ve büyük ölçekli dağıtım için daha uygun hale getirir. CarbonMLP için çıkarım süresi LSTM'den %34,8 ve BiLSTM'den %25 daha kısaydı ve bu da üretim ortamlarındaki hesaplama verimliliğini göstermektedir.

Eğitim ve çıkarım zamanı

Önerilen CarbonMLP modeli, LSTM ve BiLSTM ile karşılaştırıldığında eğitim ve çıkarım sürelerini önemli ölçüde azaltır. Bu azalmalar CarbonMLP'yi gerçek zamanlı ve büyük ölçekli dağıtım için daha uygun hale getirir. CarbonMLP, LSTM'den %54,7 ve BiLSTM'den %43,5 daha az eğitim süresi gerektirir. Benzer şekilde, CarbonMLP için çıkarım süresi LSTM'den %34,8 ve BiLSTM'den %25 daha kısaydı ve bu da üretim ortamlarındaki hesaplama verimliliğini göstermektedir.

Bellek kullanımı ve model boyutu

Bellek kullanımı ve model boyutu, sınırlı hesaplama kaynaklarına sahip bağlamlarda kritik öneme sahiptir. CarbonMLP, her iki ölçümde de önemli ölçüde azaltılmış bir ayak izine sahipti. CarbonMLP, LSTM ve BiLSTM'den %3 daha az bellek tüketir. Ek olarak, CarbonMLP'nin model boyutu, LSTM'den %76,6 ve BiLSTM'den %88,7 daha küçüktü ve bu da onu sınırlı depolama kapasitesine sahip cihazlarda dağıtım için oldukça verimli hale getiriyordu.

Gecikme ve toplu işlem süresi

Gecikme ve toplu işlem süreleri, modellerin hızlı tahminler yapması için kritik öneme sahiptir. CarbonMLP bu alanlarda LSTM ve BiLSTM'den daha iyi performans gösterir. Önerilen CarbonMLP, LSTM ile karşılaştırıldığında %61,5 ve BiLSTM ile karşılaştırıldığında %31,8 oranında gecikme azaltması sunar. Benzer şekilde, toplu işlem süresi LSTM'den %19 ve BiLSTM'den %15 daha hızlıdır ve bu da yüksek verimli ortamlarda verimliliğini daha da kanıtlamaktadır.

Model karmaşıklığı ve parametre sayısı

Daha az parametrelili bir modelin eğitimi, dağıtımı ve bakımı daha kolaydır, özellikle de sınırlı hesaplama gücüne sahip durumlarda. CarbonMLP, rekabetçi bir performans sağlarken hafif olacak şekilde geliştirilmiştir. CarbonMLP, LSTM modelinden %76,8 ve BiLSTM modelinden %88,8 daha az parametre içeriyordu ve bu da onu performanstan ödün vermeden model karmaşıklığı açısından oldukça verimli hale getiriyordu.

Performans değerlendirilmesi

Son olarak, modellerin tahmin performansı Ortalama Karesel Hata (MSE) temelinde değerlendirildi ve önerilen CarbonMLP bu metrikte hem LSTM hem de BiLSTM modellerini geride bıraktı. Önerilen CarbonMLP, azaltılmış MSE değeriyle kanıtlandığı gibi, tahmin doğruluğu açısından hem LSTM hem de BiLSTM modellerini geride bıraktı. Bu, modelin nispeten basitleştirilmiş gelişimine rağmen yararlılığını göstermektedir.

Hesaplama verimliliği karşılaştırması, önerilen CarbonMLP modelinin eğitim ve çıkarım süresi, bellek kullanımı, gecikme ve model boyutu açısından oldukça verimli olduğunu ve yine de rekabetçi tahmin performansı sağladığını ortaya koymaktadır. CarbonMLP'nin yetenekleri onu gerçek dünya CO için en iyi seçim haline getirirz emisyon tahmin görevleri, özellikle sınırlı hesaplama kaynaklarına sahip bağlamlarda.

Metrik	Önerilen MLP Modeli	LSTM Modeli	BiLSTM Modeli
Eğitim Süresi (saniye)	1.96	4.33	3.47
Çıkarım Süresi (saniye)	0,15	0,23	0,20
Bellek Kullanımı (MiB)	137.15	141,39	141,39
Gecikme (saniye)	0,15	0,39	0,22
Toplu İşleme Süresi (saniye)	0,17	0,21	0,20
Ortalama Karesel Hata (MSE)	0,0002	0,0003	0,0004
Model Boyutu (MB)	3.25	13.90	28,76
Parametre Sayısı	281.601	1.212.321	2.506.561

Tablo 5. Hesaplama verimliliği ve performans karşılaştırması.

Önerilen modelin performans değerlendirilmesi

Önerilen derin öğrenme modeli, CO arasındaki karmaşık ilişkileri tam olarak temsil edebilirzemisyonlar ve araç nitelikleri. 5 katlı çapraz doğrulama gerçekleştirildikten sonra mükemmel performans ölçümleri elde edildi. Ortalama R kare değeri 0,9938'di ve %99,4'lük bir açıklanan varyasyonu, 0,0002'lik son derece düşük bir Ortalama Karesel Hata (MSE) ve 0,0142'lik bir Kök Ortalama Karesel Hata (RMSE) ile gösterdi. Ek olarak, modelin Ortalama Mutlak Yüzdelik Hatası (MAPE) %2,5'ti ve bu da tahminlerin ortalama olarak gerçek değerlerin %2,6'sı içinde olduğunu gösteriyordu.

Bu metrikler, Şekil'de gösterilen performans eğrisinde özetlenmiştir.13R-kare, MSE, RMSE ve MAPE'nin gösterildiği, modelin öngörü doğruluğunun ve tüm çapraz doğrulama katlamaları arasında genelleme yapma yeteneğinin bütünsel bir görünümünü sağlayan.

Sonuçlar, Şekil'de gösterilen eğitim ve doğrulama kaybı eğrileri tarafından daha da desteklenmektedir.10, beş katın her biri için kayıp eğilimlerini gösteren. Bu eğriler arasındaki tutarlılık, modelin aşırı uyum olmadan doğrulama kümeleri arasında genelleme yapma yeteneğini vurgular. Şekil11Bu kayıp eğrilerinin bir özetini sunarak, hem eğitim hem de doğrulama kayıplarının eğitim süreci boyunca istikrarlı bir şekilde azaldığını daha da göstermektedir.

Ayrıca, modelin doğruluğu Şekil 2'deki gerçek ve tahmin edilen grafikte doğrulandı.12Veri noktalarının çapraz çizgi etrafında sıkı bir şekilde kümelendiği, tahmin edilen ve gerçek CO arasındaki yüksek korelasyonun güçlendirildiği yer2 emisyonlar. Tahminine kıyasla önemli ölçüde daha düşük gerçek değere sahip izole bir aykırı değer gözlemlenirken, bu durum veri anomalilerine, yeterince temsil edilmeyen desenlere veya modelin uç durumları yakalamadaki sınırlamalarına atfedilebilir. Önemlisi, tahmin edilen değerler normalleştirmeden sonra orijinal ölçeklerine geri döndürüldü ve performans ölçümlerinin gerçek CO'yu doğru şekilde yansıttığından emin olunduzemisyonları. Bu ikna edici performans göstergeleri, içgörülü görselleştirmelerle bir araya gelerek, modelin sağlamlığını ve CO'daki pratik uygulamalar için potansiyelini vurgularzemisyon tahmin görevleri.

