

HİBRİT DERİN ÖĞRENME ALGORİTMALARI KULLANILARAK BİYOGAZ REFORM SÜREÇLERİNİN OPTİMİZASYONU: CNN-LSTM MODELİ İLE ÇIKTI PARAMETRELERİNİN TAHMİNİ

Saadin OYUCU^{1*}, Münür Sacit HERDEM²

¹Adiyaman Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Adiyaman, 02040, Türkiye

²Adiyaman Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Adiyaman, 02040, Türkiye

Geliş Tarihi/Received Date: 23.05.2024 Kabul Tarihi/Accepted Date: 26.07.2024 DOI: 10.54365/adyumbd.1488710

ÖZET

Bu çalışma, biyogaz reform süreçlerinde çeşitli çıktı parametrelerini tahmin etmek için Evrişimli Sinir Ağları (CNN: Convolutional Neural Networks) ve Uzun Kısa Süreli Bellek (LSTM: Long Short-Term Memory) algoritmalarını birleştiren hibrit bir derin öğrenme modelinin uygulamasını incelemektedir. Çalışmanın amacı, bu süreçlerin yönetimini iyileştiren tahmine dayalı modeller geliştirmektir. CNN-LSTM modeli, zaman serisi verilerindeki uzun vadeli bağımlılıkları ve karmaşık özellikleri yakalama konusundaki yeterliliği nedeniyle seçilmiş ve Destek Vektör Regresyonu (SVR: Support Vector Regression) gibi diğer modellerle karşılaştırılmıştır. Araştırma metan dönüşüm oranı, hidrojen-karbon monoksit oranı ve sentez gazı bileşimi gibi biyogaz reformunun önemli çıktılarını değerlendirmektedir. Modelin etkinliği RMSE, MAE ve MAPE ölçümleri kullanılarak değerlendirilmiştir. Farklı eğitim dönemleri sonrasında, metan dönüşüm oranı için RMSE 0,1905, MAE 0,1311 ve MAPE 0,0036 olarak kaydedilmiştir. Elde edilen sonuçlar, modelin tahmin başarısındaki yüksek doğruluğu ortaya koymaktadır. Bu çalışma, makine öğrenimi tekniklerinin endüstriyel uygulamalarda biyogaz reform süreçlerinin optimize edilmesi ve kontrol edilmesine katkı sağlayabileceğini göstermektedir. CNN-LSTM modelinin özellikle karmaşık biyokimyasal süreçleri yönetmedeki başarısı, derin öğrenme tekniklerinin potansiyelini vurgulamaktadır. Gelecekteki çalışmalar, modelin farklı biyogaz tesislerinde uygulanmasını ve optimizasyon parametrelerinin daha da iyileştirilmesini amaçlayacaktır.

Anahtar Kelimeler: *Biyogaz Reformu, CNN-LSTM, SVR, Sürdürülebilir Enerji*

OPTIMIZATION OF BIOGAS REFORMING PROCESSES USING HYBRID DEEP LEARNING ALGORITHMS: PREDICTION OF OUTPUT PARAMETERS WITH CNN-LSTM MODEL

ABSTRACT

This study examines the application of a hybrid deep learning algorithm, combining Convolutional Neural Networks (CNN) with Long Short-Term Memory (LSTM), for predicting various output parameters in biogas reforming processes. The objective is to develop predictive models that enhance the management of these processes. The CNN-LSTM model was selected for its proficiency in capturing long-term dependencies and complex features in time-series data, and it was benchmarked against other models, including Support Vector Regression (SVR). This research evaluates crucial outputs of biogas reforming, such as the methane conversion rate, the hydrogen-to-carbon monoxide ratio, and the synthesis gas composition. The effectiveness of the CNN-LSTM model was assessed using RMSE, MAE, and MAPE metrics. After different training epochs, the RMSE for CONMET (%) was recorded at 0.1905, MAE at 0.1311, and MAPE at 0.0036, demonstrating the model's high accuracy in prediction. This study marks a significant advancement in incorporating machine learning techniques into optimizing and controlling biogas reforming processes for industrial applications. The success of the CNN-LSTM model, particularly in managing complex biochemical processes, underscores the potential of deep learning techniques. Future efforts will explore the model's application across different biogas plants and aim to refine optimization parameters further.

Keywords: *Biogas Reforming, CNN-LSTM, SVR, Sustainable Energy*

* e-posta¹ : saadinoyucu@adiyaman.edu.tr ORCID ID: <https://orcid.org/0000-0003-3880-3039> (Sorumlu Yazar)

e-posta² : herdem@adiyaman.edu.tr ORCID ID: <https://orcid.org/0000-0003-0079-0041>

1. Giriş

Biyogaz reformu, yenilenebilir enerji üretimi ve organik kalıntıların doğru bir şekilde değerlendirilmesi için tercih edilen bir teknolojidir. Biyogaz, farklı mikroorganizmaların organik maddeyi ayrıştırmak için çeşitli metabolik yolları izlediği, biyolojik aracılı bir sürecin anaerobik sindirimin son ürünüdür. Günümüzde biyogaz sektörü hızla büyümekte ve yeni biyogaz tesislerinin gelişmiş biyoenerji fabrikaları olarak oluşturulmasının temeli oluşturmaktadır. Bu bağlamda biyogaz tesisleri, besin maddelerinin geri dönüşümü, sera gazı emisyonlarının azaltılması ve biyorafineri amaçlı kullanılarak döngüsel ekonomi konseptinin temeli oluşturmaktadır [1].

Biyogaz reformunun temeli olan Anaerobik Bozunma (AD: Anaerobic Decomposition) veya sindirim yüzlerce yıldır bilinmesine ve uygulanmasına rağmen hem teknoloji hem de geliştirilen uygulamalar hala basit teknolojiye dayanmaktadır. Zaman içerisinde süreç büyük ölçüde bir “kara kutu” olarak görülmüştür. Ancak mikrobiyal ekolojideki son gelişmelerle birlikte biyogaz reformu sürecinde büyük gelişmelerden yararlanılarak ve biyoinformatik kullanılarak biyogaz mikrobiyomu deşifre edilmeye başlanmıştır. Güncel birkaç çalışma, metabolik etkileşimlerin birçoğunun açıklığa kavuşturulmasıyla birlikte yeni keşfedilmiş mikropları tanımlamaktadır. Yeni bilgilerin büyük bir hızla kademeli olarak ilerlediği görülmektedir. Bu yeni bilgilerin gelecekte AD sürecini özel ihtiyaçlara göre uyarlanmış daha özel bir şekilde yönlendirmek için kullanılması muhtemeldir.

