



sustainability



Madde

CO'yu tahmin etmek2Derin Öğrenme Modeli Kullanılarak Sürdürülebilir ve Akıllı Çevre İçin Trafik Araçlarından Kaynaklanan Emisyonlar

Abdullah H. Al-Nefaie ve Theyazn HH Aldhyani



<https://doi.org/10.3390/su15097615>



Madde

CO'yu tahmin etmek²Derin Öğrenme Modeli Kullanılarak Sürdürülebilir ve Akıllı Çevre İçin Trafik Araçlarından Kaynaklanan Emisyonlar

Abdullah H. El-Nefaie¹ve Theyazn HH Aldhyani²*

¹ İşletme Fakültesi, Kantitatif Yöntemler Bölümü, Kral Faysal Üniversitesi, El-Ahsa 31982, Suudi Arabistan; aalnafaie@kfu.edu.sa

² Abqaiq'teki Uygulamalı Kolej, Kral Faysal Üniversitesi, PO Box 400, Al-Ahsa 31982, Suudi Arabistan

* Yazışma: taldhyani@kfu.edu.sa

Soyut:Fosil yakıtların yakılması karbondioksit (CO) emisyonlarına neden olur², atmosferik değişikliklere ve iklim bozukluklarına önemli ölçüde katkıda bulunur. Sonuç olarak, insanlar çevrenin durumu konusunda endişe duymaya başlar ve hükümetlerin etkili önleyici tedbirler geliştirmek için kesin projeksiyonlar üretmesi gerekir. Bu çalışma, CO₂'yi modelleyerek ve tahmin ederek bölgeye önemli bir katkı sağlar.²Gelişmiş yapay zeka kullanılarak araçların emisyonları. Model, CO kullanılarak oluşturuldu²Kaggle'dan alınan araç emisyon veri kümesi, araç sınıfı, motor hacmi (L), silindir şanzımanı, yakıt türü, şehir içi yakıt tüketimi (L/100 km), karayolu yakıt tüketimi (L/100 km), toplam yakıt tüketimi (L/100 km), toplam yakıt tüketimi (mpg) ve CO₂ gibi farklı parametreleri içerir²emisyonları (g/km). CO₂'yi tahmin etmek için² araçlar tarafından üretilen emisyonlar, derin öğrenme uzun kısa süreli bellek ağı (LSTM) modeli ve çift yönlü LSTM (BiLSTM) modeli geliştirildi. Her iki model de verimlidir. Araştırma boyunca araştırmacılar dört istatistiksel değerlendirme metriği kullandılar: ortalama kare hatası (MSE), kök MSE (RMSE), Pearson korelasyon katsayısı (%R) ve belirleme katsayısı (R²). Kaggle tarafından gerçekleştirilen deneylerin veri kümelerine dayanarak, LSTM ve BiLSTM modelleri oluşturuldu ve uygulandı. Veriler keyfi olarak iki faza ayrıldı: toplam verilerin %80'ini içeren eğitim ve toplam verilerin %20'sini oluşturan test. BiLSTM modeli doğruluk açısından en iyi performansı gösterdi ve MSE ve RMSE için yüksek tahmin değerleri elde etti. BiLSTM modeli elde edilebilecek en büyük (R²=93,78). Ek olarak, R%, hangi özelliklerin CO ile en yüksek ilişki düzeyine sahip olduğunu belirlemek için veri setinin özellikleri arasında bir bağlantı bulmak için kullanıldı²emisyonları. Bu çalışmanın bir sonucu olarak karbon emisyonlarının doğru tahmini için orijinal bir strateji geliştirildi. Sonuç olarak, politika yapıcılar bu çalışmayı başarılı çevre politikaları oluşturmak ve yürütmek için potansiyel olarak faydalı bir karar destek aracı olarak kullanabilirler.

Anahtar kelimeler:yapay zeka; derin öğrenme; CO₂emisyonlar; araçlar; çevre



Alıntı:Al-Nefaie, AH; Aldhyani, THH CO'yu Tahmin Ediyor²Derin Öğrenme Modeli Kullanılarak Sürdürülebilir ve Akıllı Çevre İçin Trafik Araçlarından Kaynaklanan Emisyonlar. Sürdürülebilirlik **2023**,15,7615. <https://doi.org/10.3390/su15097615>

Akademik Editör: Yagang Zhang

Alındı: 27 Mart 2023 Gözden

geçirildi: 1 Mayıs 2023 Kabul

edildi: 2 Mayıs 2023

Yayınlandı: 5 Mayıs 2023




Telif Hakkı:© 2023 yazarlar tarafından. Lisans sahibi MDPI, Basel, İsviçre. Bu makale, Creative Commons Atıf (CC BY) lisansının (<https://creativecommons.org/licenses/by/4.0/>) hüküm ve koşulları altında dağıtılan açık erişimli bir makaledir.

1. Giriş

Son birkaç on yıldır artan sera gazı (GHG) emisyonları, küresel ısınma konusunda artan endişelere yol açtı. Enerji [1], toplu taşıma [2,3], tarımsal [4], bina [5], atık yönetimi [6] ve ağaçlandırma ve yeniden ağaçlandırma [7] sektörleri, bu emisyonların insan kaynaklı kaynaklarından sadece birkaçıdır. Uluslararası Enerji Ajansı'na göre [8], ulaşım sera gazları yaymaktan sorumlu ikinci büyük sektördür. Genellikle karbondioksit eşdeğeri (CO₂e), azot oksit (N₂O), metan (CH₄) ve karbondioksit (CO₂) otomobillerden kaynaklanan başlıca sera gazı emisyonlarıdır [9]. Küresel olarak, ulaşım faaliyetleri toplam çevresel CO₂'nin %75'ini üretiyor² emisyonlar [10]. Sonuç olarak, ulaşım kaynaklı emisyonların azaltılması iklim değişikliğine karşı dünya çapında bir hedeftir [11]. Kentsel otoyolların ve motorlu taşıt trafiğinden kaynaklanan kirletici emisyonlara maruz kalmanın değerlendirilmesi, ekonomik, sosyal ve çevresel hususlar dikkate alındığında önemlidir.

hedefler, özellikle gelişmekte olan ülkelerde [12]. Figür1 CO'nun nasıl olduğunu gösterir Araçlardan yayılıyor.



Şekil 1. Araçlardan çıkan karbondioksit.

Şehirleri birbirine bağlayan otoyollar ve otoyollar gibi ulaşım altyapıları inşa etmek, büyüyen her ekonomi için olmazsa olmazdır. Ülkenin otoyollarındaki tıkanıklık, mevcut ulaşım modlarının gelişimini karşılamak için inşa edilen altyapının hızla genişlemesinin doğrudan bir sonucudur. Bundan dolayı, otoyollar, kavşaklar ve ücretli yollar etrafındaki havanın kalitesinde fark edilir bir düşüş gözlemlenmiştir. Araç egzozları, bu altyapıların neden olduğu genel hava kirliliği miktarında önemli bir faktör olan karbon monoksit (CO) gibi trafik emisyonlarına birincil katkıda bulunan unsurdur. Mekansal tahmin modelleri, trafik emisyonlarının yol ağları üzerindeki etkilerini tahmin etme ve simüle etme kabiliyetleri nedeniyle olağanüstü bir karar verme yardım aracıdır [13–15]. Aşırı miktarda trafik çeşitli istenmeyen etkilere neden olabilir [16,17], hem gürültü hem de gaz kirliliğinde artış dahil. Yüksek miktarda CO'ya maruz kalan insanlar2Çeşitli hastalıklara ve durumlara yakalanma olasılığı önemli ölçüde artmıştır [18–20], kanser, kalp hastalıkları, solunum problemleri ve erken doğumlar gibi.

Son yıllarda bilgisayar teknolojisinin hızla gelişmesi göz önüne alındığında, önemli sayıda çalışma egzoz emisyonlarını tahmin etmek için makine öğrenimi ve derin öğrenmenin kullanımına odaklanmıştır [21] ve CO'yu tahmin etmek için regresyon analizini kullandılar Hafif hizmet tipi dizel kamyonların (LDDT) emisyonları; regresyon denklemi tabanlı CO₂ emisyonları arasındaki korelasyon katsayısı (%R)²projeksiyonlar ve gerçek CO₂Ölçümler %0,93'tü. Maksymilian ve diğerleri [22] Hibrit elektrikli otomobillerden RDE verileri toplandı, CO₂ tahmin etmek için çeşitli makine öğrenimi modellerinin doğruluğu test edildizemisyonları ve en etkili yaklaşımın Gauss süreci regresyonu olduğunu belirledi. Ek olarak, CO₂Hibrit elektrikli otomobiller tarafından üretilen emisyonlar her zaman aracın ivmelenme oranıyla orantılı olarak artmamıştır. Geçtiğimiz birkaç yıl içinde, yapay sinir ağları (YSA), gerçek uygulamalarda sayıları yüksek bir doğruluk derecesiyle tahmin etmek için bir yöntem olarak literatürde yaygın olarak uygulanmıştır [23]. Haşimi ve Clark [24] CO'yu etkili bir şekilde tahmin etmek için bir ANN modeli eğitildizAğır hizmet tipi dizel otomobillerden kaynaklanan emisyonlar, aks hızı, tork ve bunların türevlerinin özelliklerini kullanarak. Jigu ve diğerleri [25] Kısa vadeli CO₂ emisyonunu tahmin etmek için bir ANN modeli ve bir araç dinamiği modelini birleştirdizHafif hizmet dizel araçlarının emisyonları. CO₂hesaplama, gerçek sürüş koşullarının etkisini dikkate almak yerine yalnızca bu iki parametreye (motor hızı ve tork) dayanmaktadır. Bazı çalışmalarda [26–28], ANN, bir aracın egzozu yakıldığında salınan kirleticileri tahmin etmek için kullanılmıştır. Bu çalışmalardaki sorun, tahminleri oluşturmak için kullanılan modellerin yalnızca aracın motorunun mevcut durumunu ve yol koşullarını dikkate almasıdır. Dahası, otomobil emisyonlarının yüksek bir zamansal bağımlılığı vardır. Ancak, zaman hizalamasından sonra bile, egzoz gazının değeri ile çalışırken motorun değeri arasındaki ölçümde hala zaman hatası oluşur. Bu faktör göz önüne alındığında, yalnızca şu anda erişilebilir bilgileri kullanarak tahmin için bu çalışmalara güvenemeyiz.