"CarbonMLP" modelinin CO2 tahminindeki etkinliğini tam olarak değerlendirmek içinzemisyonlar için, Şekil 2'de gösterildiği gibi bir Taylor diyagramı kullandık14. Bu yararlı resim üç kritik metriği özetlemektedir: korelasyon katsayısı (R), standart sapma (SD) ve merkezlenmiş kök ortalama kare farkı (RMSD). R, beklenen ve gözlenen emisyonlar arasındaki doğrusal ilişkiyi belirtir ve bir değeri tam uyumu gösterir. Korelasyon katsayısı (R) aşağıdaki şekilde hesaplanmıştır:

$$D = \sqrt{\frac{\sum_{Ben=1}^N (x_{Ben} - \bar{x})(y_{Ben} - \bar{y})}{\sqrt{\sum_{Ben=1}^N (x_{Ben} - \bar{x})^2 \sum_{Ben=1}^N (y_{Ben} - \bar{y})^2}}} \quad (21)$$

Neresi, x_{Ben} ve y_{Ben} sırasıyla bireysel olarak tahmin edilen ve gözlenen değerleri temsil eder. $\bar{x}$ ve $\bar{y}$ ilgili araçları belirtin.

Orijinden radyal uzaklık gözlenen standart sapmaya (SD) yakın olmalıdır, aşağıdaki şekilde hesaplanır:

$$SD = \sqrt{\frac{1}{N} \sum_{Ben=1}^N (x_{Ben} - \bar{x})^2} \quad (22)$$

Son olarak, veri noktası ile merkezlenmiş kök ortalama kare farkı (RMSD) için referans noktası arasındaki daha küçük açı, emisyonlardaki dögüsel desenlerin iyi bir şekilde hizalandığını yansıtır. Merkezlenmiş RMSD aşağıdaki gibi hesaplanmıştır:


$$RMS = \sqrt{\frac{1}{N} \sum_{Ben=1}^N (x_{Ben} - y_{Ben})^2} \quad (23)$$

Şekil 2'deki Taylor diyagramında "CarbonMLP" modelimizin veri noktasının tam yerini analiz ederek önemli bilgiler elde edebiliriz.14. İdeal olarak, veri noktası, tahminler ve gözlemler arasında yüksek düzeyde bir uyum olduğunu gösteren bir korelasyon katsayısı gösteren daireye yakın olmalıdır. Ayrıca, orijinden radyal uzaklık, bildirilen standart sapmaya benzer olmalı ve bu da modelin değişkenliği yeterince yakaladığını gösterir. Son olarak, veri noktası ile merkezlenmiş RMSD için referans noktası arasındaki daha düşük bir açı, emisyonlardaki dögüsel desenlerin iyi bir şekilde senkronize olduğunu gösterir. Taylor diyagramının bu özelliklerini inceleyerek, "CarbonMLP" modelinin CO tahmin etme yeteneğini doğru bir şekilde değerlendirebiliriz.2


otomobillerden kaynaklanan emisyonlar.

Model performansının mevcut yaklaşımlarla karşılaştırılması


CO'yu tahmin etmedezemisyonları, önerdiğimiz derin öğrenme modeli karmaşık derin öğrenme mimarilerini ve geleneksel makine öğrenme algoritmalarını geride bıraktı. Tabloda gösterilen performans ölçütleri6Önerilen model, 0,9938'lik en yüksek R-kare değerine ve 0,0002'lik en düşük MSE değerine sahiptir; bu, modelin yüksek doğruluğunu ve tahmin edilen değerlerin gözlenen gerçek CO2 ile daha yüksek korelasyonunu gösterir.2 emisyonlar.




(a) Training and Validation Loss Curve for Fold 1.




(b) Training and Validation Loss Curve for Fold 2.



(c) Training and Validation Loss Curve for Fold 3.




(d) Training and Validation Loss Curve for Fold 4.




(e) Training and Validation Loss Curve for Fold 5.

Şekil 10. 5 katlı çapraz doğrulama sırasında beş katın her biri için eğitim ve doğrulama kaybı eğrileri. Her alt grafik, hem eğitim hem de doğrulama veri kümeleri için dönemler boyunca kayıp fonksiyonunun eğilimini gösterir ve tutarlı yakınsamayı ve modelin farklı katlar arasında genelleme yeteneğini gösterir. Kayıp eğrileri, etkili eğitimi ve önemli bir aşırı uyumu gösteren istikrarlı bir azalma gösterir.

Makine öğrenimi modülünde, performanslarını karşılaştırmak için Karar Ağaçları, K-En Yakın Komşular (KNN), Destek Vektör Makineleri (SVM) ve XGBoost gibi çeşitli algoritmalar uygulandı. Bu algoritmalar analizde farklı roller oynadı. Karar Ağaçları, araç özellikleri ve CO arasındaki hem doğrusal hem de doğrusal olmayan ilişkileri ele alabilen basit, yorumlanabilir modellerdir. Verileri daha küçük, daha yönetilebilir parçalara bölerek, hangi özelliklerin farklı emisyon seviyelerine yol açtığına dair sezgisel bir anlayış sağlarlar. Ancak, tek başlarına kullanıldıklarında verilerdeki karmaşık örüntüleri yakalama esnekliğinden yoksun olabilirler. K-En Yakın Komşular (KNN) regresörü, özellik alanındaki veri noktalarının yakınlığını ölçerek çalışır.




Şekil 11 CarbonMLP modelinin ortalama eğitim ve doğrulama kaybı eğrisi.




Şekil 12 CarbonMLP modelinin gerçek ve öngörülen çizimi.

Özellikler arasındaki ilişkinin doğrusal olmadığı senaryolarda kullanışlıdır. Ancak, KNN'nin performansı, Tablo'da nispeten daha yüksek MSE ve daha düşük R karesi ile görüldüğü gibi, yüksek boyutlu verilerle veya büyük veri kümeleriyle karşı karşıya kaldığında düşebilir. 6 Destek Vektör Makinesi (SVM) regresörü, veri noktalarına en iyi uyan ve tahmin hatasını en aza indiren bir hiper düzlemi bulmayı amaçlar. Bazı durumlarda etkili olsa da, SVM CO'nun karmaşıklıklarını ele almakta zorlandı Bu çalışmada, derin öğrenme yaklaşımlarına kıyasla daha yüksek hatalara yol açan emisyon verileri kullanılmıştır. Oldukça verimli bir gradyan artırma algoritması olan XGBoost, karmaşık, doğrusal olmayan problemler için oldukça uygundur. Nispeten güçlü bir performans gösterdi ancak aşırı uyum sağlamadan verilerdeki daha derin desenleri yakalayamaması nedeniyle önerilen derin öğrenme modelinin gerisinde kaldı.

Bu modeller ayrıca, genellemeyi ve doğruluğu iyileştirmek için Karar Ağaçları, KNN ve XGBoost'un güçlü yönlerini entegre eden bir topluluk yaklaşımında birleştirildi. Bu modellerden gelen tahmin çeşitliliğinden yararlanarak, topluluk, bireysel makineden daha düşük bir MSE (0,0003) ve daha yüksek bir R kare (0,9889) elde etti.



Şekil 13. CarbonMLP modelinin performans eğrisi.



Şekil 14. "CarbonMLP" modelinin performansına ilişkin Taylor diyagramı.

Örnek	MSE	RMSE	R-kare	Akçağa
BiLST	0,0004	0,0199	0,9878	3.24%
LSTM	0,0003	0,0195	0,9883	3.30%
Karar ağacı regresörü	0,0005	0,0234	0,9827	5.69%
K komşu regresörü	0,0006	0,0256	0,9794	5.18%
SVR	0,0026	0,0514	0,9172	11.46%
XGB regresörü	0,0007	0,0280	0,9753	5.07%
Adaboost regresörü	0,0015	0,0394	0,9513	8.10%
Catboost Geriletilici	0,0025	0,0503	0,9207	10.89%
Topluluk (karar ağacı, knn, xgb)	0,0003	0,0187	0,9889	3.19%
Önerilen (CarbonMLP)	0,0002	0,0142	0,9938	%2,59

Tablo 6. Tüm modeller arasında performans karşılaştırması.