Biyogaz, esas olarak metan ve karbondioksitten oluşan bir karışımdır. Biyogaz sadece önemli bir elektrik enerjisi kaynağı olarak değil [2], aynı zamanda hidrojen üretimi [3], metanol üretimi [4] ve Fischer Tropsch sentezi [5] gibi geniş bir uygulama yelpazesinde büyük potansiyele sahiptir. Biyogazın çok yönlülüğü, araştırmacıların merakını uyandırmaya ve teşvik etmeye devam etmektedir. Minutillo ve diğerleri [6], biyogaz kullanarak hidrojen, ısı ve elektrik üreten bir polijenerasyon sistemi üzerine çalışmışlardır. Çalışılan sistem [6], oto termal bir biyogaz reaktörü ve bir su gazı kaydırma reaktörünü içermektedir. Sistemin gücü, katı oksit hücreli bir güç ünitesi kullanılarak üretilmektedir. Phan ve diğerleri [3], biyogazın hidrojen değerlendirilmesi programı çerçevesinde çeşitli metan reformu tekniklerinin kapsamlı bir değerlendirmesini yapmışlardır. Bulguları, %30 oranında arka gaz geri dönüşümü ile tri-reform tekniğinin, hidrojen verimi ve enerji verimliliği açısından yaygın olarak kullanılan buharla reform tekniğini aştığını ortaya koymuştur. Chein ve diğerleri [7], biyogazdan elde edilen karbon dioksit ve sentez gazını metanol sentezi için hammaddeler olarak kullanmanın potansiyelini araştırmışlar. Reaktör tasarımının, işletme koşullarının ve yan ürünlerin giderilmesinin metanol üretimi üzerindeki önemli etkisini göstermişlerdir. Sistemik analizler, aşırı ısınma reaksiyon sıcaklıklarını yönetme yeteneği nedeniyle izotermal reaktörün, adyabatik reaktöre göre daha yüksek metanol üretimi sağladığını belirlemiştir. Ayrıca çalışma kapsamında metan ve su eklenerek sentez gazı bileşiminin ayarlanmasının optimal endüstriyel metanol sentezi için etkili olduğu vurgulanmıştır. Marchese ve diğerleri [8], iki farklı yöntem kullanarak, biyogazdan endüstriyel atık karbon dioksiti Fischer-Tropsch sentetik yakıtlarına dönüştürme üzerine odaklanan güçten-sıvıya yollarının iç görülü bir analizini sağlamışlardır. Al-Wahaibi ve diğerleri [9], çeşitli gıda atıklarından biyogaz üretim potansiyeli üzerine bir teknik-ekonomik çalışma yürütmüş, fermantasyon kapasitesini etkili bir şekilde belirlemek için hem kısa (24 saat) hem de uzun (21 gün) test aralıkları kullanmışlardır. Çalışma kapsamında bu zaman dilimleri arasında yüksek bir korelasyon elde edilmiştir. Potansiyel gaz üretimini hızlı bir şekilde değerlendirmek için 24 saatlik testin uygun bir yöntem olduğu önerilmiştir. Polinom modelleri, teorik ve pratik veriler arasında yüksek bir uyum ($R^2 = 0.99$) göstererek, toplam gaz ve metan üretimini yüksek bir doğrulukla tahmin etmiştir. Roy ve diğerleri [10], biyogazı yüksek hidrojen içerikli sentez gazına dönüştürmek için bir buhar-biyogaz reformu sürecini Katı Oksit Yakıt Hücresi (SOFC: Solid Oxide Fuel Cell) ile entegre etmişlerdir. Yenilenebilir metan kaynaklarını kullanarak yerel güç üretimini artırmışlardır. Çalışma kapsamında gerçekleştirilen deneysel çalışmalar ve Aspen Plus benzetimlerini içermekte olup, yüksek sıcaklıklarda (1073 K üzeri) önemli metan dönüşümü ve olumlu karbondioksit dönüşümünün mümkün olduğunu göstermiştir. Reformer sıcaklıkları 948 K ve üzerindeyken sistem enerji verimliliği yaklaşık %40'a ulaşmıştır. Elde edilen sonuçlar, biyogazı

yenilenebilir güç üretimi için etkili bir şekilde kullanma potansiyelini vurgulamaktadır. İşletme sıcaklıklarının ve buhar-karbon oranlarının verimliliği arttırmak için optimize edilmesinin önemini belirtmektedir.

Literatürde belirtildiği gibi biyogaz reformu, metanol üretimi gibi çeşitli endüstriyel uygulamalarda biyogazın kullanılabilmesi için büyük önem taşımaktadır. Biyogazı sentez gazına dönüştürebilecek farklı biyogaz reformu yöntemleri arasında kuru-reform, çift-reform ve tri-reform bulunmaktadır [11]. Biyogaz reformu süreci için kritik girdi parametreleri arasında biyogazın bileşimi, reformer sıcaklığı ve reform ortamı bulunmaktadır. Diğer yandan, biyogazdaki metanın dönüşüm oranı, hidrojen ile karbon monoksit oranı, biyogazdaki metana göre sentez gazındaki hidrojen oranı, sentez gazındaki karbon monoksit ve karbon dioksit oranları ile sentez gazındaki kok yüzdesi biyogaz reformu için önemli çıktı parametreleridir. Makine öğrenimi teknikleri, biyogaz reform sürecindeki çeşitli çıktı parametrelerini tahmin etmek için kullanılabilir. Literatürde, çeşitli yakıt reformu süreçlerinin sonuçlarını tahmin etmek için başarıyla makine öğrenimi teknikleri uygulayan birçok çalışma bulunmaktadır [12–14]. Bu çalışmalar genellikle bir Makine Öğrenimi (ML: Machine Learning) yaklaşımı veya daha karmaşık Yapay Sinir Ağları (ANN: Artificial Neural Networks) kullanmıştır. Bu araştırmada, biyogaz reformunun çeşitli çıktılarını tahmin etmek için birden fazla ML tekniği geliştirilmiştir. Farklı koşullar altında biyogaz hammaddesindeki değişiklikler ve reform ortamı dahil olmak üzere bir biyogaz reformerinin farklı çalışma koşullarında ML tekniklerini uygulamak için kapsamlı bir çerçeve tasarlanmıştır. Bu çalışmada önerilen metodoloji, çeşitli biyogaz reform yöntemlerinin sonuçlarını doğru bir şekilde tahmin etmek için farklı senaryolara kolayca uyum sağlamak üzere geliştirilmiştir.