CO'yu tahmin etmek için çeşitli modeller kullanılabilir. Zulaşım kaynaklı emisyonlar ve literatür [29–31] kullanılabilecek birçok yöntemi tartışır.

Erken trafik CO₂ modelleme, çoğunlukla veri örneklemesine ve GPS gibi teknolojilere bağımlı olan geleneksel yaklaşımlara dayanarak oluşturulmuştur. Bir bölgedeki trafik emisyon dağılımının simülasyonu, farklı temalı haritalar ve araç emisyon denklemlerinin birleştirilmesiyle elde edilebilir ve bu da bilgilendirilmiş yargılarda bulunmaya yardımcı olabilecek bilgilendirici haritaların oluşturulmasıyla sonuçlanabilir [29]. Arazi kullanım regresyon analizi için, yakın zamanda geliştirilen yöntemler büyük ölçüde istatistiksel ve yumuşak hesaplama algoritmalarına dayanmaktadır [32]. Bu hesaplamalı ve istatistiksel yaklaşımlar, girdi olarak trafik ve yol düzenine ilişkin çeşitli faktörleri kullanabilir. Bu modellerin ezici çoğunluğunun deneysel veriler kullanılarak oluşturulduğu göz önüne alındığında, trafik akışındaki, ölçüm tekniklerindeki ve coğrafi konumlardaki değişikliklere karşı oldukça hassastırlar [32]. Bu modeller, aracın türü ve markası ve hava durumu gibi faktörleri göz önünde bulunduran yerel ortama bağlı oldukları için genelleştirilemezler [33,34]. Yol geometrisi bileşenlerini tespit etmek için veri kaynağı olarak otomobillerden elde edilen araştırılmış konum bilgilerini kullanan bir yöntem kurulmuştur [35].

Uzun kısa süreli bellek ağları (LSTM'ler), akademisyenler tarafından gradyan kaybolması ve gradyan kesilmesi sorunlarını çözmek için kurulmuştur [36]. Bu nedenle, CO miktarını tahmin etmede insanlardan çok daha iyidirler. Zarabalar tarafından serbest bırakıldı. Tao, anlık CO'yu tahmin etti. Diğer son teknoloji tekniklerden daha fazla hassasiyetle LSTM tabanlı bir araç emisyon modeli kullanılarak taksilerin emisyonları [37]. Yang ve diğerleri. [38] LSTM'nin NO_x emisyonlarındaki kısa vadeli dalgalanmaları tahmin etmede diğer modellerden daha iyi performans gösterdiğini buldu. CO'yu tahmin etmek. Öte yandan, hafif hizmet tipi dizel kamyonlardan (LDDT) kaynaklanan emisyonların dizi modelleri kullanılarak hesaplanmasına, yayınlanmış literatürde neredeyse hiç rastlanmamaktadır.

İçinde [39], araştırmacılar varsayımsal bir yüksek hızlı aracın emisyonlarını ve yakıt kullanımını hesaplamak için bir GBR modeli kullandılar. Genel olarak, sonuçlardan memnunuz. Yine de, tahmin modeli yalnızca içten yanmalı motorlu araçların (ICE) ne zaman çalıştırıldığına dair bilgileri içeriyordu, bu da bulgularımızla çelişiyor. Bu nedenle, yazarlar HV'lerde meydana gelen güç aktarma organının durumundaki değişiklikleri hesaba katmadılar.

İki hafif hizmet dizel motorlu otomobilin CO₂ emisyonları karşılaştırmalı bir çalışmada LSTM, DNN ve CNN kullanılarak tahmin edildi [40]. Veri seti, aracın yerleşik tanılama (OBD2) konektöründen alındı. Test edilen modeller arasında, LSTM modeli en düşük RMSE puanını (9,30) kazandı. Yazarlar ayrıca, modelin doğruluğunu %30'a kadar azaltabilecek olan giriş verilerindeki gürültülü verilerin etkisini de araştırdılar.

Geleneksel mikro ve makro tahmin algoritmaları başka yerlerde de kullanılsa da, Ref. [41] CO'yu tahmin etmek için bir dizi makine öğrenme tekniği kullanıldı. Hibrit araçların emisyon oranı. Diğer modellerle karşılaştırıldığında, Gauss süreci regresyon (GPR) modeli %69 ile en iyi doğruluğu elde etti. Yazarlar, tutarlı sonuçlar sağlamadıkları için mevcut emisyon modellerinde bir sorun olduğu sonucuna varıyorlar. Hibrit araçların tutarsız CO₂ emisyonları bu sorundan sorumludur. Bu araştırmanın sonuçları bu soruna bir çözüm arayışına önemli bir katkı sağlamaktadır.

Çeşitli araç kirleticileri için emisyon tahmin modelleri PEMS kullanılarak oluşturulabilir ve araştırmacıların yazarları [42] paralel dikkat tabanlı LSTM (veya PA-LSTM) kullanılmasını önermektedir. Eğitim süresi, iki katmanlı dikkat uzamsal kodlama yaklaşımı kullanılarak modelin yakınsama hızı artırıldığından azaltılmıştır. Sonuçlar, PA-LSTM'nin diğer tüm ML modlarından daha iyi performans gösterdiğini ve %94,6'lık bir doğruluk elde edildiğini göstermiştir.

CO'yu hesaplamak için birçok ML modeli kullanıldı. Dizel yakıtla çalışan bir aracın çıkışı [43]. İnşaat ekipmanı şasi hareketinin, yazarların incelediği emisyon oranlarıyla önemli ölçüde ilişkili olduğu gösterilmiştir. Sonuçlar, %94'lük bir başarı oranıyla RF'nin en iyi performans gösteren algoritma olduğunu göstermiştir.

LSTM modelleri, [gibi çeşitli gerçek zamanlı uygulamaları öngörmek için kullanılmıştır. 44], hava kirliliğini tahmin etmek için LSTM modellerini kullanan ve [45], termik santrallerin performansını tahmin etmek için LSTM modellerini kullanan. Kaynak [46] tahmini karbon

emisyollar, Ref. [47] gelecekteki ihracat tahminleri, Ref. [48] pazarlama verilerini analiz edin, Ref. [49] tahmini elektrik yükü ve Ref. [50] hisse senedi fiyatlarını tahmin ediyor.


Atmosferdeki kirliliğin neden olduğu zorluklara katkıda bulunan başlıca etkenlerden biri, sürekli artan araç sayısıdır. Hem zamanında hem de doğru bir şekilde, karayolu taşıtlarından çıkan egzoz emisyonunun uzun ve kısa vadeli tahmini, hava kirliliğini önlemeye, halk sağlığının korunmasına ve hükümetlerin çevre yönetimi için kullandıkları karar alma sürecine yardımcı olabilir. Meteorolojik unsurların ve trafik akışının doğasıyla birlikte gelen içsel öngörülemezlik ve dengesizlik nedeniyle, araç egzoz emisyonu önemli durağan olmayan ve doğrusal olmayan özelliklere sahiptir. Bu nedenle, doğru uzun ve kısa vadeli araç egzoz emisyonu tahmini, karbon monoksit (CO) dahil olmak üzere çeşitli emisyon gazları üzerindeki uzun ve kısa vadeli zamansal bağımlılıklar ve karmaşık doğrusal olmayan bağlantı dahil olmak üzere bir dizi engelle sahiptir. Uzun ve kısa vadeli çok değişkenli araç egzoz emisyonlarını verimli bir şekilde tahmin etmek için LSTM ve BiLSTM modelleri adlı benzersiz bir hibrit derin öğrenme çerçevesi öneriyoruz. Bu, sunulan zorlu zorlukların üstesinden gelmemizi sağlayacaktır.

Bu araştırmanın amacı, CO₂ emisyonunu tahmin edebilen yapay zeka teknolojisini kullanan bir model oluşturmaktır.2otomobillerden kaynaklanan emisyonlar, dünyanın en büyük petrol üreten ülkelerinden biri olan Suudi Arabistan'a ek bir odaklanma ile. Kamuoyuna açıklanan rakamlara göre, Suudi Arabistan Krallığı'nı oluşturan topraklarda şu anda 12 milyondan fazla otomobil bulunmaktadır. Bu sayının 2030 yılına kadar 25 milyon otomobile çıkması bekleniyor. Böyle bir modelin oluşturulması çevrenin korunmasına ve CO₂ yayılımının sınırlandırılmasına katkıda bulunabilir.2Araştırma makalesinin temel katkıları şunlardır:

1. Genel olarak, bu çaba Birleşmiş Milletler tarafından belirlenen Sürdürülebilir Kalkınma Hedeflerinden birkaçının başarılmasına katkıda bulunur. Hedefle doğrudan ilişkilidir "İklim eylemi" başlığını taşıyan 13 numaralı hedefimiz, dolaylı yoldan diğer hedeflere ulaşılmasına da yardımcı oluyor.
2. Daha spesifik olarak, bu çalışmada, CO₂'yi tahmin etmek için oldukça etkili bir derin öğrenme uzun kısa vadeli bellek ağı (LSTM) modeli ve iki yönlü bir LSTM (BiLSTM) modeli oluşturulmuştur.2Trafik araçlarından kaynaklanan emisyonlar.
3. Derin öğrenme modellerini iyileştirmek için tüm veri setindeki aykırı değerleri ele almak amacıyla bir ön işleme yaklaşımı olarak kaba k-ortalama kümelemesi önerilmiştir.
4. Bu modeller ayrıca otomobil nüfusunun CO₂ üzerindeki etkisini de tahmin ediyor2 Üretim. Tipik CO'yu araştırmak için oluşturulan modele yeni bir yöntem olarak duyarlılık analizi eklendi.2Trafik araçlarının ürettiği emisyonlar.
5. Mevcut modelin CO tahminindeki performansızemisyonlarının diğer mevcut modellere göre daha üstün olduğu tespit edildi.