öğrenme algoritmaları, önerilen derin öğrenme modelini hala geride bırakmasa da. Sonuçlar, Karar Ağaçları veya KNN gibi bu tür temel tekniklerin tatmin edici tahminler sağlamasına rağmen, CO içindeki faktörlerin doğrusal olmayanlığını kucaklayamadıklarını göstermektedir. emisyon.

Derin öğrenme modülümüzde LSTM ve BiLSTM modellerini kullanırken bu modellerin ardışık veri işlemedeki üstünlüğü dikkate alındı. LSTM modelleri, doğaları gereği dizideki mesafeleri kapsar ve uzun aralıklarla belleği uygular, bu da onları zaman serisi tahmini için uygun hale getirir. Bu, araç özellikleri ile CO arasında bir ilişki kurmak için önemlidir zaman içinde emisyonlar. BiLSTM, kelime dizilerinin geçmiş ve gelecekteki veri noktalarındaki bağlamları yakalayarak ileri ve geri yollarla analiz edilmesi anlamında yukarıdakileri iyileştirir. Bu bölünmüş görünüm, katsayıların önceki ve sonraki değerlerin bir fonksiyonu olabileceği emisyon tahminlerinde en yararlıdır. LSTM ve BiLSTM, sıralı veriler için çalışan en iyi algoritmalar arasında oldukları ve tahmin görevleri için gereken sıralı veriler olduğu için kullanılır. Elde edilen emisyon verileri her zaman otomobilin özellikleri ve mevzuattaki değişiklikler gibi şeylerle ilgili zamansal özelliklere sahiptir. Bu dinamikler bu modeller kullanılarak yakalanabilir ve dolayısıyla CO'nun daha iyi tahminlerini sağlar emisyonlar. Ayrıca, mevcut veri modellerine uyum sağlayabilmesi için veri modeli değişkenliği ile bir tahmin modelinin oluşturulması da önemlidir. Bu, derin öğrenme yaklaşımının bu karmaşık etkileşimleri etkili bir şekilde yakaladığı ve bu nedenle son derece hassas CO elde etmeye yönelik en iyi yaklaşım olduğu önerilen CarbonMLP modelinde belirgindir. gerçek ortamlarda emisyon tahmini.

SHAP kullanarak XAI yorumlama


Gelişmiş derin öğrenme modelinin temel mekanizmasını ve farklı özelliklerin tahminlerini nasıl etkilediğini daha iyi anlamak için (SHAP) değerlerini kullandık. Bu modelden bağımsız teknik, her değişkenin modelin CO'sunu nasıl etkilediğini anlamamızı sağlar emisyon tahminleri. Etkileyici derecede düşük 0,0002'lik Ortalama Karesel Hata (MSE) ve 0,9938'lik yüksek bir R-kare değeriyle, önerdiğimiz model iyi performans gösterdi ve onu SHAP açıklaması için en iyi seçenek olarak belirledi. Her tahminle ilişkili SHAP değerlerini analiz etmek, hangi özelliklerin modelin CO2'si üzerinde en büyük pozitif veya negatif etkiye sahip olduğunu belirlememizi sağlar emisyon tahminleri.

SHAP özet grafiği: CO için küresel özellik önemizemisyon tahmini

Şekildeki SHAP özet grafiği 15 farklı özelliklerin CO'yu nasıl etkilediğine dair kapsamlı bir görünüm sağlar. Tüm veri kümesindeki emisyon tahminleri. Özellikler önemlerine göre sıralandı ve grafik, modelin çıktısı üzerindeki etkilerinin dağılımını gösteriyor. SHAP özet grafiğinin temel unsurları şunlardır:

- Özellik Önemi (Y eksen):** Özellikler önem sırasına göre sıralanmıştır ve en etkili özellikler en üstte listelenmiştir. Bu grafikteki ilk üç özellik şunlardır: *Yakıt Tüketimi Şehir (L/100 km)*, *Yakıt Tüketimi Comb (L/100 km)*, *Ve Yakıt Tüketimi Karayolu (L/100 km)* yakıt tüketimi ölçümlerinin CO'nun kritik tahmin edicileri olduğunu gösteriyor emisyonlar.
- SHAP Değeri (X eksen):** SHAP değerleri her bir özelliğin tahmine katkısını temsil eder. Pozitif SHAP değerleri tahmin edilen CO'yu artırdı emisyonları, negatif SHAP değerleri ise bunu azalttı. 0'lık bir SHAP değeri, o örnek için tahminde hiçbir etki olmadığını gösterir.
- Renk Gradyanı (Özellik Değeri):** Renkler özellik değerlerini temsil eder; mavi düşük değerleri, kırmızı ise yüksek değerleri gösterir. Örneğin, düşük yakıt tüketimi değerleri (mavi) CO2'yi azaltma eğilimindedir tahminleri artırırken, yüksek yakıt tüketim değerleri (kırmızı) tahminleri artırıyor.
- Etki Dağılımı:** Her bir özellik için puanların yayılımı, etkisinde ne kadar çeşitlilik olduğunu gösterir. Şu gibi özellikler: *Yakıt Türü_XVe Silindirler_6* SHAP değerlerinin geniş bir dağılıma sahip olması, bunların etkisinin araç konfigürasyonuna bağlı olarak önemli ölçüde değişebileceğini göstermektedir.

Özet grafik, yakıt tüketim ölçümlerinin, motor hacminin, silindir sayısının, yakıt türünün ve araç sınıfının CO2 emisyonunun en önemli belirleyicileri arasında olduğunu ortaya koymaktadır. emisyonları. Özellikler gibi *Yakıt Tüketimi Şehir* *Ve Yakıt Tüketimi Tarak* CO ile tutarlı bir pozitif ilişkiye sahip olmak emisyonlar-daha yüksek yakıt tüketimine sahip araçlar daha fazla CO üretir. Ek olarak, belirli özelliklerin etkisi, örneğin: *Yakıt Türü_X*




Şekil 15. SHAP Özeti: En yüksek sıradaki özellik olarak Yakıt Tüketimi Birleşik (L/100 km) ile özellik öneminin görselleştirilmesi. Kırmızı, CO üzerinde daha büyük bir etkiyi temsil ederzemisyonları, mavi ise daha düşük etkiyi temsil ediyor.

Ve İletim_A56, araç konfigürasyonuna bağlı olarak değişmekte olup, modelin tahminlerinde özellik etkileşimlerinin önemini vurgulamaktadır.