Bu çalışma, biyogaz reformu süreçlerinde makine öğrenimi tekniklerinin kullanımına odaklanarak literatürdeki boşluğu doldurmaktadır. Literatürde, biyogaz reformu süreçlerinin çıktılarını tahmin etmek için makine öğrenimi tekniklerinin uygulanmasına dair çalışmalar bulunmakla birlikte, mevcut çalışmalar genellikle ANN gibi klasik yaklaşımlar üzerine yoğunlaşmaktadır. Bu çalışmada, daha gelişmiş bir model olan CNN-LSTM kullanılarak biyogaz reformu süreçlerinin çeşitli çıktılarını tahmin etme yeteneği araştırılmıştır. Ayrıca bu çalışmada önerilen metodoloji, farklı biyogaz reformu yöntemleri ve koşulları altında yüksek doğrulukla tahmin yapabilen kapsamlı bir çerçeve sunmaktadır. Bu bağlamda araştırmamız, makine öğrenimi tekniklerinin biyogaz reformu süreçlerinde nasıl daha etkin kullanılabileceğine dair yeni ve özgün bir perspektif sunmaktadır.

Çalışmanın giriş bölümünde, biyogaz reformunun tarihsel ve teknolojik önemi verilmiş, çeşitli kullanım alanları ve mevcut bilimsel ilerlemeler kapsamlı bir şekilde ele alınmıştır. Çalışmanın ilerleyen bölümleri ise şu şekilde düzenlenmiştir: İkinci bölümde, araştırmada kullanılan materyaller ve metotlar detaylı bir şekilde açıklanmıştır. Üçüncü bölümde, biyogaz reformu sürecinin çeşitli çıktı parametrelerini tahmin etmek için kullanılan modellerin geliştirilmesi süreci anlatılmıştır. Dördüncü bölüm, deneysel sonuçların sunulduğu kısımdır; burada elde edilen verilerin analizi, model doğrulaması ve sonuçların değerlendirilmesi gerçekleştirilmiştir. Son bölümde ise elde edilen bulguların tartışılması ve araştırmanın sonuçlarına dair genel bir değerlendirme yapılmıştır.

2. Materyal ve Metot

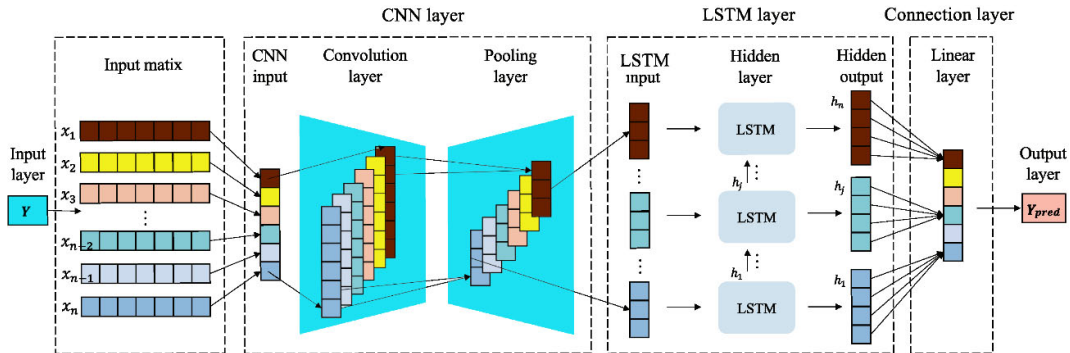
Biyogaz AD ağırlıklı olarak karbondioksit (CO₂), metan (CH₄), su (H₂O) ve oksijen(O₂) içermektedir. Biyogaz yanabilir bir gaz olduğundan ısınma ve ısıtma başta olmak üzere çok amaçlı olarak kullanılabilir. Kullanım alanının geniş olması biyogazdan olabildiğince verimli bir şekilde faydalanmayı gerektirir. Bu nedenle biyogaz işleminde ortaya çıkacak ürünlerin doğru tahmin edilmesi üretim hattında arz ve tüketim hattında kararlılığı doğru yönetmeye yardımcı olacaktır.

Bu çalışmada, karbondioksit/metan (CO₂/CH₄), su/metan (H₂O/CH₄), oksijen/metan (O₂/CH₄) ve reaktör sıcaklığı (RTEMP, °C) değerleri kontrol edilerek biyogaz reformu sürecindeki dönüşüm verimliliği (CONMET %), hidrojen/karbon monoksit oranı (H₂/CO), karbon yüzdesi (C %) ve hidrojen/metan oranı (H₂/CH₄) tahmin edilmiştir. Biyogazın enerji değeri büyük ölçüde içerdiği CH₄

miktarına bağlıdır. Bu nedenle, H₂/CH₄ değerini tahmin etmek önemlidir. Tahmin edilen her bir değer genellikle karmaşık süreçleri daha iyi anlamak ve optimize etmek için kullanılmaktadır. Biyogaz reformu süreçlerini optimize etmek için deterministik modeller, stokastik modeller, makine öğrenmesi ve yapay zekâ yöntemleri kullanılabilir. Deterministik modeller, genellikle denklemler kullanılarak biyogaz üretim süreçlerini modellemeye çalışır. Stokastik modeller, belirsizlik ve rastgelelik faktörlerini dikkate alır. Bu modeller, süreç parametrelerinin belirli bir aralıktaki değerlerine dayalı tahminler yapmaktadır. Ancak son yıllarda, makine öğrenmesi ve yapay zekâ, biyogaz üretim tahminlerinde kullanılan önemli araçlardan biri haline gelmiştir. Özellikle Derin Öğrenme (DL: Deep Learning) modelleri, karmaşık süreçleri modellemek için kullanılmaktadır. Bu model ve algoritmaların temel görevi biyogaz reformu süreçlerinin karmaşıklığını ve belirsizliğini daha iyi anlamak ve yönetmektir. Her modelin veya algoritmanın kendi avantajları ve sınırlamaları vardır ve hangi modelin kullanılacağına karar verirken bu faktörler dikkate alınmalıdır.