2. Malzemeler ve Yöntemler

CO'yu tahmin etme ve modelleme çerçevesi2Araç trafiğinden kaynaklanan emisyonlar Şekil'de gösterilmektedir2Önerilen çerçevede adım adım modelleme tekniği bütünüyle sunulmaktadır.



Şekil 2. Karbondioksit emisyonu tahmininin çerçevesi.

2.1. Veri seti


Bu veri seti CO'nun resmi kaydını içerir2farklı özelliklere sahip çeşitli araçların emisyon verileri. Bu veri toplama, bir aracın CO2 emisyonu için olasılık aralığını doğru bir şekilde tasvir ederzemisyonları birçok niteliğinin bir fonksiyonu olarak. Bilgiler Kanada hükümetinin açık veri portalından elde edildi. Kolaylık olması açısından en son sürümü hazırladık. Sağlanan bilgiler 7 yılı kapsıyor. Toplam 12 sütun ve 7385 satır sağlandı. Özelliklerin listesini kısaltmak için birkaç kısaltma kullanıldı. Tablo1 fload64'ün ondalık nokta ile ayrılmış hem pozitif hem de negatif değerlerden oluştuğu ve int64'ün gerçek sayı olduğu veri kümesinin özelliklerini gösterir.

Tablo 1.Veri setinin özellikleri.

# Değişken	Türler
# Modeli	nesne
# Araç Sınıfı	Nesne
# Motor Boyutu (dm)3)	yüzen64
# Silindirler	int64
# Bulaşma	int64
# Yakıt Türü	int64
# Yakıt Tüketimi Şehir (L/100 km)	yüzen64
# Yakıt Tüketimi Karayolu (L/100 km)	yüzen64
# Yakıt Tüketimi Comb (L/100 km)	yüzen64
# Yakıt Tüketimi Comb (mpg)	yüzen64
# CO2Emisyonlar (g/km)	int64

Araçlar boyutlarına göre sınıflandırılır. Şekil3araç sınıfı tipini gösterir. Toplamda 16 ayrı araç sınıfı oluşturuldu. Bunları hatchback, sedan, SUV veya kamyon olarak sınıflandırdık. Grafik, arabalar ne kadar büyükse o kadar fazla CO2yayarlar. Sedan, üç kutulu bir tasarımda üretilen ve ayrı olarak yapılmış bir bagaja sahip dört kapılı bir otomobildir, oysa hatchback, iki kutulu bir tasarımda üretilen dört kapılı bir otomobildir. Boyut, konfor ve yakıt verimliliği gibi özellikler karşılaştırıldığında, hatchback ve sedan arasında birkaç küçük ayrım yapılır. Sportif amaçlı araçlar genellikle SUV olarak adlandırılır. SUV, bir minivanın yolcu kapasitesini bir pikap kamyonun arazi becerisi ve çekme kapasitesiyle birleştiren bir tür motorlu araçtır. Bu faktörler göz önüne alındığında, SUV'ler harika açık hava maceraları için harika seçimlerdir. Özellikle, otomobiller ne kadar büyükse, o kadar fazla karbondioksit üretirler. CO'nun en düşük ve en yüksek dörtte birizEmisyonlar sırasıyla kutunun alt ve üst taraflarıyla gösterilmektedir.

CO'nun ortanca ve ortalama düzeylerizher araç için emisyonlar kutuyu yatay olarak ikiye bölen çizgiyle gösterilir. En düşük ve en yüksek dörtte birlik CO2her araç için emisyonlar kutunun ötesine uzanan iki çizgiyle gösterilir. Noktaların maksimum dörtte birini geçtiği alanlar CO'lu alanları temsil eder2Maksimum değerden daha yüksek emisyonlar.



Şekil 3. Araç sınıfları ile karbondioksit emisyonları arasındaki ilişki.

2.2. Ön işleme

"Veri hazırlama" terimi, verilerin bir bilgisayar tarafından okunup anlaşılabilirliği için dönüştürülmesi veya kodlanması için gerçekleştirilmesi gereken eylemleri ifade eder. Doğru ve kesin model tahminleri üretmek için, bunun altında yatan algoritmanın verilerin niteliklerini hızla analiz etme kapasitesine sahip olması gerekir. Verilerin kalitesinin ve bunlardan türetilen yararlı bilgilerin modelimizin öğrenme potansiyeli üzerinde doğrudan bir etkisi olduğu göz önüne alındığında, verilerimizin modelimize beslenmeden önce ön işlenmesi çok önemlidir. Veri ön işleme, makine öğreniminin en önemli aşamalarından biridir. Eksik değerleri doldurma, gürültülü verileri düzeltme, tutarsızlıkları çözme ve aykırı değerleri ortadan kaldırmayı içeren veri hazırlama sürecindeki aşamaya "eksik değerleri doldurma" denir. Veri kümesinde artık toplam 6281 giriş ve 12 özellik sağlanmıştır ve eksik veya yinelenen değerler yoktur. Veri hazırlama, çeşitli kaynaklardan elde edilen verilerin bir veri ambarı gibi tek ve daha kapsamlı bir veri depolama tesisinde birleştirilmesini içerir. Veri işleme adımları Şekil 4'de sunulmuştur.



Şekil 4. Ön işleme adımları.

Bağımsız değişkenlerden veya veri bileşenlerinden oluşan bir grubun normalleştirilmesi, özellik ölçekleme adı verilen bir yöntem kullanılarak gerçekleştirilebilir. Veri işleme alanında, genellikle veri hazırlama aşamasında gerçekleştirilen bu aşama, veri nor-

malization. Min-max ölçekleme veya min-max normalizasyonu olarak da bilinen en basit teknik, [0, 1] aralığındaki aralığı ölçeklemek için özellik aralığını yeniden ölçeklendirmeyi içerir. Bu yöntemin diğer adları min-max ölçekleme ve min-max normalizasyondur. Evrensel normalizasyon formülü aşağıdaki gibidir:

$$\frac{X - X_{\text{dakika}}}{X_{\text{maks}} - X_{\text{dakika}}} \quad (1)$$

2.3. Kaba K-Ortalamlar Kümelemesi (RKM)

Basit bir k-ortalama kümelemesi, [sunulan] RKM kümeleme metodolojisinin temelini oluşturur.[51]. Joshi ve diğerleri. [52] başlangıç konseptinin algoritmasını, yüksek boyutlu verileri yönetmek için, birbirleriyle karşılaştırılabilir mesafeler arasında ayırım yapmak için önerilen yeni yöntem olarak mesafe oranlarını kullanarak yaklaşık bir merkez noktası hesaplayarak geliştirdiler. Saldırı tespiti ile ilgili belirsiz öğeler üzerine yaptıkları çalışmada, Ref. [53] kaba k-ortalamlar ve ECM kümeleme tekniklerini kullandı. Kaba k-ortalamlar yöntemi, kümelerin en üst sınırına ait belirsiz öğeleri belirleme amacıyla geliştirilen bir metodolojidir.

Verileri kullanarak daha düşük bir yaklaşım kümesi ve daha yüksek bir yaklaşım kümesi oluşturun. Her değişken yaklaşık k-ortalaması ile temsil edilir.

(P1) Bir nesne $\vec{x}$ n fazla bir kümenin daha düşük bir yaklaşımının parçası olabilir.

$$(P2) X \in \underline{A} \xrightarrow{(C_{\text{Ben}})} \Rightarrow C \in \text{Bir} \xrightarrow{(c)_{\text{Ben}}} \overline{}$$

(P3) Bir nesneXherhangi bir alt yaklaşımın parçası değildir. M

→ Xiki veya daha fazla kümenin üst yaklaşımına aittir.

Yumuşak kümeleme genel olarak kaba ortalamalar k-testi kavramı olarak. Tüm nesnelere değerler verilir daha düşük ve üst algoritmanın seyri tamamlandığında, her bir arasındaki mesafeyi öge vektörü ve küme merkezi, ile gösterilir $\vec{v}_i$ (v, c_j)'ye dikkate alınabilir. $d(v, c_{Ben}) = \frac{\vec{v} \cdot \vec{c}_{Ben}}{\|\vec{v}\| \|\vec{c}_{Ben}\|}$ az $1 \leq j \leq k$ (v, c_j), Oranlar $\frac{d(v, c_j)}{D(v, c_j)}$, $1 \leq Ben, ben \leq k$, kullanılır katılımcıları tanımlayın. Yani, $T = \{j: \frac{d(v, c_j)}{D(v, c_j)} \geq \frac{d(v, c_{Ben})}{D(v, c_{Ben})} \}$ eşik değerini elde ettik.

1. $T = \text{olması durumunda}$ $\varphi, \vec{v} \in A(C_j)$ $\forall \vec{v} \in A(\vec{C}_j), \forall j \in T$ ayrıca, daha temel bir yaklaşımda görünmüyor. Yukarıda belirtilen koşul, (P3) özelliğinin yerine getirilmesini sağlar.

2. Alternatif olarak, eğer $\vec{T} = \text{ise } \varphi, \vec{v} \in A(C_j)$. Ayrıca, $A()$ (P2)'nin bir karakteristiğidir, $\vec{v} \in A(C_j)$.

Kaba k-ortalamalar yöntemi, tasarımı nedeniyle belirsizlikle başa çıkmak için kararlı ve güvenilirdir. Kaba k-ortalamalar algoritması, öğeleri üst sınır ve alt sınır kategorilerine başarıyla gruplamıştır. Üst sınırdaki bulunan şeyler belirsiz olarak kabul edilirken, alt sınırdaki bulunan nesneler doğru olarak kabul edilir. Üst sınır boş olmamalıdır ve içinde bulunan nesneler, küme numaralarında bulunan bir veya daha fazla üst sınırla bağlantılı olabilir. Şekil 5 gözlemden gelen aykırı değerlerin ele alınmasına ilişkin RKM sonuçlarını gösterir.