SHAP şelale grafiği: CO için Örnek Düzeyinde açıklamazemisyon tahmini

Her bir özelliğin belirli bir aracın (indeks 0) tahminine olan katkısını açıklamak için, Şekil 2'de gösterildiği gibi bir şelale grafiği oluşturmak üzere SHAP'ı kullandık. 16SHAP şelale grafiği, farklı özelliklerin nihai CO₂'ya nasıl katkıda bulunduğuna dair örnek düzeyinde bir açıklama sağlar; belirli bir veri noktası için emisyon tahmini. SHAP şelale grafiğindeki temel unsurlar şunlardır:

- **Temel Değer** $E(\hat{R}|X) = 0.506$: Tahminin beklenen değeri, yani ortalama CO₂Veri setindeki tüm örneklerde emisyon tahmini. Bu temel çizgi, grafiğin başlangıç noktası olarak hizmet etti.
- **Model Çıktısı** $\hat{R}(X) = 0.543$: Tüm özelliklerin katkıları hesaba katıldıktan sonra, bu belirli örnek (araç) için nihai tahmin edilen değer. Bu, CO₂'yu temsil eder. Veri setindeki 0. endeks için emisyon tahmini.
- **Özellik Katkıları**: Her yatay çubuk, bir özelliğin nihai tahmine katkısını temsil eder. Tahmin edilen değeri artıran özellikler kırmızıyla gösterilir (pozitif katkılar), tahmin edilen değeri artıran özellikler ise



Şekil 16. SHAP Şelale Grafiği: Her bir özelliğin temel değerden değişimlere olan göreceli katkılarını gösteren ayrıntılı analiz. Şehirdeki yakıt tüketiminin, kombine yakıt tüketiminin ve otoyol yakıt tüketiminin modelin CO2'si üzerindeki önemli etkisini vurgularz emisyon tahmini.

tahmini katlama mavi olarak gösterilir (olumsuz katkılar). Örneğin, *Yakıt Türü_X* son tahmine +0,02 katkıda bulunur ve CO'yu biraz artırırz emisyon tahmini. Öte yandan, *Silindir_6* negatif bir katkısı vardır (-0,01), bu da tahmini azaltır.

- **Toplam Etki:** Tüm özelliklerden gelen katkılar, temel çizgiden başlanarak toplandı $E[f(X)] = 0.506$, ve son tahmine ulaşıldı $f(x) = 0.543$. Her bir özelliğin bu küçük katkısı, tahminin başlangıç değerinden nihai sonuca kaydırılmasına katkıda bulunur.
- **Birçok Küçük Katkı:** Grafik, çok sayıda küçük özelliğin ("2099 diğer özellik" olarak gruplandırılmış) +0,02'lik birleşik bir katkısı olduğunu ve bunun da tahmini etkilediğini göstermektedir. Bu gruplanmış özelliklerin tek tek küçük etkileri vardır ancak toplu olarak nihai çıktıyı etkilerler.

SHAPwaterfall grafiği her bir özelliğin tahmin üzerindeki etkisini görsel olarak gösterir. Şu gibi özellikler: *Yakıt Türü_X* ve *Yakıt Tüketimi Tarak* tahminleri yukarı doğru iterken, şu gibi özellikler de var: *Yakıt Türü_Z* ve *Silindirler_6* olumsuz bir etkiye sahiptir. Tüm bu özellik katkılarının kümülatif etkisi, 0,506'lık temel değerden 0,543'lük bir nihai tahmine yol açtı. Bireysel özellik katkılarını görselleştirerek, SHAP şelale grafiği, modelin belirli CO'ya nasıl ulaştığına dair yorumlanabilir ve şeffaf bir görünüm sağlarz emisyon tahminleri. Bu şeffaflık, her aracın tahminini önemli ölçüde etkileyen özelliklerin anlaşılmasına yardımcı olur.

SHAP kuvvet grafiği: CO için Örnek Düzeyinde açıklamazemiyon tahmini

Şekildeki SHAP Kuvvet Grafiği 17 veri kümesindeki 0. endeks için model tarafından yapılan bireysel tahminlerin ayrıntılı bir açıklamasını sağlar. Her bir özelliğin katkılarını görselleştirerek, tahmini temel çizgiden daha yükseğe mi yoksa daha aşağıya mı ittiklerini gösterir.

- **Temel Değer $E[f(X)]$:** Modelin çıktısının herhangi bir özellik bilgisi olmaksızın beklenen değerini temsil eden temel değer, $E[f(X)] = 0.50$. Bu, CO'nun ortalama tahminidir tüm örneklerdeki emisyonlar.
- **Model Çıktısı $f(X) = 0.543$:** 0. endeks için öngörülen son değer şudur: $f(X) = 0.543$. Bu, temel değerden biraz daha yüksek olup, daha yüksek bir CO tahminini göstermektedir. Bu örnek için emisyon.
- **Olumlu Katkılar (Kırmızı):** Şu gibi özellikler: *Yakıt Tüketimi Şehir (L/100 km)* ve *Yakıt Türü*. Tahmini önemli ölçüde artırdı ve nihai çıktıya olumlu katkıda bulundu. Bunlar, grafiğin sol tarafındaki kırmızı bölümlerle temsil edilir.
- **Olumsuz Katkılar (Mavi):** Şu gibi özellikler: *Yakıt Türü* ve *Silindirler*. Tahmini azalttı, aksi takdirde olacağından daha aşağıya çekti. Bunlar grafiğin sağ tarafındaki mavi bölümlerle temsil edilir.
- **Toplam Etki:** Grafik, pozitif ve negatif katkıları dengeleyerek temel değerden nihai tahmin edilen değere geçişi göstermektedir. Bu özelliklerin genel etkisi, kuvvet grafiğinin sağ ucunda gösterildiği gibi 0,543'lük nihai tahmin edilen değere yol açmıştır.

Bu görselleştirme, modelin karar alma sürecine ilişkin sezgisel bir anlayış sunarak, çeşitli özelliklerin nihai tahmini üretmek için nasıl etkileşime girdiğini vurgulamaktadır.

SHAP bağımlılık grafikleri: CO üzerindeki özellik etkisinin analizizemiyonlar

Şekildeki SHAP bağımlılık grafikleri 18 belirli özelliklerin öngörülen CO'yu nasıl etkilediğine dair ayrıntılı bir görselleştirme sağlar. Emisyonlar ve bunların modeldeki diğer değişkenlerle nasıl etkileşime girdiği.


- **Motor Boyutu:** Şekildeki bağımlılık grafiği 18a, motor boyutu ile CO arasında pozitif bir ilişki olduğunu göstermektedir. Emisyonları, daha büyük motorların daha yüksek emisyonlara katkıda bulunduğunu göstermektedir. Ancak, diğer özelliklerle karşılaştırıldığında SHAP değerlerinin daha dar aralığı, motor boyutunun CO üzerinde nispeten daha düşük bir etkiye sahip olduğunu göstermektedir. Bu, yakıt tüketimi ölçümlerinin (Şehir, Kombine ve Otoyol) emisyonlara daha doğrudan bağlı olduğu ve bunları modelde daha etkili tahmin ediciler haline getirdiği verilerin doğasıyla uyumludur.
- **Yakıt Tüketimi (Şehir):** Şekildeki bağımlılık grafiği 18b, şehir içi sürüş koşullarında yakıt tüketiminin CO ile güçlü bir şekilde ilişkili olduğunu ortaya koymaktadır. Kentsel ortamlarda daha yüksek yakıt tüketimi, CO2 emisyonunun artmasına neden olur. Tahminler, şehir yakıt verimliliğini emisyon azaltma stratejileri için önemli bir hedef haline getiriyor.
- **Yakıt Tüketimi (Kombine):** Şekildeki kombine yakıt tüketimi bağımlılığı grafiği 18c, genel yakıt tüketiminin artmasıyla daha yüksek CO2 emisyonuna yol açan benzer bir eğilimi göstermektedir. Bu, çevresel etkiyi azaltmak için farklı sürüş koşullarında yakıt verimliliğinin iyileştirilmesinin önemini vurgular.
- **Yakıt Tüketimi (Otoyol):** Şekildeki karayolu yakıt tüketimi grafiği 18d ayrıca CO ile pozitif bir ilişki göstermektedir. Otoyol sürüşü genellikle şehir içi sürüşten daha yakıt tasarruflu olsa da, bu durumda yakıt tüketimi yine de emisyonlara önemli ölçüde katkıda bulunur ve emisyonları azaltmada verimlilik iyileştirmelerinin rolünü vurgular.