Bu araştırmada, biyogaz reformu sürecine ilişkin verilerin tahmin edilmesi amacıyla makine öğrenmesi algoritmalarından Destek Vektör Regresyonu (SVR: Support Vector Regression) kullanılmıştır. SVR, sürekli çıktılar elde edildiği durumlarda, karmaşık ilişkilerin modellenmesi ve tahminlerin yapılması için başvurulan bir yöntemdir. Biyogaz reformu süreci, çeşitli girdi parametreleri (karbondioksit/metan oranı (CO₂/CH₄), su/metan oranı (H₂O/CH₄), oksijen/metan oranı (O₂/CH₄) ve reaktör sıcaklığı (RTEMP, °C) ile çıktılar (dönüşüm verimliliği (CONMET, %), hidrojen/karbon monoksit oranı (H₂/CO), karbon yüzdesi (C%), hidrojen/metan oranı (H₂/CH₄) arasındaki ilişkileri kapsar. Bu karmaşık ilişkiler, SVR gibi makine öğrenmesi teknikleri ile etkin bir şekilde modellenebilir. SVR, aykırı değerlere ve hatalı verilere karşı gösterdiği yüksek dayanıklılık ile bilinir ve yüksek genelleme kapasitesine sahiptir. Ayrıca modelin eğitim verilerine aşırı uymasını (overfitting) engellemeye yönelik bir düzgünleştirme (regularization) parametresi içerir. Bu parametre, modelin yeni verilere olan uyum kabiliyetini artırarak genelleme yeteneğini güçlendirir. Bu özelliklerinden dolayı SVR, bu çalışmada tercih edilen yöntem olmuştur.

Bu araştırmada, biyogaz reformu sürecindeki faktörlerin tahmin edilmesi için yalnızca makine öğrenmesi algoritmalarına değil, aynı zamanda karmaşık ilişkileri daha etkin bir şekilde modelleyebilen LSTM yöntemine de başvurulmuştur. Geleneksel tekrarlayan sinir ağlarındaki uzun süreli bağımlılıkları öğrenmede karşılaştığı güçlükleri aşmak amacıyla geliştirilen LSTM'ler, her bir hücrenin veya nöronun bir "hafıza hücresi" ile donatılmasıyla öne çıkmaktadır [15]. Bu hafıza hücreleri, bilgiyi uzun süreler boyunca koruma ve gerektiğinde yeniden kullanma kapasitesi sağlar. Biyogaz reformu sürecinde LSTM'ler özellikle zaman serisi verilerini modellemek için tercih edilmektedir. Bu modeller, normal operasyonlardan sapmaları tespit etmede de kullanılabilir. Örneğin, biyogaz üretim tesisindeki beklenmedik bir düşüş veya artış durumunda, LSTM modeli bu anomaliyi belirleyerek operatörlere uyarıda bulunabilir. Ayrıca LSTM'lerin başarısı, derin öğrenme modelleri ile birleştirildiğinde daha da artmaktadır [15]. Bu nedenle araştırmada zaman serisi ve sıralı verileri işlemek için kullanılan bir tür derin öğrenme modeli olan CNN ile LSTM yapısı bir arada kullanılmıştır.



Şekil 1. CNN-LSTM mimarisi [16].

CNN-LSTM, genellikle zaman serisi verileri ve sıralı verileri işlemek için kullanılan bir tür derin öğrenme modelidir. CNN-LSTM modeli, hem CNN'nin derin özellikleri öğrenme yeteneğinden hem de LSTM'nin uzun süreli bağımlılıkları modelleme yeteneğinden faydalanmaktadır. Biyogaz reformu sürecinde, CNN-LSTM genellikle zaman serisi verilerini tahmin etmede kullanılmaktadır. CNN yapısı birden çok zaman serisi girişi arasındaki özellikleri öğrenirken, LSTM bu özelliklerin zamana göre değişim hareketlerini öğrenir ve istenilen üretim hattının verilerini tahmin etmek için kullanır. CNN-LSTM yapısının genel yapısı Şekil 1'de verilmiştir.

Bu çalışmada kullanılan CNN-LSTM yapısında, CNN bölümü bir dizi evrişimli ve havuzlama katmanlarından meydana gelmektedir. Bu katmanlar girdi verilerinden özellikleri otomatik olarak tespit etmektedir. Evrişimli katmanlar, giriş verileri üzerinde kayan pencereler kullanarak yerel özellikleri tespit eder. Havuzlama katmanları, özelliklerin boyutlarını küçülterek modelin ölçeklenme ve dönüşüm varyasyonlarına karşı daha dirençli hale gelmesini sağlar. LSTM kısmı ise evrişimli katmanlar tarafından çıkarılan özelliklerin zaman içindeki değişimlerini modellemek amacıyla kullanılır. LSTM hücreleri, bilgiyi uzun süreler boyunca muhafaza eder ve ihtiyaç duyulduğunda bu bilgiyi geri çağırabilir. Bu özellik modelin uzun vadeli bağımlılıkları öğrenmesini ve zaman serisi veriler üzerinde tahminlerde bulunmasını mümkün kılmaktadır.

3. Model Geliştirme

Bu araştırmada üç farklı modelin geliştirilmesine odaklanılmıştır. İlk olarak, makine öğrenmesi temelli bir SVR modeli ele alınmıştır. İkinci ve üçüncü modeller ise sırasıyla LSTM ve CNN-LSTM birimlerinin entegrasyonundan oluşan CNN-LSTM modelleridir. Bu modellerin geliştirilmesi belirlenen bir düzen dahilinde yürütülmüştür. Model geliştirme sürecinde, alt başlıklar altında detaylı bir şekilde açıklanan işlem adımları takip edilmiştir. Bu adımlar, modelin yapısının kurgulanmasından başlayarak, performansının değerlendirilmesine kadar olan süreçleri kapsamaktadır.