CO'daki belirsiz nesnelerzemisyon veri kümeleri derin öğrenme algoritmalarının performansını düşürmüştür. Algoritmayı orijinal verilere uyguladığınızda sonuçların olumlu olmadığı gözlemlenmiştir. Verilerden, sınıflandırma algoritmalarını engelleyen belirsiz nesnelerin olduğu araştırılmıştır. Bu aykırı nesneler, kesin belirsizliği belirlemeye yardımcı olmak için kaba k-ortalama kümeleme ile incelenmiştir. Veri kümesi beş karşılık gelen küme için kümelendirilmiştir ve RKM algoritması aykırı nesneleri üst yaklaşım ve alt yaklaşım olarak kümelemiştir. Bir veya daha fazla küme numarasına ait olan üst yaklaşıma ait nesneler hariç tutulmuştur (aykırı değerler).

Number of iterations: 69

Centroid for cluster 0: 373.32

Lower bound for cluster 0:

13,14,16,18,19,36,46,48,50,52,70,72,73,74,75,112,132,173,175,177,181,182,193,21,3719,3746,3747,3860,3899,3958,3959,3960,3961,3979,4008,4009,4048,4049,4051,405

Boundary region for cluster 0:

15 17 47 51 118 120 122 124 174 176 178 179 194 210 214 216 220 362 387 389 43

Centroid for cluster 1: 310.31

Lower bound for cluster 1:

43,45,49,53,54,55,63,69,71,119,121,123,125,131,134,168,180,184,191,212,241,244,97,1799,1802,1803,1842,1852,1853,1856,1857,1866,1873,1874,1879,1953,1954,1979,369,3373,3431,3433,3435,3446,3449,3450,3451,3470,3478,3479,3480,3485,3502,350,4627,4644,4645,4647,4651,4652,4662,4664,4668,4669,4672,4705,4710,4711,4726,47,5849,5850,5851,5853,5854,5856,5857,5858,5859,5860,5861,5862,5868,5869,5870,5,5,7122,7125,7126,7127,7131,7132,7173,7174,7176,7177,7178,7180,7229,7246,7247,

Boundary region for cluster 1:

15 17 35 44 47 51 57 59 64 104 106 108 110 111 116 117 118 120 122 124 141 174 018 3019 3020 3071 3141 3151 3152 3208 3239 3245 3285 3329 3364 3371 3408 3410 6543 6544 6553 6561 6563 6582 6583 6584 6585 6601 6602 6605 6616 6618 6623 662 Centroid for cluster 2: 185.49

Şekil 5.RKM sonuçlarından bir kesit.


2.4. İstatistiksel Analiz

İstatistiksel analizin birincil odak noktaları verilerin toplanması, işlenmesi, yorumlanması ve sunulmasıdır. Her istatistiksel analizde yapılması gereken ilk şey hedef olguyu karakterize etmektir. Popülasyon, bilinen bir zaman serisine ve sürecin çeşitli dönemlerde gerçekleştiği şekilde gözlemlenmesiyle toplanan verilere dayanır. Verilerin özelliklerini belirlemek için istatistiksel analiz kullanmanın önemi hemen unutulmaz. CO₂'yu tahmin etmek için yürütülen istatistiksel araştırma sonucundadıüzeylerde, daha az karmaşık, daha az girdi kullanan ve işletme maliyeti daha düşük olan istatistiksel modelleri araştırdık. Tablo2istatistiksel analizin bulgularını gösterir. Şekil'e göre6, spor araçlar ve lüks otomobiller daha fazla CO₂ emisyonuna neden oluyor2emisyonları premium ve genel amaçlı araçlara göre daha düşüktür.


Mevcut CO'nun en belirgin özellikleri şunlardır:2veri toplama ana araştırma aracımız olarak işlev görür. Şekil7söz konusu veri kümesinin önemli sayıda aykırı değere sahip olduğunu gösterir, bu da dikkate alınması gereken önemli bir faktördür. Ortalamanın en yüksek ve modun üç ölçünün en düşük olduğu varsayıldığında, CO₂emisyonlar pozitif eğimlidir, bu da gözlemlerin büyük çoğunluğunun ortalama değerin altına düştüğünü göstermektedir [54].

Tablo 2.Duyarlılık analizi sonuçları.

	Motor Boyutu	Yakıt_ Tüketim_ Şehir	Yakıt_ Tüketim_ Karayolu	Yakıt_ Tüketim_ Tarak	Yakıt_ Tüketim_ iyon_ Tarak1	Ortak2_ Emisyonlar
Saymak	6282.00	6282.00	6282.00	6282.00	6282.00	6282.00
Anlam	3.16181	12.61022	9.070583	11.01787	27.411016	25.157752
Sınıf	1.36520	3.553066	2.278884	2.9468	7.245318	59.290426
Dakika	0,9000	4.20000	4.00000	4.100000	11.00000	96.00000
Maksimum	8.40000	30.600000	20.600000	26.100000	69.00000	522.0000



Şekil 6. Veri setinden sınıf otomobil değerlerinin karbondioksit emisyonlarının dağılımı.




Şekil 7. Anlık karbondioksit emisyonlarının kutu grafiği.

Figür8 veri kümesinin kategorik özelliklerinin ortalama değerlerini görüntüler. Kanada yollarında en sık kullanılan otomobil modeli Ford modelidir. Ford


F-150 FFV şu anda Kanada yollarında en iyi bilinen araçlardan biridir. En iyi on araç sınıfı sıralamasına göre, SUV-küçük kategorisi Kanadalı sürücüler arasında en popüler olanıdır. En iyi on şanzıman: binden fazla araç AS6 veya AS8 tipi şanzımanla donatılmıştır. Yakıt türleri: Kanada'daki çoğu otomobil X ve Z yakıt türleriyle çalışır. CO₂ Markaya göre emisyonlar: Kanada yollarındaki araçların çoğu Ford olmasına rağmen, en fazla CO üreten marka Bugatti'dir2

araç başına. CO₂emisyona v/s: Bugatti Chiron, maksimum miktarda CO salan otomotiv modelleri arasında yer alıyoratmosfere CO₂emisyona ve araç sınıfı: Van, SUV ve pikap gibi ağır araçların çoğu, CO emisyonunun en büyük üreticileri arasındadır2Emisyona ve şanzıman: Otomatik şanzımanlı araçların çoğu CO yayar2. Emisyona ve yakıt türü: E yakıt türüne sahip araçlar en fazla CO yayar2. Ortak2emisyona ve yakıt türü: D yakıt türünü kullanan araçlar en az miktarda CO yayar2. NeredeX =normal benzin;Z =premium benzin; D = dizel; E = E85; B = elektrik.



Şekil 8.Kategorik değişkenlerin ve karbondioksit emisyonlarının ortalaması.

Araştırılan yedi faktör arasındaki ilişki Şekil'de gösterilmiştir. ⁹CO üzerinde en büyük etkiye sahip faktörler emisyonları sağlar. Bu prosedürü kullanarak, CO'yu hesaplamak için yedi ayrı faktöre karar verdikçikti. Yüksek negatif korelasyonlar (≤ 0.9) yakıt tüketimi şehir, yakıt tüketimi_tarak ve CO arasında gösterilir2_Emisyonlar, güçlü negatif korelasyonlar (≤ 0.8) silindir sayısı ile motor hacmi arasında ve CO arasında gözlemlenir2 emisyonlar.



Şekil 9.Özellikler ile karbondioksit emisyonları arasındaki korelasyon grafiği.

2.5. Tahmin Modelleri

Uzun seri tahminine dayalı olarak, RNN, gradyan patlaması ve gradyan kaybolmasının getirdiği zorluklar nedeniyle güvenilir değildir. Üstün bellek hücreleri göz önüne alındığında, LSTM tipi RNN, eğitim süreci sırasında gradyan patlaması ve kaybolan gradyanların sorunlarından kaçınabilir. LSTM, türünün tek örneği gizli durumu ve üç düzenleyici kapısı nedeniyle hem uzun hem de kısa vadeli bellekleri kontrol edebilir. Her zaman adımında, LSTM, giriş olarak, şu anda mevcut olan giriş değerini, daha önce elde edilen çıktı değerini ve gizli durumu alır. Bellek durumu, mevcut durumla ilgili önceki dizilerden gelen tüm bilgilerin tutulduğu yerdir [55,56].

Giriş kapısı, unutma kapısı ve çıkış kapısı Şekil'de gösterilmiştir. ¹⁰temel LSTM mekanizmalarını gösterir ve bu kapılar kapıya giriş yaparBent, kapıyı unutFıve çıkış kapısıOtsırasıyla, aşağıdaki matematiksel gösterim kullanılarak ifade edilebilir:

$$B_{ent} = \sigma(B_{Ben} \cdot X_T + B_{Ben} \cdot H_{t-1} + B_{Ben}) \quad (3)$$

$$F_T = \sigma(B_F \cdot X_T + B_F \cdot H_{t-1} + B_F) \quad (4)$$

$$O_T = \sigma(B_O \cdot X_T + B_O \cdot H_{t-1} + V_O \cdot C_T + b_O) \quad (5)$$

Neresi B_{Ben} , B_F , V_O , her biri, önceki zaman adımının çıktı değerinin kombinasyon sonucuna uygulanan ağırlık matrislerini temsil eder ($\cdot H_{t-1}$), öncekinin bellek durumu

zaman adımı (C_t), ve geçerli zaman adımının giriş değeri (x_t), VeB_{Ben}, B_F, VeB_o , her biri sırasıyla o kombinasyon sonucuna uygulanan önyargıyı temsil eder. Bu üç kapının her birini düzenlemek için, sigmoid fonksiyonunu bir aktivasyon fonksiyonu olarak kullandık. Bu strateji, 0 ile 1 arasına düşen negatif olmayan türevlerin üretilmesine olanak tanır.


$$\bar{c} = \tanh(Bc[H_{t-1}x_t] + Bc) \quad (6)$$

$$C_t = (f_t * C_{t-1} + B_{ent} * C) \quad (7)$$

NeresiCbellegin depolama durumunu değiştirmek için kullanılan tanh tipinde olası bir aktivasyon fonksiyonunu temsil eder. Kapıların değerleri tam olarak sıfır veya sıfıra aşırı yakınsa, kapılar kapanır. Kapılara girilen değerler beklenen değerlerle uyuşmuyorsa, kapılar açılır. $f_t=0$ ve $B_{ent}>0$, geçerli giriş adayının bellek durumu unutulmalı ve bunun yerine, önceki giriş adayından gelen bellek durumu yeni bellek durumu olarak kullanılmalıdır.

$$H_t = o_t + \tanh(C_t) \quad (8)$$

Ayrıca, bir çıkış kapısı O_t =verilen geçerli bellek hücresinden okunan değeri belirler H_t LSTM, hareketli kapı mekanizması aracılığıyla bellek durumunun değerini manipüle ederek tüm seri hakkında yararlı bilgiler çıkarabilir. Bu nedenle, LSTM genellikle gelecekteki elektrik yüklerini tahmin etmek için kullanılır.