Genel olarak, SHAP bağımlılık grafikleri, motor boyutu ve yakıt tüketimi ölçümlerinin, özellikle şehir içi, kombine ve otoyol sürüş koşullarında, araç CO2'sini tahmin etmede nasıl önemli roller oynadığına dair kapsamlı ve içgörülü bir analiz sağlar. Motor Boyutu için SHAP değerlerinin daha düşük varyasyonu ve daha küçük büyüklüğü, Yakıt Tüketimi özellikleriyle karşılaştırıldığında hedef değişken üzerinde daha zayıf bir etkiye sahip olduğunu göstermektedir. Yakıt tüketimi ölçümleri, modelin tahminleri üzerindeki baskın etkilerini vurgulayarak daha geniş bir SHAP değeri aralığı sergilerken, motor boyutu için gözlemlenen daha küçük aralık, karşılaştırmada nispeten daha düşük önemini göstermektedir. Bu ayırım, özellikle kentsel ve kombine sürüş koşullarında yakıt verimliliği iyileştirmelerinin CO'yu azaltmak için kritik itici güçler olduğunu vurgulamaktadır. Bununla birlikte, motor boyutu tamamen göz ardı edilemeyecek bir katkıda bulunan faktör olmaya devam ediyor.

Bu bulgular CO2 emisyonunda önemli bir azalma potansiyelini vurgulamaktadır. Araç tasarımında ve yakıt verimliliğinde hedeflenen iyileştirmeler yoluyla emisyonları azaltın. Daha küçük deplasmanlı motorlar geliştirmeye odaklanarak, farklı sürüş koşullarında yakıt tüketimini optimize ederek ve gelişmiş teknolojileri kullanarak



Şekil 17. SHAP Kuvvet Grafiği: Her bir özelliğin modelin çıktısını nasıl etkilediğini gösteren bireysel tahminlerin derinlemesine analizi. Şehir yakıt tüketiminin, kombine yakıt kullanımının ve karayolu yakıt tüketiminin CO üzerindeki dikkate değer etkisini vurgular. Emisyon tahminleri.



Şekil 18. Çeşitli özellikler için SHAP Bağımlılık Grafikleri: (A) Motor Boyutu, (B) Yakıt Tüketimi (Şehir İçi), (C) Yakıt Tüketimi (Kombine) ve (D) Yakıt Tüketimi (Otoyol).

Verimliliği artırmak, üreticiler emisyonları en aza indirmek için önemli adımlar atabilirler. Bu sadece çevre düzenlemelerine uymaya yardımcı olmakla kalmaz, aynı zamanda iklim değişikliğini azaltma ve sürdürülebilir bir gelecek elde etme gibi daha geniş bir hedefe de destekler. Sonuç olarak, SHAP analizi hem politika yapımcıları hem de otomotiv mühendislerini bilgilendirebilecek, ulaşım sektöründe enerji verimliliği ve emisyon azaltımına öncelik veren stratejilerin benimsenmesini teşvik edebilecek eylem geçirilebilir içgörüler sağlar. Bu, daha yeşil araçların ve daha temiz ortamların geliştirilmesine yol açacak ve iklim değişikliğiyle mücadele için küresel çabalara anlamlı bir şekilde katkıda bulunacaktır.

Önceki çalışmalarla karşılaştırma

Bu analiz, önerilen Özel Derin Öğrenme Modelini CO tahminine yönelik mevcut modellerle karşılaştırarak literatür incelemesinin bulgularını genişletiyor. Tabloda gösterildiği gibi literatür taramasında atıfta bulunulan birçok çalışmada bu görev için BiSTM ve XGBoost gibi modeller kullanılmıştır.

Önerdiğimiz yöntem CO tahmininde mevcut yöntemlerden daha iyi performans göstermektedir. Tablodaki modellerin en düşük Ortalama Karesel Hata (MSE) ve Kök Ortalama Karesel Hata (RMSE) değerlerine sahipti ve bu da beklenen ve gerçek CO₂ emisyonları arasında daha iyi bir uyum olduğunu gösteriyor. Ayrıca, önerilen modelin yüksek bir R kare değeri vardı ve bu da tahminler ile gerçek veriler arasında önemli bir bağlantı olduğunu gösteriyordu. Önceki çalışmalarda kullanılan veri kümeleri ve değerlendirme ölçütlerindeki farklılıklardan kaynaklanan potansiyel kısıtlamaları kabul ederken, önerilen yaklaşım bu önemli parametreleri geride bıraktı. Ayrıca, yorumlanabilirliğini artıran SHAP değerlerine sahiptir. SHAP değerlerini kullanarak, farklı özelliklerin modelin tahminlerini nasıl etkilediğine dair içgörüler elde ettik ve genel şeffaflığını ve güvenilirliğini artırdık. Sonuç olarak, özel derin öğrenme modelimizin yüksek performansı ve yorumlanabilirliği, onu CO tahmininde etkili bir araç haline getiriyor.

Tartışma

Önerilen derin öğrenme modeli mevcut karbondioksit (CO) emisyonlarını geride bıraktığı 0,0002'lik düşük Ortalama Karesel Hata (MSE), 0,0142'lik Kök Ortalama Karesel Hata (RMSE) ve 0,9938'lik yüksek R-kare değerine sahip emisyon tahmin modelleri. Bu göstergeler, model tahminleri ile gerçekler arasında daha iyi bir eşleşme göstermektedir.

Yazar	Kullanılan Model	MSE	RMSE	R-Kare	MAPE Yüzdesi	XAI KULLANIMI (ŞAP)
Al-Nefaie ve diğerleri. 2023	BİLST	0,001177	0,0343	0,9378	-	✗
Mağziel ve diğerleri. 2023	Gradient-Boosting	0,7780	0,877	0,6126	-	✓ (ŞAP)
Ziókowski ve diğerleri. 2021	Çok kanallı	-	1.0598	0,9861	%5,06 ila %10,88	✗
Pandey ve diğerleri. 2023	İngiltere	-	0,0604	0,8468	-	✓ (ŞAP)
Tena-Gago ve diğerleri. 2023	UWS-LSTM	0,0261	0,1616	0,975	-	✗
Çınarer ve ark. 2024	XGBoost	0,0011	0,0333	0,9886	5.76%	✗
Wen ve diğerleri. 2021	İngiltere	-	0,95	0,99	-	✗
Wei ve diğerleri. 2021	Kedi Güçlendirme	-	0,039	0,83	-	✗
Ullah ve diğerleri. 2023	ışıkGBM	-	16.34	0,9800	-	✗
Hien ve diğerleri. 2022	Tek Değişkenli Polinom Regresyonu	-	1.287	0,986	-	✗
Li ve diğerleri. 2023	Topluluk Modeli	-	2.01	0,88	-	✗
Önerilen Yöntem	KarbonMLP	0,0002	0,0142	0,9938	%2,59	✓ (ŞAP)

Tablo 7. Önceki çalışmalarla karşılaştırma.