Model geliştirme sürecinin ilk aşaması olarak veri toplama ve ön işleme gerçekleştirilmiştir. İlgili modelleme problemimiz (biyogaz reformu) ile alakalı tarihsel veriler toplanmış ve bu veriler, SVR, CNN veya CNN-LSTM yapısına uygun biçimde ön işlemeye tabi tutulmuştur. Sürecin ikinci aşamasında, toplanan veriler üzerinden modelin tahmin kapasitesini artıracak önemli özellikler seçilmiş ve analiz edilmiştir. Bu özellikler regresyon problemlerinde hedef değişkenin değerini optimum düzeyde belirlemeye yardımcı olmaktadır. Üçüncü aşamada veri seti eğitim ve test veri kümelerine ayrılmıştır. Burada eğitim kümesi modelin eğitilmesi, test kümesi ise modelin performansının değerlendirilmesi amacıyla kullanılmıştır. Modelin geliştirilmesi ve eğitimi, kullanılan makine öğrenmesi veya yapay zekâ algoritmalarının özelliklerine bağlı olarak farklılık göstermektedir ve bu nedenle farklı başlıklar altında incelenmiştir. Geliştirilen modelin performansı, test veri kümesi üzerinden değerlendirilmekte olup performans değerlendirmesi esas olarak modelin hedef değişkeni ne kadar doğru tahmin ettiğini ölçmektedir. Regresyon problemleri için sık kullanılan performans ölçütlerinden biri Kök Ortalama Kare Hata (RMSE: Root Mean Squared Error)'dir [17]. Son aşamada model gerçek dünya uygulamalarına entegre edilmelidir. Eğitim ve doğrulama işlemlerinden sonra model, yeni verilere dayalı olarak hedef değişkenin değerini tahmin etmek üzere kullanılabilir. Bu, modelin gerçek dünya verileri üzerindeki tahmin çalışmalarını mümkün kılmaktadır.

3.1. Veri Toplama ve Ön İşlem

Bu çalışma için veri üretimi, farklı girdi koşulları altında biyogaz reformu süreçlerinin çeşitli sonuçlarını elde etmek amacıyla RGibbs reaktör modelini kullanan Aspen Plus benzetim yazılımı kullanıldı. Bu analizde, biyogazın sadece CH₄ ve CO₂ içerdiği varsayıldı ve CO₂ ile CH₄ oranı 0.3 ile 3 arasında değiştiği kabul edildi. Çalışma ayrıca birkaç başka değişkeni de göz önünde bulundurdu. H₂O ile metan oranı 0 ile 9 arasında değişti, O₂ ile metan oranı 0 ile 0,3 arasında değişti ve reformer sıcaklığı 200 ile 1000°C arasında olacak şekilde ayarlandı.


Benzetimlerden elde edilen çıktı parametreleri arasında, biyogazdaki metanın mol başına hesaplanan metan dönüşüm oranı, H₂/CO oranı, kok oluşum oranı ve sentez gazındaki CO, CO₂ ve H₂ oranları bulunmaktadır. Bu veri seti, farklı reform senaryolarının verimliliğini ve uygulanabilirliğini analiz etmek için kapsamlı bir temel sağlamaktadır. Gelecekteki çalışmalarda özel araştırma ihtiyaçlarına uygun olarak daha da geliştirilebilir veya ek parametreleri incelemek için genişletilebilir bir yapıda ele alınmıştır.

Elde edilen veriler üzerinde ön işlem uygulanmış ve eksik değerler kontrol edilmiştir. Ek olarak aykırı değerler uzman değerlendirmesinin ardından veri kümesinden çıkarılmıştır. Veriler hazırlandıktan sonra SVR modeli için 'numpy' dizileri kullanılmıştır. Yapay zekâ algoritmaları için verilere 'scaler' dönüşüm uygulanmıştır. Ayrıca derin öğrenme modellerinde, özelliklerin normalleştirilmesi genellikle modelin daha hızlı ve daha etkin bir şekilde eğitilmesine yardımcı olmaktadır. Normalleştirme, gradyan iniş gibi optimizasyon algoritmalarının daha hızlı ve daha etkin bir şekilde yakınsamasını sağlamaktadır.

CNN yapısı, genellikle görüntü işleme gibi alanlarda kullanılır ve bu tür uygulamalar tipik olarak üç boyutlu veri gerektirir. Örneğin bir renkli görüntü genellikle yükseklik, genişlik ve renk kanallarından oluşan üç boyuta sahiptir. Bu bağlamda model eğitimi için verilerin üç boyutlu olarak hazırlanması önem taşır. CNN girişinde kullanılan üç boyutlu veriler, CNN'nin birden fazla boyutta yerel özellikleri eş zamanlı olarak yakalamasına olanak tanır ve bu da verinin daha kapsamlı bir temsilini sağlar. Çalışma kapsamında, verileri üç boyutlu formatlara dönüştürmek için Python'un 'numpy' kütüphanesine ait 'reshape' fonksiyonundan yararlanılmıştır. 'Reshape' fonksiyonu, verileri belirlenen boyutlara uygun şekle getirmek için kullanılmaktadır. Derin öğrenme modellerimiz için veriler örnek sayısı, zaman adımı sayısı ve özellik sayısı olmak üzere üç boyutta yapılandırılmıştır. Böylece veri ön işleme süreci bu üç boyuta göre optimize edilmiştir.