Şekil 10.LSTM yapısı.


Çift yönlü LSTM

LSTM'nin bir çeşidi olan BiLSTM, hem geriye dönük öğrenme hem de ileriye dönük tahmin için potansiyel gösterir. BiLSTM, zıt yönde yayılan iki LSTM katmanını içerir. İlk LSTM katmanı seri verilerini ileriye dönük olarak görüntülerken, ikinci katman verileri geriye dönük olarak görüntüler. Her LSTM katmanının hesaplaması, tüm BiLSTM mimarileri tarafından paylaşılan LSTM katmanında olduğu gibi Denklemler (3)–(7) ile belirtilir. İkinci LSTM katmanı yalnızca BiLSTM'de ters çevrilir. Şekil 11 iki LSTM katmanının aynı anda zıt yönlerde yayıldığını gösterir. Bir fonksiyon kullanılarak (F), bir toplam, birleştirme veya ortalama olabilen BiLSTM, iki gizli durum dizisini birleştirir—biri ileri yönden ve biri arka yönden. BiLSTM, burada yeni bir dizi geliştirir

her bir element geçmiş ve gelecek bilgilerinin bir melezidir. Atılan adımların ve elde edilen sonuçların diyagramatik bir gösterimi aşağıdaki gibidir:

$$H_T = f(h_T: H_T) \quad (9)$$

Neresi H_T Ve H_T zamanda ileri gizli durumu temsil eder, T Ve H temsil eder zamanda geriye doğru gizli durum T . Final serisi H geçmiş ve gelecekteki her zaman adımının gizli hallerini içerir. N dizideki toplam eleman sayısının tanımlayıcısıdır. Bu şekilde, BiLSTM hem geçmiş hem de gelecek bilgilerini içeren elemanları olan bir akış üretir. Her bir seriyi işleyerek serilerin işlenmesini basitleştirir ve bir serinin tüm elemanlarını her iki yönde de toplayabilir. Zaman serisi tahmini, BiLSTM'nin LSTM modellerinden üstün olduğu bir alandır. Zaman serisi tahminindeki etkinliklerine rağmen, LSTM ve BiLSTM, her iki bileşeninde gözlem ve emisyon periyotlarının ayrıklaştırılması nedeniyle zaman serisinin karmaşık dinamiklerini öğrenme kapasiteleri açısından sınırlıdır. Düğümün sürekli bir sinir ağı olması nedeniyle, daha önce ele alınan LSTM sorununu çözen ebediyen derin bir ağ hala inşa edilebilir. Elektrik yükü tahmini için, hem LSTM hem de BiLSTM mimarilerini kullanarak düğümlerin bir analizini gerçekleştirdik.



Şekil 11. BiLSTM yapısı.

Derin öğrenme modelinin tahmin kapasitesi, hiperparametreler ve modelin yapısı tarafından belirlenir. Bu çalışmada, araç CO'sunu simüle etmek için kullanılacak alternatif alt optimum ağ modellerini değerlendirmek için ağ mimarilerini tanımlayan çeşitli hiperparametre kümelerini karşılaştırdık. 2. Masa 3 Bu çalışma boyunca araştırılan yapıların ve hiperparametrelerin bir listesini ve her birine karşılık gelen arama alanlarının etki alanlarını içerir.

Tablo 3. Derin öğrenme model parametreleri.

Parametreler	Değerler
Birinci katman	100
İkinci katman	100
Üçüncü katman	200
Dördüncü katman	200
yürütme Ortamı	İşlemci

Tablo 3.Devamı

Parametreler	Değerler
miniTopluBoyut	20
maxEpoch'lar	100
Optimizasyoncu	Adem
Öğrenme oranı	0,005

2.6. Değerlendirme Ölçütleri

Son olarak, her modelin performansı, modelin gözlemlenmemiş verileri tahmin etmedeki genelleme becerilerini değerlendirmek için test setinde test edildi. Derin öğrenme modelini değerlendirmek için Ortalama, MSE, RMSE, Pearson'ın R% ve R2 kullanıldı. Tahmin modellerini değerlendirmek için kullanılan istatistiksel metrikler bu araştırma boyunca oluşturuldu. Bu parametreler aşağıda sunulmuştur:

$$MSE = \frac{1}{N} \sum_{ben=1}^N (ve_{ben, \text{üs}} - ve_{ben, \text{pred}})^2 \quad (10)$$


$$RMS = \sqrt{\frac{\sum_{ben=1}^N (ve_{ben, \text{üs}} - ve_{ben, \text{pred}})^2}{N}} \quad (11)$$

$$R2 = 1 - \frac{\sum_{ben=1}^N (e_{ben, \text{üs}} - ve_{ben, \text{pred}})^2}{\sum_{ben=1}^N (ve_{ben, \text{üs}} - se_{nort., \text{üs}})^2} \quad (12)$$


Neresi $ve_{ben, \text{üs}}$ $ve_{ben, \text{pred}}$ CO'lar mız sırasıyla gözlem ve tahmin değerleri.

3. Modelleme Sonuçları

Hava kirliliğinin sağlıksız seviyelerinden çoğunlukla araç trafiği ve kirleticileri sorumlu tutulmaktadır, örneğin CO₂, özellikle ücretli yol koridorları boyunca, nüfuslu şehirlerde. Bazı modeller CO'nun sonuçlarını değerlendirmek için kullanılır. Zulaşımından kaynaklanan emisyonları hem insanlara hem de çevreye yansıtırken, diğer modeller bu emisyonların coğrafi tahminini göstermek üzere tasarlanmıştır. Deney için MATLAB 2020 yazılımını kullandık. Makinenin fiziksel yapılandırması, bileşenlerinin bir parçası olarak 2,8 GHz Intel i7 Dört Çekirdekli CPU ve 8 GB belleğe sahipti. Önceki araştırmalarla karşılaştırıldığında, bu örneklem boyutu hala oldukça küçüktür. Buna karşılık, aşırı uyum sorunlarıyla başa çıkmak için etkili bir strateji gerektirir. İlk modelde, araç sınıfı, motor hacmi (L), silindir şanzımanı, yakıt türü, yakıt tüketimi şehir içi (L/100 km), yakıt tüketimi otoyol (L/100 km), yakıt tüketimi tarak (L/100 km), yakıt tüketimi tarak (mpg) ve emisyonlar (g/km) model için kullanılan girdi değişkenleridir. Veri normalizasyonu için, maksimum-minimum yaklaşımı kullanıldı. Ortalama karesel hata (MSE), kök MSE (RMSE), R% ve belirleme katsayısı (R2), oluşturulan modelin doğru tahminler üretme kapasitesinin değerlendirilmesinde kullanılan dört istatistiksel özelliktir. Derin öğrenme modelleri, araç CO₂ gibi doğrusal olmayan sorunların karmaşık simülasyonlarını temsil edebilir2 emisyon. Bu kapasite, hesaplama gücündeki son gelişmeler sayesinde mümkün oldu. LSTM ve biLSTM yöntemlerinin eğitim süreci şekillerde gösterilmiştir12Ve13.



Şekil 12.Uzun kısa süreli bellek ağı modelinin eğitim süreci.




Şekil 13.Çift yönlü uzun kısa süreli bellek ağı modelinin eğitim süreci.

3.1. Eğitim Sonuçları

Eğitim prosedürü, belirli deneysel verileri kullanarak oldukça etkili bir model geliştirme sürecinde önemli bir adımdır. Sürecin bu aşamasında veri kümelerinin yaklaşık %80'i bu amaç için kullanılmıştır. Şekil14hem oluşturulan LSTM hem de BiLSTM modellerinin performansını gösterir ve Tablo3değerlendirme metriklerinin değerlerini sunar. CO'nun öngörülen değerleriz% (Y eksen) ve deneysel

değerler (X eksen) Şekil'de gösterildiği gibi tüm veri kümelerinde tamamen tutarlıdır14ve Tablo4, sırasıyla. Oluşturulan LSTM ve BiLSTM modelleri, BiLSTM'nin yüksek R% (97.07%) ve R2 (93.78) değerlerine ve son derece düşük MSE ve RMSE değerlerine sahip olması durumunda test edilmeye hazırdır. Bu değerler, sistemin belirtilen hedeflere ulaşabileceğini gösterir.



Şekil 14.Karbondioksit eğitiminin regresyon grafiği (A) LSTM (B) BiLSTM modelleri.

Tablo 4.LSTM ve BiLSTM modellerinin eğitim aşamasında karbondioksit emisyonlarını tahmin etme sonuçları.


Modeller	#MSE	#RMSE	# R (%)	R2(%)
LSTM modeli	0,004980	0,07057	90.47	77.81
BiLSTM modeli	0,001177	0,0343	97.07	93.78

3.2. Test Sonuçları

LSTM ve BiLSTM modellerini doğrulamak için test aşamasında veri kümelerinin %20'sinden daha önce görülmemiş veriler kullanıldı. Şekil12ve Tablo5sırasıyla hem LSTM hem de BiLSTM modelleri için test sonuçlarını gösterir. Şekil15tahmin edilen değerler ile beklenen değerler (deneysel) arasında güçlü bir korelasyon olduğunu gösterir. Ek olarak, MSE ve RMSE değerleri sırasıyla 0,0012 ve 0,0035'te olağanüstü düşüktü, oysa R% ve R2değerler sırasıyla %97,07 ve 0,93,78'de son derece yüksekti. CO'yu tahmin etmek için BiLSTM modelinin doğruluğuzemisyonlar, hükümetin kirliliğin artmasını önleme kararları almasına yardımcı olabilir. Sonuçlarımız, BiLSTM modelinin tahminlerde en yüksek kesinlik derecesine sahip olduğunu göstermektedir.