Ortakz emisyonları, gerçek dünya verileriyle önemli bir korelasyon olduğunu gösteriyor. Önceki araştırma yaklaşımlarındaki farklılıklardan kaynaklanan olası sınırlamaları vurgularken, modelin açık üstün performansı onu hassas CO için güçlü bir araç olarak ortaya koyuyor. emisyon tahmini. Bizim temel katkımız yalnızca CO₂'yi değil, aynı zamanda emisyonları değil, aynı zamanda SHAP değerlerini kullanarak yorumlanabilirlik de sağlar. Bu şeffaflık, araç özellikleri, yakıt tüketimi ve motor boyutu gibi hangi unsurların CO₂ üzerinde en büyük etkiye sahip olduğunu daha iyi anlamamıza yardımcı olur. emisyonları. Bu ana faktörleri belirleyerek, model araçla ilgili CO emisyonlarını bilgilendirebilir. emisyon azaltma planları. Örneğin, modelin yorumlanabilirlik özelliklerinden elde edilen içgörüler, motor performansını iyileştirmeyi, yakıt tasarruflı araçları teşvik etmeyi ve çevreye duyarlı sürüş uygulamalarını desteklemeyi amaçlayan çabaları hedeflemek için kullanılabilir. Bu çalışma, CO₂ emisyon tahminleri ve çevre yetkililerine, düzenleyicilere ve otomotiv sektörüne yararlı bilgiler sağlar. Bu paydaşlar, modelin yeteneklerini kullanarak CO₂'yi azaltmak için başarılı planlar oluşturabilir ve uygulayabilirler. 2 otomobillerden kaynaklanan emisyonları azaltarak daha sürdürülebilir bir çevrenin önünü açıyor.

Sonuç ve gelecekteki çalışmalar

Bu çalışma, karbondioksit (CO) emisyonunu tahmin etmek için derin öğrenme modelinin etkinliğini araştırdı.2) araçlardan kaynaklanan emisyonlar. Önerilen model, doğruluk ve yorumlanabilirlik açısından önceki teknikleri geride bırakarak olağanüstü bir performans gösterdi. Özetle, bu çalışma CO tahmin etmek için explainable AI (XAI) entegrasyonuna sahip derin bir öğrenme modeli geliştirdi.Çok Katmanlı Algılayıcı (MLP) mimarisi kullanan araçlardan kaynaklanan emisyonlar. Model, Marka, Model, Araç Sınıfı, Motor Boyutu (L), Silindirler, Şanzıman, Yakıt Türü, Yakıt Tüketimi derecelendirmeleri (Şehir, Otoyol ve Kombin) ve CO gibi araç özelliklerini içeren 7.385 satır ve 12 sütundan oluşan bir veri kümesi kullanılarak eğitildizemisyonları (g/km). Model, 0,9938'lik yüksek R kare değeri ve 0,0002'lik düşük Ortalama Kare Hata (MSE) ile kanıtlandığı üzere son derece başarılıydı. Değerlendirme ölçümleri ve görselleştirmeler kullanan daha ileri çalışmalar, modelin araç özellikleri ile CO arasındaki karmaşık bağlantıları temsil etme kapasitesini doğruladıemisyonları. Ek olarak, SHapley Katkısal Açıklamaları (SHAP) değerleri, modelin CO2 emisyonları üzerindeki farklı özelliklerin etkisini elde etmek için uygulandı.2)modelin emisyon tahminleri. Bu iyimser bulgulara rağmen, bu çalışmanın daha fazla araştırma gerektiren bazı sınırlamaları vardır. Önerilen modelin performansı kullanılan veri setinden etkilenmiştir. Belirli bir bölge veya araç türünden veriler kullanılarak eğitilirse, farklı popülasyonlara veya coğrafi konumlara uygulanabilirliği sınırlı olabilir. Ayrıca, bu çalışmanın CO2emisyonlar, önemli olsa da, çevresel zorluğun yalnızca bir yönünü ele alır. Azot oksitler (NOx) ve partikül madde (PM) gibi diğer kirleticileri dahil etmek, bir aracın çevresel etkisine dair daha eksiksiz bir görünüm sağlayacaktır. Ayrıca, model analizi eğitim verileriyle bulunan özelliklerle sınırlandırılmıştır. CO'ya etkileyebilecek dış unsurlara daha derinlemesine bir bakış2 Sürüş davranışı, hava koşulları ve yol altyapısı gibi emisyonlar, gelecekteki model değişiklikleri için yararlı bilgiler sağlayabilir.

Gelecekteki çabalar bu çalışmayı temel alabilir ve daha sürdürülebilir bir çevre yaratmak için yeni yollar keşfedebilir. Veri setini daha geniş ve daha çeşitli coğrafi bölgeleri kapsayacak şekilde genişletmek, modelin geliştirilebilirliğini artıracaktır. CO analizine daha fazla kirlenici dahil etmemiz, araçların çevresel etkisine dair daha kapsamlı bir anlayış sağlayacaktır. Karmaşık yorumlanabilirlik tekniklerini keşfetmek, modelin karar alma sürecine dair daha fazla içgörü sağlayabilir. Ancak, gelecekteki en önemli gelişmeler gerçek dünya uygulamalarını içerecektir. CO ölçen sensörlerle donatılmış araçları düşününzemisyonları, modelin önemli olarak tanımladığı aynı parametrelere dayalı olarak hesaplar. Bu gerçek zamanlı veriler, sürekli iyileştirmeyi sağlamak ve sürücülere eko-sürüş tavsiyeleri konusunda bilgilendirmek için modele geri beslenebilir. Sürdürülebilir bir çevreye doğru yolculuğumuz kavramsal çerçevenin ötesine geçer. Gelecekteki çalışmalar, sürüş alışkanlıkları, yol koşulları ve çevresel faktörler gibi etki değişkenleri dahil etmeyi düşünmelidir. Gerçek zamanlı izleme sistemleri ve araç sensörü verileri, kirlilik tahminlerini iyileştirmek için olmazsa olmazdır. Dahası, karmaşık derin öğrenme mimarilerini ve topluluk yaklaşımlarını araştırmak, modelin tahmin yeteneklerini artırabilir. Bu adımları atarak, gezegenimiz için daha temiz ve daha sürdürülebilir bir gelecek yaratmak için bu bilimin gücünden yararlanabiliriz. Bu çalışma, daha kesin

ve anlaşılabilir CO₂ araçlar için emisyon tahmin modelleri. Bu bilgi, kamu görevlilerinin, otomobil üreticilerinin ve sürücülerin kısıtlamaları çözerek ve yeni fırsatları keşfederek ulaşım için daha sürdürülebilir bir gelecek geliştirmelerini sağlayacaktır. İleri modellemeyi yorumlanabilirlikle birleştiren önerilen yaklaşım, sürdürülebilir ulaşım sistemleri kurma, çevreyi koruma ve araç emisyonlarını azaltma konusunda önemli bir katkı sağlamaktadır.

Veri kullanılabilirliği

Bu çalışmada kullanılan veri seti Kaggle'da kamuya açıktır:<https://kaggle.com/datasets/debajyotipodder/co2-emissions-araclarla>. Marka, model, motor detayları, şanzıman tipi, yakıt tüketim oranları ve CO2 emisyonları dahil olmak üzere kapsamlı araç bilgileri sağlar. Veriler, Kanada hükümetinin resmi açık veri web sitesinden alınmış ve derlenmiştir; bu siteye şu adresten erişilebilir:<https://open.canada.ca/data/en/dataset/98f1a129-f628-4ce4-b24d-6f16bf24dd64>. Bu veri setini daha ileri analizler için kullanmak isteyen araştırmacılar, en son veriler için resmi kaynağa başvurabilirler.