3.2. Veri Bölme

Biyogaz reformu aşamasında elde edilen verileri bölme işlemi, sınıflandırma tür verilerle ilgili farklı olmalıdır. Biyogaz reformu zamana bağlı veriler sıralı bir yapıya sahiptir ve bu yapı, modelin eğitim ve test sürecinde korunmalıdır. Çalışma kapsamında ele alınan problem geçmiş verilere dayanarak gelecek verileri tahmin edebilmektir. Bu nedenle veri bölme işlemine dikkat edilmez ise gelecekteki bilgilere dayalı olarak geçmişi tahmin etmeye çalışan bir model oluşturabilir. Bu durum gerçek problemlerde istenmeyen bir hatayı ortaya çıkaracaktır. Çalışma kapsamında elde edilen veriler zaman tabanlı olarak bölümlenmiştir. Bu bölümlenme işlemi ile veri setinin bir bölümü (70% - 90.321 adet) (genellikle eski veriler) modelin eğitilmesi için ve kalan bölümü (yeni veriler - 38.709 adet) modelin test edilmesi için ayrılmıştır. Şekil 2'de veri bölme işlemi gösterilmiştir.



Şekil 2. Veri bölme işlemi.

Şekil 2’de veri setinin eğitim ve test verilerinin dağılımı verilmiştir. Mavi alan, eğitim verilerini temsil ederken, turuncu alan test verilerini göstermektedir. X eksen, veri setindeki veri noktalarının sayısını gösterirken, y eksen ise bu veri noktalarının sıklığını temsil etmektedir. Şekil 2, veri setinin bölünmesi ve kullanımının görsel bir özetini sağlayarak, eğitim ve test verilerinin veri seti üzerindeki kapsamını ve dağılımını sunmaktadır.

3.3. Model Parametreleri ve Eğitim

Model geliştirme sürecinde, SVR, CNN ve CNN-LSTM yapısı olmak üzere farklı yapılar için çeşitli modelleme parametreleri kullanılmıştır. SVR, Destek Vektör Makinelerinin (SVM: Support Vector Machines) sınıflandırma yeteneği, sürekli hedef değişkenleri tahmin etmek üzere uyarlanmış bir versiyonudur. SVM, genellikle iki sınıf arasındaki farkı en üst düzeye çıkarmaya çalışırken, SVR modeli belirlenen bir hata farkı içinde kalan tahminlerin sayısını en üst düzeye çıkarma amacına yönelik çalışmaktadır. Python programlama dilinde SVR modellerini eğitmek ve tahminlerde bulunmak için sıklıkla kullanılan ‘Scikit-learn’ kütüphanesi bu süreçte tercih edilmiştir [18]. SVR algoritmalarının en önemli özelliklerinden biri çekirdek (kernel) fonksiyonlarıdır. Bu algoritmalarda kullanılan çekirdek fonksiyonu, özelliklerin daha yüksek boyutlu bir uzaya dönüştürülmesini sağlamaktadır. Doğrusal olarak ayrılabilen verilerin ayrılabilir hale gelmesine olanak tanır. Bu çalışmada, çekirdek fonksiyonu olarak Radyal Taban Fonksiyonu (RBF: Radial Basis Function) kullanılmıştır. RBF çekirdeği, veri noktaları arasındaki mesafeyi hesaplar ve bu mesafeyi Gaussian (Normal) dağılım fonksiyonuna tabi tutarak verinin daha yüksek boyutlu bir uzaya dönüştürülmesini sağlar. RBF çekirdeğinin bir diğer önemli parametresi olan ‘gamma’, çekirdek fonksiyonunun şeklini etkileyerek modelin performansını doğrudan etkiler.

Klasik makine öğrenmesi algoritmalarından biri olan SVR üzerine model geliştirme çalışmaları tamamlandıktan sonra, LSTM ve CNN ile bütünleşmiş LSTM modelleri üzerindeki çalışmalara geçilmiştir. LSTM modeli için kullanılan parametreler, Çizelge 1’de detaylandırılmıştır. Bu geçiş farklı modelleme tekniklerinin karşılaştırmalı analizini ve her birinin veri seti üzerindeki performansını değerlendirmeyi amaçlamaktadır.

Çizelge 1. LSTM Model Parametreleri.

Parametreler	Değerler
Gizli Durum Boyutu (Hidden State Size)	8
Katman Sayısı (Number of Layers)	3
Aktivasyon Fonksiyonu (Activation Function)	tanh
Bırakma Oranı (Dropout Rate)	0.2
Optimizasyon Algoritması	Adam optimization
Öğrenme Oranı (Learning Rate)	0.001
Toplu Boyut (Batch Size)	64
Eğitim Dönemi (Number of Epochs)	250, 500, 750

LSTM modeli için kullanılan parametreler, Çizelge 1’de verilmiştir. Bu parametrelerden Gizli Durum Boyutu (Hidden State Size), modelin öğrenebileceği bilgi miktarını etkileyen önemli bir faktördür. Genellikle daha büyük bir gizli durum boyutu, modelin daha karmaşık özellikler öğrenmesine imkân tanırken, aşırı uyum riskini de artırabilir. Bu nedenle veri miktarına uygun bir boyut belirlenmiştir. Çalışmada bu değer 8 olarak ayarlanmıştır. Katman Sayısı (Number of Layers) ise, modelin daha detaylı özellikleri öğrenmesine yardımcı olur ancak hesaplama maliyetini ve aşırı uyum riskini yükseltir. Bu nedenle 3 olarak belirlenmiştir. Aşırı öğrenmeyi önlemek için Bırakma Oranı

(Dropout Rate), eğitim sırasında rastgele seçilen nöronların devre dışı bırakılmasını sağlamak amacıyla kullanılmıştır. Toplu İş Boyutu (Batch Size), hesaplama verimliliği ve modelin genelleme yeteneğini artırmak için 64 olarak ayarlanmıştır. Modelde aktivasyon fonksiyonu olarak ise genellikle -1 ile 1 arasındaki çıktı gerektiren durumlar için tercih edilen ‘tanh’ fonksiyonu kullanılmıştır. Bu fonksiyon, zaman serisi verilerinin bu aralıkta başarıyla normalleştirilmesi durumunda idealdir. Modelin aşırı öğrenme durumunu izlemek ve model başarısını dönemsel olarak değerlendirebilmek amacıyla 250, 500 ve 750 eğitim dönemi değerlerinde eğitimler gerçekleştirilmiştir.