Tablo 5.LSTM ve BiLSTM modellerinin test aşamasında karbondioksit emisyonlarını tahmin etme sonuçları.

Modeller	#MSE	#RMSE	# R (%)	# R2(%)
LSTM modeli	0,005075	0,07125	90.14	75,73
BiLSTM modeli	0.0012678	0,03560	96,95	93.55



Şekil 15.Karbondioksit testinin regresyon grafiği (A) LSTM (B) BiLSTM.

4. Tartışma


Motorlu taşıtlardan kaynaklanan emisyonlar hem iklim hem de soluduğumuz havanın kalitesi üzerinde önemli bir etkiye sahip olmaya devam ediyor. Dünya çapında birçok bölgede, hafif ve ağır hizmet tipi taşıtların test edilmesini düzenleyen düzenlemeler şu anda gözden geçiriliyor ve kirleticiler için sıkı emisyon sınırları ve iklim politikaları ve hedefleri şu anda geliştiriliyor.

CO₂ emisyonlarını azaltmak için en etkili stratejileri seçmeye gelinezemisyonları, bu emisyonların doğru bir şekilde tahmin edilmesi önemlidir. Çünkü CO₂'yi hesaba katarlar2Çeşitli araç tipleri tarafından üretilen bu araştırmanın bir parçası olarak geliştirilen modeller, CO₂'yi tahmin etmede önemli ölçüde daha doğrudur2Mevcut modellerden bazılarının halihazırda mevcut ve geliştirilmiş olmasına rağmen, emisyonları mevcut modellerden herhangi birinden daha düşüktür.


İnsan hayatı ve inşa edilmiş çevre üzerindeki olumsuz etkileri göz önüne alındığında, kirlilik dünya çapında büyük bir sorun olarak kabul edilmektedir. Bu nedenle, CO tahmininde bulunmak için doğru modelleme stratejileri gereklidir.2megakentler gibi yoğun nüfuslu yerlerdeki emisyonlar. CO üzerine çalışmalar2emisyonlar yakın zamanda LSTM ve BiLSTM gibi derin öğrenme algoritmalarının kullanımıyla önemli bir umut vadetmektedir. Bu makalede, CO tahmininde yeni bir teknik sağladık2Derin öğrenmeye dayalı araçlardan kaynaklanan emisyonlar. Yaklaşımımız hem yüksek kullanım doğruluğu hem de pratiklik elde etme potansiyeline sahiptir. Farklı araç tiplerinden ve çalışma parametrelerinden gelen veriler yerleşik tanılama arayüzünden elde edildi ve egzoz emisyonları ile ilgili tahminlerde bulunmak için kullanıldı. Bu parametreler şunları içeriyordu: araç sınıfı, motor_boyutu (L), silindir sayısı, şanzıman türü, yakıt türü, yakıt_tüketimi_şehir (L/100 km), yakıt_tüketimi_karayolu (L/100 km), yakıt_tüketimi_şehir_tarak (L/100 km), yakıt_tüketimi_şehir_tarak (mpg) ve CO₂ emisyonlar (g/km). Her parametrenin emisyon tahminindeki göreceli önemi, R²'yi karşılaştırarak ve zıtlıştırarak ayrıntılı olarak analiz edildi. Modelin CO tahminindeki doğruluğuzemisyonlar girdi olarak kullanılan elementlerin sayısı ile orantılıdır. Ne kadar çok bileşen olursa o kadar iyidir. Buna rağmen, elde edilebilecek doğruluk artışı miktarı girdi için parametreler tarafından belirlenir.

Rakamlar16Ve17CO'yu tahmin etmek için eğitim ve testin histogram hatasını göster zemisyonları. Eğitim aşamasında LSTM ve BiLSTM modelleri için ortalama hatalar sırasıyla 0,0000568 ve 0,00399 idi. Test aşamasında LSTM ve BiLSTM modellerinin ortalama histogram hataları sırasıyla 0,0457 ve 0,0457 idi. Son olarak, bu bulgu BiLSTM modelinin daha az tahmin hatası elde ettiğini göstermektedir.

Önerilen sistem BiLSTM ile çeşitli tahmin modelleri arasındaki karşılaştırma Tablo'da gösterilmektedir6.



Şekil 16.Eğitim adımında histogram hatası (A) LSTM (B) İkili-LSTM.



Şekil 17.Test adımında histogram hatası (A) LSTM (B) İkili-LSTM.

Tablo 6.Tahmin sonuçlarının karşılaştırılması Cozemisyon ve modelimiz.

Referans	Örnek	RMSE
Referans [57]	Yapay Sinir Ağı	1.286
	SVR	2.752
Referans [58]	uzun kısa süreli bellek ağı	0,1648
Referans [59]	Yapay Sinir Ağı	2,95
Referans [60]	Destek Vektör Regresörü (SVR)	0,71
Referans [61]	Rastgele orman ağacı	MAE = 0,58
Önerilen	BiLST	0,03560

5. Sonuçlar

Artan CO seviyelerizemisyolları, hem doğrudan hem de dolaylı olarak insan sağlığı üzerinde çeşitli olumsuz sonuçlara yol açmıştır. Yüksek miktarlarda bulunduğunda, dispne, körlük, vertigo ve hatta deliryum gibi ciddi hastalıklara yol açabilir. Yüksek düzeyde CO₂ emisyonu, iklim değişikliği, asit yağmuru ve küresel ısınma gibi küresel sorunların gelişimine katkıda bulunur. Bu nedenle, CO modellemesi ve tahminizCO emisyonunun gelecekteki değerlerinin tahmin edilmesi açısından çok önemlidirzemisyonu. CO modellemesi ve tahmini hakkında aşağıdaki çıkarımlar yapılabilir2Motorlu taşıtlardan kaynaklanan emisyonlar:

- Araç CO₂ emisyonu için yapay zeka algoritmalarına dayalı istihbarat sistemi tahmin modellerinin geliştirilmesizCO emisyonları halk sağlığı ve hükümetin harekete geçme kapasitesi için önemlidir,2Önümüzdeki birkaç on yıldaki emisyonların doğru bir şekilde tahmin edilebilmesi gerekiyor.
- Mevcut araştırmalara göre CO'nun sonuçlarızemisyonları birçok ülkede gözlemlenmektedir. İnsanların hayatta kalma olasılığını artırmak için yapabileceğimiz şeylerden biri de zararlı CO miktarını azaltmaktırzemisyonları. CO modelini araştırmak için2Emisyonları hesaplamak için derin öğrenmeye dayalı bir zaman serisi modeli kullandık.
- Modelin temel performans göstergelerine ilişkin performansı analiz edildikten sonra, gelecekteki tahminler için uygun bir model seçildi. Son çalışmaların bulgularına göre, LSTM ve BiLSTM modelleri, hassas CO için kullanılabilecek diğer modellerle karşılaştırıldığında en iyi performansı sağlar.zemisyon tahmini.
- Son araştırmaların bulgularına göre, LSTM ve BiLSTM modelleri hassas CO ölçümü için kullanılabilecek diğer modellerle karşılaştırıldığında en iyi performansı sağlamaktadır.2emisyon tahmini. Modellerin performansını değerlendirmek için CO ile ilgili 7 yıllık verileri kullandıkzemisyonları. En başarılı model, 0,00126'lık bir MSE, 0,03560'lık bir RMSE ve R'ye sahip olan BiLSTM idi.2%93,35'lik. Bu rakamlar performans ölçümleri için gözlemlenen değerlerden türetilmiştir. Bu yöntemi kullanarak CO ile ilgili tahminlerde bulunabilirizzemisyonların tek bir boyutta ele alınması.
- Gelecekteki hükümet eylemleri, yenilenebilir enerji kaynaklarına geçiş, ekonomik ilerleme gibi dışsal faktörlerin gelecekte incelenebileceği bazı örnekler olmak üzere henüz pek çok boyut henüz netleşmedi.

Yazar Katkıları:THHA ve AHA-N. kaynakları, THHA veri düzenlemesi, AHA-N. ve AHA-N.; yazma - orijinal taslak hazırlama, THHA ve AHA-N. yazma - inceleme ve düzenleme, AHA-N.; görselleştirme, THHA ve AHA-N. denetim, THHA; proje yönetimi, THHA ve AHA-N.; fon edinimi, THHA ve AHA-N. Tüm yazarlar makalenin yayınlanmış versiyonunu okumuş ve kabul etmiştir.

Finansman:Bu araştırma ve APC, Suudi Arabistan Eğitim Bakanlığı Araştırma ve İnovasyon Başkan Yardımcılığı tarafından INST069 proje numarasıyla finanse edilmiştir.

Veri Kullanılabilirliği Beyanı:<https://www.kaggle.com/datasets/debajyotipodder/co2-emisyonu-araclar>(son erişim Aralık 2022).

Teşekkürler:Bu araştırma ve APC, Suudi Arabistan Eğitim Bakanlığı Araştırma ve İnovasyon Başkan Yardımcılığı tarafından INST069 proje numarasıyla finanse edilmiştir.

Çıkar Çatışmaları:Yazarlar herhangi bir çıkar çatışması olmadığını beyan etmektedir.