Alındı: 23 Haziran 2024; Kabul Edildi: 17 Ocak 2025

Published online: 29 January 2025

Referanslar

1. Kanada, E. & Change, C. Sera gazı emisyonları (2024). Son erişim 2024/04/14.
2. Dünya Sağlık Örgütü. Ortam hava kirliliği (2022).
3. Boschee, P. Yorumlar: Nükleer enerji (bir miktar) ilgi görüyor. *Petrol Teknolojisi Dergisi*[UZAY]<https://doi.org/10.2118/0723-0010-jpt>(2023).
4. ABD Çevre Koruma Ajansı (EPA). Tipik bir binek araçtan kaynaklanan sera gazı emisyonları (nd). Son erişim 2024/04/28.
5. Uluslararası Temiz Taşımacılık Konseyi. Küresel ulaşım sektörüOrtak2021'de emisyonlar %2,8 arttı (2021).
6. Dünya Sayılır. Arabaların çevreye etkisi (2022).
7. Fleck, A. Dünya arabasız gün. *İstatistikçi*(2023). Veri Gazetecisi: anna.fleck@statista.com .
8. Hao, H., Cheng, X., Wang, Y., Liu, J. ve Wei, Z. Alternatif ulaşım yollarının yaşam döngüsü değerlendirmesindeki ilerlemenin incelenmesi. *Yenilenebilir ve Sürdürülebilir Enerji İncelemeleri***131**, 110008 (2020).
9. Gnann, E., Schulte, M., Munzer, A. ve Breuer, V. Depo-tekerlek emisyonlarının odaklanarak hidrojen yakıt hücreli araçların yaşam döngüsü değerlendirmesi. *Uluslararası Hidrojen Enerjisi Dergisi***55**, 22122-22132 (2020).
10. Zheng, M., Zhao, R., Liu, Z., Li, X. & Li, Z. Benzinli motorların küçültülmesi ve turboşarj edilmesi: Bu, yakıt tüketimini azaltacak mı?Ortak2tüm yaşam döngüsü boyunca emisyonlar? *Enerji Dönüşümü ve Yönetim***248**, 114800 (2021).
11. Zhang, S., Li, J., Ma, X. ve Wang, W. Otomatik şanzıman tiplerinin yakıt ekonomisi ve emisyonlar üzerindeki etkilerinin incelenmesi. *Yenilenebilir ve Sürdürülebilir Enerji İncelemeleri***133**, 110223 (2020).
12. Liu, Z., Wang, Y., Tang, L. ve Li, Y. Uzun kısa süreli hafıza sinir ağına dayalı eko-sürüş davranışı tanıma. *IEEE Akıllı Ulaşım Sistemleri İşlemleri***21**, 3682-3691 (2020).
13. Zhang, J., Liu, J., Lv, W., Wang, X. & Li, P. Kentssel trafiğin gerçek zamanlı tahminiOrtak2Derin öğrenme yaklaşımı kullanılarak emisyonların belirlenmesi. *Ulaştırma Araştırması Bölüm D: Ulaştırma ve Çevre***161**, 102722 (2022).
14. Wang, X., Liu, D., Hao, H., Wang, X. & Liu, J. Yakın yollardaki ortam sıcaklığı ve neminin etkileriHAYIRve benzinli araçların CO emisyonları. *Çevre Bilimi ve Kirillik Araştırması uluslararası***27**, 30791-30802 (2020).
15. Wang, J., Li, L., Peng, C. & Li, Z. Elektrikli araçlar için aerodinamik sürtünme azaltma teknolojilerinin incelenmesi. *Güç Kaynakları Dergisi***510**, 120820 (2021).
16. Ones, D. & Patel, R. Makine öğrenimi ve sensör veri birleştirme kullanılarak araç emisyonlarının gerçek zamanlı tahmini. *Ulaştırma Araştırması Bölüm C: Ortaya Çıkan Teknolojiler***78**, 102-115 (2020).
17. Avrupa Çevre Ajansı (AÇA). Karayolu taşımacılığı için emisyon faktörleri (eft).<https://www.eea.europa.eu/publications/emep-ea-guidebook-2019/emission-factors-database>(2021). 10 Mart 2024'te erişildi.
18. Smith, A., Johnson, B. ve Williams, C. Araç hızını tahmin etmek için makine öğrenimi modelleriOrtak2emisyonlar. *Çevre Bilimi ve Teknoloji***45**, 567-578 (2021).
19. Dong, M., Guo, W. & Han, X. Yapay zeka, endüstriyel yapı optimizasyonu veOrtak2emisyonlar. *Araştırma Meydanı* [UZAY]<https://doi.org/10.21203/rs.3.rs-2954106/v1> (2023).
20. Zhong, J., Zhong, Y., Han, M., Yang, T. & Zhang, Q. Yapay zekanın karbon emisyonları üzerindeki etkisi: 66 ülkeden elde edilen kanıtlar. *Uygulamalı Ekonomi*[UZAY]<https://doi.org/10.1080/00036846.2023.2203461> (2023).
21. Moraliyaga, H. ve diğerleri. Net sıfır karbon emisyonları için enerji verimli altyapının ölçümü ve doğrulanması için açıklanabilirliğe sahip sağlam bir yapay zeka yaklaşımı. *Sensörler***22**, 9503. <https://doi.org/10.3390/s22239503> (2022).
22. Sharma, N., Singh, U. & Mahapatra, SS Hindistan'daki kömürle çalışan elektrik santrallerinden kaynaklanan maliyet ve emisyon tahmini ortak2Yapay zeka teknikleri kullanılarak yakalama ve depolama. *Mühendislik Yönetiminin Sınırları***6**, 573-582. <https://doi.org/10.1007/s11708-017-0482-6> (2019).
23. Chen, S. ve diğerleri. Yapay zeka karbon nötrlüğüne ulaşabilir mi? yarı doğal bir deneyden elde edilen kanıt. *Ekoloji ve Evrimde Sınırlar*[UZAY]<https://doi.org/10.3389/fevo.2023.1151017> (2023).
24. Saggari, A. & Nigam, B. Enerji yoğun endüstrilerde net sıfırı maksimize etmek: Sera gazı azaltımı için yapay zeka uygulamalarına genel bakış. *Temiz Üretim Dergisi*[UZAY]<https://doi.org/10.3233/jcc230003> (2023).
25. Verdecchia, R., Sallou, J. & Cruz, IJ Yeşil yapay zekanın sistematik bir incelemesi. *Wiley Disiplinlerarası İncelemeleri: Veri Madenciliği ve Bilgi Keşfi*[UZAY]<https://doi.org/10.1002/widm.1507> (2023).
26. Chadha, AS, Shinde, Y., Sharma, N. & De, PK Tahmin EtmeOrtak2Makine öğrenmesi kullanılarak araçların emisyonları. *Yaylı* [UZAY]https://doi.org/10.1007/978-981-19-2600-6_14 (2022).
27. Manvitha, MS, Pujitha, MV, Prasad, NH & Anju, BY Bir tahmin analiziOrtak2Makine öğrenmesi teknikleri kullanılarak otomobillerdeki emisyonlar. *IEEE Uluslararası Veri Bilimi ve Nesnelerin İnterneti Konferansı*[UZAY]<https://doi.org/10.1109/idiot56793.2023.10053539> (2023).
28. Li, X., Ren, A. & Li, Q. Taşımacılıkla ilgili modellerin araştırılmasıOrtak2Makine öğrenmesi yöntemleri kullanılarak emisyonların belirlenmesi. *Sürdürülebilirlik*[UZAY]<https://doi.org/10.3390/su14084588> (2022).
29. Kadam, P. & Vijayumar, S. Tahmin modeli:Ortak2makine öğrenimi kullanılarak emisyon. *IEEE Uluslararası Buluşsal Hesaplama Teknolojileri Konferansı (ICICT)*[UZAY]<https://doi.org/10.1109/i2ct.2018.8529498> (2018).
30. Kangralkar, S. & Khanai, R. Otomotiv emisyon tahmini için makine öğrenimi uygulamaları. *IEEE Uluslararası Yaratıcı Hesaplama Teknolojileri Konferansı*[UZAY]<https://doi.org/10.1109/i2ct51068.2021.9418152> (2021).
31. Howlader, AM, Patel, D. & Gammariello, R. Entegre derin sinir ağı kullanılarak anlık araç emisyonu tahmini için veri odaklı yaklaşım. *Ulaştırma Araştırması Bölüm D: Ulaştırma ve Çevre*[UZAY]<https://doi.org/10.1016/j.trd.2023.103654> (2023).