Çalışma kapsamında geliştirilen bir diğer model yapısı ise CNN ve LSTM bileşenlerini birleştiren CNN-LSTM mimarisidir. Bu yapı hem uzamsal hem de zamansal özelliklerin öğrenilmesine olanak tanır ve bu avantajı sayesinde, video analizi veya çok boyutlu zaman serisi veriler gibi karmaşık problemlerin çözümünde son derece etkilidir. Ancak CNN ve LSTM bileşenlerinin çok sayıda parametresi bulunmaktadır ve bu parametrelerin ayarlanması zaman alıcı ve karmaşık bir süreç gerektirebilir. CNN-LSTM yapısında kullanılan parametreler, Çizelge 2’de ayrıntılı olarak sunulmuştur.

Çizelge 2. CNN-LSTM Model Parametreleri.

Parametreler	Değerler
Evrişim katmanı filtreleri	32
Evrişim katmanı çekirdek boyutu	1
Evrişim katmanının aktivasyon fonksiyonu	tanh
Havuzlama katmanı havuz boyutu	1
Havuzlama katmanının aktivasyon fonksiyonu	ReLU
Zaman adımı, yerleştirme boyutu	12
Parti boyutu	32
Öğrenme oranı	0.0001
Optimizasyon	Adam
Kayıp fonksiyonu	Mean absolute error
Dönem Sayısı	250, 500, 750
LSTM katmanındaki gizli birimlerin sayısı	64
LSTM katmanının aktivasyon fonksiyonu	tanh

Çizelge 2’de verilen parametreler CNN-LSTM modelinin performansını ve eğitim süresini önemli ölçüde etkilemektedir. Parametre ayarlanması genellikle deneme yanılma süreci ile gerçekleştirilmektedir. Bu nedenle ilk denemelerde LSTM yapısında gizli katman sayısı 48 olarak belirlenmiştir. Elde edilen ilk sonuçlar yeterli başarı göstermediğinden ikinci bir katman daha eklenerek 16 gizli katman sayısı belirlenmiştir. İlk sonuçlar iyileştirme göstermiştir. Ancak kabul edilebilir seviyede değildir. Bu nedenle model yapısı değiştirilmiş ve ilk LSTM katman sayısı 64, ikincisi ise 48 olarak ayarlanmıştır.

Hazırlanan modeli geliştirmek için her türden derin öğrenme modelini tanımlamak ve eğitmek için uygun koşulları sağlayan Python programlama dilinde oluşturulmuş bir derin öğrenme kütüphanesi olan TensorFlow Keras kullanılmıştır. Model yapısında aktivasyon fonksiyonu olarak ReLU kullanılmıştır. ReLU, diğer aktivasyon fonksiyonlarına göre (sigmoid veya tanh gibi) daha az hesaplama maliyetine sahiptir. Bu durum zaman serisi verilerinde daha az işlem gerektirmektedir. Ayrıca ReLU, çıktıları sifıra eşitleme yeteneği sayesinde, nöronların aktif hale gelmesi için bir tür seçim mekanizması sağlamaktadır. Bu yeteneği sinir ağının genel olarak daha etkili ve verimli olmasına yardımcı olmaktadır. Model eğitimi LSTM yapısında da olduğu gibi kademeli olarak gerçekleştirilmiştir. Böylelikle modelin aşırı öğrenmesi üzerine bilgi edinilmiştir.

4. Deneysel Sonuçlar

4.1. Değerlendirme Metrikleri

Çalışma kapsamında hazırlanan modelleri test edebilmek için birden fazla yöntem kullanılmıştır. İlk test işlemlerinde istatistiksel tahminlerin doğruluğunu değerlendirmekte kullanılan bir metrik olan RMSE kullanılmıştır [17,18]. RMSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasının karekökü olarak hesaplanmaktadır (Denklem 1).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{a}_i - a_i)^2}{n}} \quad (1)$$

Deneysel çalışmalarda model testi için kullanılan diğer bir yaklaşımda Ortalama Mutlak Sapma Hatası (MADE: Mean Absolute Deviation Error)'dir [19]. Genellikle regresyon modellerinin performansını ölçmek için kullanılan MADE, tahmin edilen değerler ile gerçek değerler arasındaki ortalama mutlak farkı temsil etmektedir. Diğer bir deyişle her bir tahminin ne kadar "yanıldığını" belirlemeye çalışır. MADE hem pozitif hem de negatif hataların büyüklüğünü dikkate almaktadır. Ancak hata yönünü (yani tahminin gerçek değerden çok mu yüksek yoksa çok mu düşük olduğunu) dikkate almaz. Bu nedenle RMSE ve Ortalama Mutlak Yüzde Hatası (MAPE: Mean Absolute Percentage Error) gibi diğer hata metrikleriyle birlikte kullanılır [20].

MAPE, tahmin edilen değerler ile gerçek değerler arasındaki mutlak yüzde farkın ortalamasını hesaplar. Tahminlerin gerçek değerlere göre ne kadar yüzdesel olarak sapma gösterdiğini belirler. MAPE Denklem 2'de verildiği gibi hesaplanmaktadır.