Referanslar

1. Klemm, C.; Wiese, F. Enerji sistemi modellemesine dayalı sürdürülebilir kentsel enerji sistemlerinin optimizasyonuna yönelik göstergeler. Enerji Sürdürülebilirliği Soc.**2022**,12,3. [ÇaprazRef]
2. Sajede, A.; Mohsen, S.; Fahime, M.; Borna, A. Farklı ulaşım türlerinde kirletici emisyonlarını etkileyen faktörler. Enerji Temsilcisi **2022**,8,2508–2529.
3. Menendez, M.; Ambühl, L. Sürdürülebilir Hareketlilik için Tasarım ve Operasyonel Önlemlerin Uygulanması: Zürih'ten Dersler. Sürdürülebilirlik**2022**,14,625. [ÇaprazRef]
4. Guo, Y.; Ma, Z.; Ren, B.; Zhao, B.; Liu, P.; Zhang, J. Kontrollü Salımlı Gübreye Eklenen Humik Asidin Yaz Mısır Verimi, Azot Kullanım Verimliliği ve Sera Gazı Emisyonu Üzerindeki Etkileri.Tarım**2022**,12,448. [ÇaprazRef]

5. Fang, D.; Mueller, C. Modern ahşap konstrüksiyon için geçmeli birleştirme: Alternatif bir yapısal bağlantının somut karbonunun nicelenmesi. *Mimari Yapı İnş.* **2021**, *3*, 11–24. [[ÇaprazRef](#)]
6. Gorka, M.; Bezyk, Y.; Sowka, I. Belediye Atık Depolama Sahası Yakınlarında Sera Gazı Etkileşimlerinin Değerlendirilmesi—Vaka Çalışması. *Enerjiler* **2021**, *14*, 8259. [[ÇaprazRef](#)]
7. Stubenrauch, J.; Garske, B.; Ekdardt, F.; Hagemann, K. Avrupa Orman Yönetişimi: Statüko ve Paris İklim Hedefi ile İlgili Seçeneklerin Optimize Edilmesi. *Sürdürülebilirlik* **2022**, *14*, 4365. [[ÇaprazRef](#)]
8. IEA (Uluslararası Enerji Ajansı). Veriler ve İstatistikler: “Sektöre Göre CO2 Emisyonları, Dünya 1990–2019”. Çevrimiçi olarak mevcuttur: <https://www.iea.org/data-and-statistics/data-browser?country=WORLD&fuel=CO2%20emissions&indicator=CO2BySector> (10 Şubat 2023'te erişildi).
9. ProAire. Meksika'da Calidad del Aire'nin En İyi Programı 2011–2020. Çevrimiçi olarak mevcuttur: https://www.gob.mx/cms/uploads/attachment/file/69289/12_ProAire_Mexicali.pdf (10 Şubat 2023'te erişildi).
10. Zhang, H.; Mu, J.E.; McCarl, B.A.; Yu, J. İklim değişikliğinin küresel enerji kullanımına etkisi. *Azaltma. Uyarlama. Strateji. Küresel. Değişim.* **2022**, *27*, 9. [[ÇaprazRef](#)]
11. Garrido, P. CO2 Gran Santiago'da özel ulaşım yöntemiyle nüfusun yer değiştirmesinden kaynaklanan emisyonlar. *Coğrafya Rev.* **2013**, *3*, 69–86.
12. Obaid, M.; Torok, A. Otonom Araç Etkilerinin Makroskobik Trafik Simülasyonu. *Araçlar* **2021**, *3*, 187–196. [[ÇaprazRef](#)]
13. Bastien, L.A.; McDonald, B.C.; Brown, N.J.; Harley, R.A. Eşlenik duyarlılık analizi kullanılarak kentsel hava kirliliğine katkıda bulunan kaynakların yüksek çözünürlüklü haritalanması: Benzen ve dizel siyah karbonu. *Çevre. Bilim. Tekn.* **2015**, *49*, 7276–7284. [[ÇaprazRef](#)] [[PubMed](#)]
14. Fameli, K.M.; Assimakopoulos, V.D. Yunanistan ve Büyük Atina Bölgesi için bir karayolu taşımacılığı emisyon envanterinin geliştirilmesi: Önemli parametrelerin etkileri. *Bilim. Toplam Çevre.* **2015**, *505*, 770–786. [[ÇaprazRef](#)] [[PubMed](#)]
15. Borge, R.; Narros, A.; Artinano, B.; Yagüe, C.; Gomez-Moreno, F.J.; de la Paz, D.; Quaassdorff, C. Kapsamlı bir saha çalışması yoluyla Madrid'deki (İspanya) kentsel bir sıcak noktadaki hava kirliliğinin mikro ölçekli mekansal-zamansal değişiminin değerlendirilmesi. *Atmosfer. Çevre.* **2016**, *140*, 432–445. [[ÇaprazRef](#)]
16. Oftedal, B.; Krog, N.H.; Pyko, A.; Eriksson, C.; Graff-Iversen, S.; Haugen, M.; Aasvang, G.M. Karayolu trafik gürültüsü ve obezite belirteçleri - popülasyona dayalı bir çalışma. *Çevre. Res.* **2015**, *138*, 144–153. [[ÇaprazRef](#)] [[PubMed](#)]
17. Ancona, C.; Badaloni, C.; Mattei, F.; Cesaroni, G.; Stafoggia, M.; Forastiere, F. Roma'da Hava Kirliliği, Gürültü ve Yeşil Alan Eksikliğinin Sağlık Üzerindeki Etki Değerlendirmesi. *J. Transp. Sağlık* **2017**, *5*, S42–S43. [[ÇaprazRef](#)]
18. Garshick, E.; Laden, F.; Hart, J.E.; Caron, A. ABD gazilerinde ana yola yakın ikamet ve solunum semptomları. *Epidemioloji* **2003**, *14*, 728. [[ÇaprazRef](#)]
19. Delfino, R.J.; Tjoa, T.; Gillen, D.L.; Staimer, N.; Polidori, A.; Arhami, M.; Longhurst, J. Koroner arter hastalığı olan yaşlı bireylerde trafik ile ilişkili hava kirliliği ve kan basıncı. *Epidemioloji* **2010**, *21*, 396–404. [[ÇaprazRef](#)]
20. Crouse, D.L.; Goldberg, M.S.; Ross, N.A.; Chen, H.; Labrèche, F. Postmenopozal meme kanseri, Kanada Montreal'de trafik kaynaklı hava kirliliğine maruz kalmayla ilişkilidir: Bir vaka kontrol çalışması. *Çevre. Sağlık Perspektifi.* **2010**, *118*, 1578. [[ÇaprazRef](#)]
21. Hong, S.; Zhang, K.; Bagheri, M.; Burken, J.G.; Gu, A.; Li, B.; Ma, X.; Marrone, B.L.; Ren, Z.; Schrier, J.; ve diğerleri. Makine Öğrenimi: Çevre Bilimi ve Mühendisliğinde Yeni Fikirler ve Araçlar. *Çevre. Bilim. Tekn.* **2021**, *55*, 12741–12754.
22. Junepyo, C.; Park, J.; Lee, H.; Chon, M.S. Gerçek Dünya CO için Regresyon Analizine Dayalı Tahmin Çalışması Hafif Hizmet Dizel Araçlarında Emisyonlar. *Uluslararası Otomotiv Teknolojileri J.* **2021**, *22*, 569–577.
23. Aldhyani, T.H.; Alkahtani, H. Körfez Ülkelerinde COVID-19'u Tahmin Etmek İçin İki Yönlü Uzun Kısa Süreli Bellek Modeli Algoritması. *Hayat* **2021**, *11*, 1118. [[ÇaprazRef](#)]
24. Hashemi, N.; Clark, N.N. Güney Kaliforniya'daki Ağır Hizmet Dizel Araçlarından Kaynaklanan Emisyonlar İçin Tahmini Bir Araç Olarak Yapay Sinir Ağı. *Uluslararası J. Motor Araştırması* **2007**, *8*, 321–336. [[ÇaprazRef](#)]
25. Jigu, S.; Yun, B.; Park, J.; Park, J.; Shin, M.; Park, S. Entegre Yapay Sinir Ağı ve Araç Dinamiği Modeline Dayalı Dizel Hafif Hizmet Araçlarından Anlık Gerçek Dünya Emisyonlarının Tahmini. *Bilim. Toplam Çevre.* **2021**, *786*, 147359.
26. Pai, P.S.; Rao, B.S. Farklı Enjeksiyon Zamanlamalarında Biyodizel Olarak WCO Kullanan Değişken Sıkıştırma Oranlı Bir CI Motorunun Performans ve Emisyon Özelliklerinin Yapay Sinir Ağı Tabanlı Tahmini. *Uygulama Enerji* **2011**, *88*, 2344–2354.
27. Cai, M.; Yin, Y.; Xie, M. Yapay Sinir Ağı Yaklaşımı Kullanılarak Kentsel Arterlerin Yakınlarındaki Saatlik Hava Kirlilik Konsantrasyonlarının Tahmini. *Transp. Res. Kısım D Transp. Çevre.* **2009**, *14*, 32–41. [[ÇaprazRef](#)]
28. Jaikumar, R.; Nagendra, S.S.; Sivanandan, R. Heterojen Trafik Koşulları Altında Binek Otomobillerin Gerçek Zamanlı Egzoz Emisyonlarının Modellenmesi. *Atmosfer. Kirlilik. Ar.* **2016**, *8*, 80–88. [[ÇaprazRef](#)]
29. Singh, D.; Kumar, A.; Kumar, K.; Singh, B.; Mina, U.; Singh, B.B.; Jain, V.K. O'nun istatistiksel modellemesi Ticari bir kompleksteki NOx, CO, PM2.5, VOC ve gürültü seviyeleri ile akademik bir kurumdaki ilişkili sağlık riski değerlendirmesi. *Bilim. Toplam Çevre.* **2016**, *572*, 586–594. [[ÇaprazRef](#)] [[PubMed](#)]
30. Behera, S.N.; Sharma, M.; Mishra, P.K.; Nayak, P.; Damez-Fontaine, B.; Tahon, R. NO'nun pasif ölçümü ve kentsel çevrede mekansal olarak dağıtılmış hava izleme ağı oluşturmak için CBS'nin uygulanması. *Kentsel İklim.* **2015**, *14*, 396–413. [[ÇaprazRef](#)]
31. Johnson, M.; Isakov, V.; Touma, J.S.; Mukerjee, S.; Özkaynak, H. Kentsel bir alanda hava kalitesi konsantrasyonlarını tahmin etmek için kullanılan arazi kullanım regresyon modellerinin değerlendirilmesi. *Atmosfer. Çevre.* **2010**, *44*, 3660–3668. [[ÇaprazRef](#)]
32. Kanaroglou, P.S.; Adams, M.D.; De Luca, P.F.; Corr, D.; Sohel, N. Mekansal otoregresif bir modelle kükürt dioksit hava kirliliği konsantrasyonlarının tahmini. *Atmosfer. Çevre.* **2013**, *79*, 421–427. [[ÇaprazRef](#)]