Ek Bilgiler

Yazışmalar ve materyal talepleri RI veya KN'ye iletilmelidir **Yeniden basım ve izin bilgileri** şu adreste mevcuttur: www.nature.com/yenidenbaskilar.

Yayıncının notu Springer Nature, yayınlanan haritalardaki yargı yetkisi iddiaları ve kurumsal bağlantılar konusunda tarafsızlığını korumaktadır.

Açık Erişim Bu makale, orijinal yazar(lar)a ve kaynağa uygun atıflarda bulunduğunuz, Creative Commons lisansına bir bağlantı sağladığınız ve lisanslı materyali değiştirip değiştirmediğinizi belirttiğiniz sürece, ticari olmayan herhangi bir kullanım, paylaşım, dağıtım ve herhangi bir ortamda veya biçimde çoğaltılmasına izin veren Creative Commons Atıf-Ticari Olmayan-Türev Eserler 4.0 Uluslararası Lisansı kapsamında lisanslanmıştır. Bu lisans kapsamında, bu makaleden veya bazı bölümlerinden türetilen uyarlanmış materyali paylaşma izniniz yoktur. Bu makaledeki görseller veya diğer üçüncü taraf materyalleri, materyale ait bir atıf satırında aksi belirtilmediği sürece, makalenin Creative Commons lisansına dahildir. Materyal, makalenin Creative Commons lisansına dahil değilse ve amaçladığınız kullanım yasal düzenleme tarafından izin verilmiyorsa veya izin verilen kullanımı aşıyorsa, doğrudan telif hakkı sahibinden izin almanız gerekecektir. Bu lisansın bir kopyasını görüntülemek için şu adresi ziyaret edin: <http://creativecommons.org/licenses/by-nc-nd/4.0/>.

© Yazar(lar) 2025

Şartlar ve koşullar

Springer Nature dergisinin içeriği, Springer Nature Müşteri Hizmetleri Merkezi GmbH ("Springer Nature") izniyle sizlere sunulmaktadır.

Springer Nature, tüm telif hakkı, ticari markalar ve hizmet markaları ve diğer mülkiyet bildirimlerinin korunması koşuluyla, yazarlar, aboneler ve yetkili kullanıcılar ("Kullanıcılar") tarafından araştırma makalelerinin makul miktarda paylaşılmasını destekler. Springer Nature dergi içeriğine erişerek, paylaşarak, alarak veya başka şekilde kullanarak bu kullanım koşullarını ("Koşullar") kabul etmiş olursunuz. Bu amaçlar için Springer Nature, akademik kullanımı (araştırmacılar ve öğrenciler tarafından) ticari olmayan olarak değerlendirir.

Bu Şartlar tamamlayıcıdır ve geçerli herhangi bir web sitesi hüküm ve koşullarına, ilgili bir site lisansına veya kişisel aboneliğe ek olarak uygulanacaktır. Bu Şartlar, ilgili hükümler, bir site lisansı veya kişisel abonelik ile ilgili herhangi bir çatışma veya belirsizliğe üstün gelecektir (sadece çatışma veya belirsizlik ölçüsünde). Creative Commons lisanslı makaleler için kullanılan Creative Commons lisansının şartları geçerli olacaktır.

Springer Nature dergisi içeriğine erişim sağlamak için kişisel verileri topluyor ve kullanıyoruz. Ayrıca bu kişisel verileri ResearchGate ve Springer Nature içinde dahili olarak kullanabilir ve kararlaştırıldığı şekilde, takip, analiz ve raporlama amaçlarıyla anonimleştirilmiş bir şekilde paylaşabiliriz. Gizlilik Politikasında ayrıntılı olarak açıklandığı gibi izniniz olmadığı sürece kişisel verilerinizi ResearchGate veya Springer Nature şirketler grubu dışında ifşa etmeyeceğiz.

Kullanıcılar, Springer Nature dergisi içeriğini küçük ölçekli, kişisel ve ticari olmayan amaçlarla kullanabilirken, Kullanıcıların şunları yapamayacağını unutmamak önemlidir:

1. Bu tür içeriği, diğer kullanıcılara düzenli veya büyük ölçekli bir temelde erişim sağlamak amacıyla veya erişim kontrolünü aşmanın bir yolu olarak kullanmak;
2. bu tür içerikleri, herhangi bir yargı bölgesinde suç veya kanuni suç olarak değerlendirilecek, hukuki sorumluluğa yol açacak veya başka bir şekilde hukuka aykırı olacak yerlerde kullanmak;
3. Springer Nature tarafından yazılı olarak açıkça kabul edilmediği sürece, yanlış veya yanıltıcı bir şekilde onay, tasdik, sponsorluk veya ilişki ima etmek veya önermek;
4. İçeriğe erişmek veya mesajları yönlendirmek için botlar veya diğer otomatik yöntemleri kullanın
5. herhangi bir güvenlik özelliğini veya dışlayıcı protokolü geçersiz kılmak; veya
6. Springer Nature ürünleri veya hizmetleri için alternatif oluşturmak veya Springer Nature dergi içeriğinin sistematik bir veritabanını oluşturmak amacıyla içeriği paylaşmak.

Ticari kullanıma yönelik kısıtlamaya uygun olarak, Springer Nature, içeriğimizden veya ücretli bir hizmetin parçası olarak veya başka bir ticari kazanç için dahil edilmesinden gelir, telif hakkı, kira veya gelir yaratan bir ürün veya hizmetin oluşturulmasına izin vermez. Springer Nature dergi içeriği, kütüphaneler arası ödünç verme için kullanılamaz ve kütüphaneciler Springer Nature dergi içeriğini büyük ölçekte kendi veya başka bir kurumsal depoya yükleyemez.

Bu kullanım koşulları düzenli olarak gözden geçirilir ve herhangi bir zamanda değiştirilebilir. Springer Nature, bu web sitesinde herhangi bir bilgi veya içerik yayınlamakla yükümlü değildir ve kendi takdirimize bağlı olarak, herhangi bir zamanda bildirimde bulunarak veya bulunmadan bunları veya özelliklerini veya işlevselliğini kaldırabilir. Springer Nature, bu lisansı size herhangi bir zamanda iptal edebilir ve kaydedilmiş olan Springer Nature dergi içeriğinin herhangi bir kopyasına erişimi kaldırabilir.

Yasanın izin verdiği en geniş ölçüde, Springer Nature, Kullanıcılara Springer Nature dergisi içeriğiyle ilgili olarak açık veya zımni hiçbir garanti, beyanda bulunmamakta veya taahhütte bulunmamaktadır ve tüm taraflar, pazarlanabilirlik veya belirli bir amaca uygunluk dahil olmak üzere yasa tarafından empoze edilen her türlü zımni garantiyi veya taahhüitten feragat eder ve bunları reddeder.

Lütfen bu hakların, Springer Nature tarafından yayınlanan ve üçüncü şahıslardan lisanslanmış olabilecek içerik, veri veya diğer materyallere otomatik olarak uygulanmayacağını unutmayın.

Springer Nature dergimizin içeriğini daha geniş bir kitleye veya düzenli olarak veya bu Şartlar tarafından açıkça izin verilmeyen başka bir şekilde kullanmak veya dağıtmak isterseniz lütfen Springer Nature ile şu adresten iletişime geçin:

onlineservice@springernature.com