33. Vandaele, N.; Van Woensel, T.; Verbruggen, A. Kuyruk tabanlı bir trafik akışı modeli. *Transp. Res. Kısım D Transp. Çevre*. **2000**, *5*, 121–135. [[ÇaprazRef](#)]
34. Tomić, J.; Bogojević, N.; Pljakić, M.; Šumarac-Pavlović, D. Farklı esnek hesaplama teknikleri kullanılarak kentsel alanlardaki trafik gürültüsü seviyelerinin değerlendirilmesi. *J. Acoust. Soc. Am.* **2016**, *140*, EL340–EL345. [[ÇaprazRef](#)]
35. Hamad, K.; Khalil, MA; Shanableh, A. Yapay sinir ağları kullanılarak sıcak bir iklimde yol trafiği gürültüsünün modellenmesi. *Transp. Res. Bölüm D. Transp. Çevre*. **2017**, *53*, 161–177. [[ÇaprazRef](#)]
36. Di Mascio, P.; Di Vito, M.; Loprencipe, G.; Ragnoli, A. GPS verilerini kullanarak yol hizalamasının geometrisini belirleme prosedürü. *Procedia-Sosyal Davranış Bilimleri* **2012**, *53*, 1202–1215. [[ÇaprazRef](#)]
37. Hamrani, A.; Akbarzadeh, A.; Madramootoo, CA Tarımsal Topraklardan Sera Gazı Emisyonlarının Tahmini İçin Makine Öğrenimi. *Bilim. Toplam Çevre*. **2020**, *741*, 140338. [[ÇaprazRef](#)]
38. Tao, J.; Zhang, P.; Chen, B. Araç CO'nun Mikroskobik ModelizDerin Öğrenmeye Dayalı Emisyonlar - Çin'in Wuhan Şehrindeki Taksilerin Zamansal ve Mekansal Analizi. *IEEE Çev. Intel. Transp. Sistem* **2022**, *23*, 18446–18455.
39. Wang, A.; Xu, J.; Zhang, M.; Zhai, Z.; Song, G.; Hatzipoulou, M. Gerçek dünya metropol trafik koşullarında hibrit bir elektrikli aracın emisyonları ve yakıt tüketimi. *Uygulama Enerji* **2022**, *306*, 118077. [[ÇaprazRef](#)]
40. Singh, M.; Dubey, R. Derin Öğrenme Modeli Tabanlı CO2 Araç Telematik Sensör Verilerini Kullanarak Emisyon Tahmini. *IEEE Trans. Intell. Veh.* **2021**, *8*, 768–777. [[ÇaprazRef](#)]
41. Maździel, M.; Jaworski, A.; Kuszewski, H.; Woś, P.; Campisi, T.; Lew, K. CO'nun GelişimizMakine Öğrenmesi Tekniklerinin Kullanımıyla Tam Hibrit Aracın Anlık Emisyon Modeli. *Enerjiler* **2021**, *15*, 142. [[ÇaprazRef](#)]
42. Xie, H.; Zhang, Y.; He, Y.; You, K.; Fan, B.; Yu, D.; Lei, B.; Zhang, W. PEMS ve OBD kullanarak araç emisyonlarının tahmin modelinin oluşturulması için paralel dikkat tabanlı LSTM. *Ölçüm* **2021**, *185*, 110074. [[ÇaprazRef](#)]
43. Shahnavaz, F.; Akhavan, R. Eylemsizlik Sensörleri ve Makine Öğrenme Modelleri Kullanılarak İnşaat Ekipmanı Emisyonunun Otomatik Tahmini. *Sürdürülebilirlik* **2022**, *14*, 2750. [[ÇaprazRef](#)]
44. Xayasouk, T.; Lee, H.; Lee, G. Uzun Kısa Süreli Bellek (LSTM) ve Derin Otokoder (DAE) Modellerini Kullanarak Hava Kirliliği Tahmini. *Sürdürülebilirlik* **2020**, *12*, 2570. [[ÇaprazRef](#)]
45. Wang, X.; Yan, C.; Liu, W.; Liu, X. Kazan Besleme Suyunu Etkileyen Faktörlerle SSA-LSTM Algoritmasına Dayalı Termik Santral Karbon Emisyonu Tahmin Modeli Üzerine Araştırma. *Sürdürülebilirlik* **2022**, *14*, 15988. [[ÇaprazRef](#)]
46. Gu, B.; Zhang, T.; Meng, H.; Zhang, J. Uzun kısa vadeli hafızaya, bulut modeline ve parametrik olmayan çekirdek yoğunluk tahminine dayalı rüzgar gücünün kısa vadeli tahmini ve belirsizlik analizi. *Yenile. Enerji* **2021**, *164*, 687–708. [[ÇaprazRef](#)]
47. Sakshi, KVA Canlı veriler kullanarak borsa tahmini için bir ARIMA-LSTM hibrit modeli. *Mühendislik Bilimi ve Teknolojisi Dergisi* **2020**, *13*, 117–123. [[ÇaprazRef](#)]
48. Dave, E.; Leonardo, A.; Jeanive, M.; Hanafiah, N. ARIMA-LSTM hibrit modeli kullanılarak Endonezya ihracatının tahmini. *Procedia Bilgisayar Bilimleri* **2021**, *179*, 480–487. [[ÇaprazRef](#)]
49. Huang, S.; Shen, J.; Lv, Q.; Zhou, Q.; Yong, B. Kısa Vadeli Elektrik Yüğü Tahmini için LSTM ile Birleştirilmiş Yeni Bir NODE Yaklaşımı. *Geleceğin İnterneti* **2023**, *15*, 22. [[ÇaprazRef](#)]
50. Al-Nefae, AH; Aldhyani, THH Gelişmekte Olan Suudi Borsalarında Kapanış Fiyatının Tahmini: Zaman Serisi Modelleri. *Elektronik* **2022**, *11*, 3443. [[ÇaprazRef](#)]
51. Lingras, P.; West, C. Kaba k-ortalamarla web kullanıcılarının aralık kümesi kümelemesi. *J. İstihbarat Sistemleri* **2004**, *23*, 5–16. [[ÇaprazRef](#)]
52. Aldhyani, TH; Joshi, MR Saldırı tespitinde belirsiz paketlerin ele alınması. 3. Uluslararası Sinyal İşleme, İletişim ve Ağ Konferansı (ICSCN) Bildirilerinde, Chennai, Hindistan, 26–28 Mart 2015.
53. Hartigan, JA; Wong, MA Algoritma AS 136: Bir k-ortalamar kümeleme algoritması. *Uygulama Stat.* **1979**, *28*, 100–108. [[ÇaprazRef](#)]
54. Wada, K. Resmi istatistiklerdeki aykırı değerler. *Jpn. J. Stat. Veri Bilimi*. **2020**, *3*, 669–691. [[ÇaprazRef](#)]
55. Al-Nefae, AH; Aldhyani, THH Bitcoin Fiyat Tahmini ve Ticareti: Veri Analitiği Yaklaşımları. *Elektronik* **2022**, *11*, 4088. [[ÇaprazRef](#)]
56. Al-Adhaileh, MH; Aldhyani, TH Suudi Arabistan'da gıda güvenliğini artırmak için ürün verimini modelleme ve tahmin etme amaçlı yapay zeka çerçevesi. *Peer J. Bilgisayar Bilimleri*. **2022**, *8*, e1104. [[ÇaprazRef](#)] [[PubMed](#)]
57. Azeez, OS; Pradhan, B.; Shafri, HZM; Shukla, N.; Lee, C.-W.; Rizeei, HM Yapay Sinir Ağları Kullanılarak Trafik Araçlarından Kaynaklanan CO2 Emisyonlarının Modellenmesi. *Uygulamalı Bilimler* **2019**, *9*, 313. [[ÇaprazRef](#)]
58. Zhang, R.; Wang, Y.; Pang, Y.; Zhang, B.; Wei, Y.; Wang, M.; Zhu, R. CO2'yi Tahmin Etmek İçin Derin Öğrenme Mikro Ölçekli Bir Model Gerçek Dünya Sürüşüne Dayalı Hafif Hizmet Dizel Kamyonlarından Kaynaklanan Emisyonlar. *Atmosfer* **2022**, *13*, 1466. [[ÇaprazRef](#)]
59. Debone, D.; Martins, TD; Miraglia, SGEK Brezilya'nın En Yüksek Ekonomik Kutbu ve Büyük Kentsel Yayıncının Karbon Salınımının Modellenmesi: Klasik Yöntemler ve Yapay Sinir Ağlarının Karşılaştırılması. *İklim* **2022**, *10*, 9. [[ÇaprazRef](#)]
60. Chadha, AS; Shinde, Y.; Sharma, N.; De, PK Makine Öğrenimini Kullanarak Araçlar Tarafından CO2 Emisyonlarının Tahmini. *Veri Yönetimi, Analitiği ve İnovasyonu*; Goswami, S., Barara, IS, Goje, A., Mohan, C., Bruckstein, AM, Eds.; ICDMAI 2022. Veri Mühendisliği ve İletişim Teknolojileri Üzerine Ders Notları; Springer: Singapur, 2023; Cilt 137. [[ÇaprazRef](#)]
61. Shah, S.; Thakar, S.; Jain, K.; Shah, B.; Dhagel, S. Arabalardaki CO2 Emisyonunun Tahmini İçin Makine Öğrenmesi ve Derin Öğrenme Tekniklerinin Karşılaştırmalı Bir Çalışması. *arXiv* **2022**, arXiv:2211.08268.

Yasal Uyarı/Yayıncının Notu: Tüm yayınlarda yer alan ifadeler, görüşler ve veriler yalnızca bireysel yazar(lar) ve katkıda bulunan(lar) aittir ve MDPI ve/veya editör(ler) e ait değildir. MDPI ve/veya editör(ler), içerikte atıfta bulunulan herhangi bir fikir, yöntem, talimat veya üründen kaynaklanan herhangi bir kişi veya mal yaralanmasından sorumlu değildir.