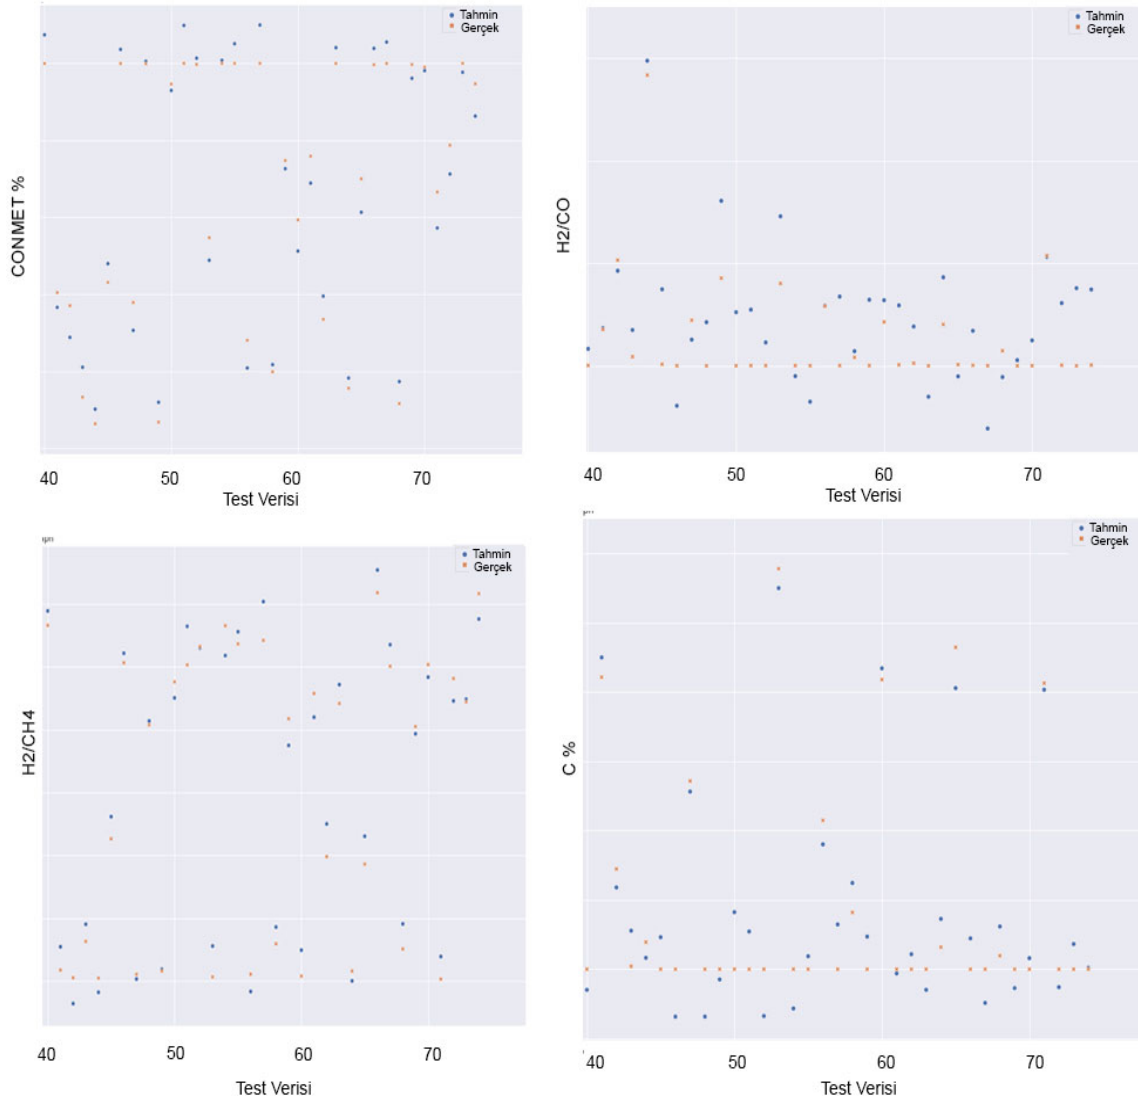
$$MAPE = (1/n) * \sum \left(\frac{|actual - forecast|}{|actual|} \right) * 100 \quad (2)$$

Denklem 2'de gösterildiği gibi her bir tahmin için, tahmin edilen değer ile gerçek değer arasındaki farkı hesaplanır. Ardından bu farkın mutlak değerini alınır. Bu mutlak fark, gerçek değere bölünerek yüzdesel hata değerini elde edilir. MAPE, hataları orijinal ölçekte değil de yüzdesel olarak değerlendirmenin daha anlamlı olduğu durumlar için yararlıdır.

4.2. SVR Modeli ile CONMET (%), H2/CO, C(%), H2/CH4 Verilerinin Tahmini

Bu çalışmada geliştirilen SVR modeli, belirli parametreler üzerinden CONMET (%), H2/CO, C (%), H2/CH4 verilerinin tahmini amacıyla kullanılmıştır. Model doğrulama sürecinde, test işlemleri için seçilen veriler, modelin eğitim aşamasında kullanılmamıştır. Modelin görmediği veriler üzerindeki performansının değerlendirilmesi açısından önemlidir. Şekil 3, tahmin edilen değerlerin gerçek verilere göre konumlarını görsel olarak sunmakta ve böylece modelin tahmin doğruluğu hakkında bilgi vermektedir.

Şekil 3'te SVR modeli ile tahmin edilen CONMET (%), H2/CO, C (%), ve H2/CH4 değerleri ile bu parametrelerin gerçek değerleri arasındaki ilişki gösterilmektedir. Her bir grafik, x ekseninde test verisi indekslerini ve y ekseninde ilgili parametre değerlerini temsil etmektedir. Mavi noktalar gerçek değerleri, kırmızı noktalar ise SVR modeli tarafından tahmin edilen değerleri göstermektedir. CONMET(%) grafiğinde, tahmin edilen değerlerin gerçek değerlere göre oldukça dağılmış olduğu görülmekte, bu da modelin bu parametre için daha yüksek bir hata oranına sahip olabileceğine işaret etmektedir. H2/CO ve C (%) grafiklerinde, tahminlerin genel olarak gerçek değerlere daha yakın olduğu, ancak yine de belirli noktalarda önemli sapmaların mevcut olduğu gözlemlenmektedir. H2/CH4 grafiğinde ise, modelin tahminleri gerçek değerlere nispeten daha düşük bir doğrulukla uyum sağlamış görünmektedir.




Şekil 3. SVR modeli ile tahmin edilen ve gerçek değerlerinin karşılaştırmalı analizi.

4.3. LSTM Modeli ile CONMET (%), H2/CO, C(%), H2/CH4 Verilerinin Tahmini

Bu çalışmada geliştirilen LSTM modeli, belirli bir veri seti üzerinden CONMET (%), H2/CO, C (%), ve H2/CH4 verilerinin tahmin edilmesi amacıyla kullanılmıştır. Model 250, 500 ve 750 eğitim dönemi olmak üzere üç farklı iterasyon sayısında eğitilmiştir. Elde edilen sonuçlar incelendiğinde 250 ile 500 eğitim dönemi arasında iyileşmenin fazla olduğu, 500-750 eğitim dönemi arasında model başarısının çok değişmediği gözlemlenmiştir. 750 eğitim dönemi sonucunda elde edilen LSTM sonuçları Şekil 4’te verilmiştir.

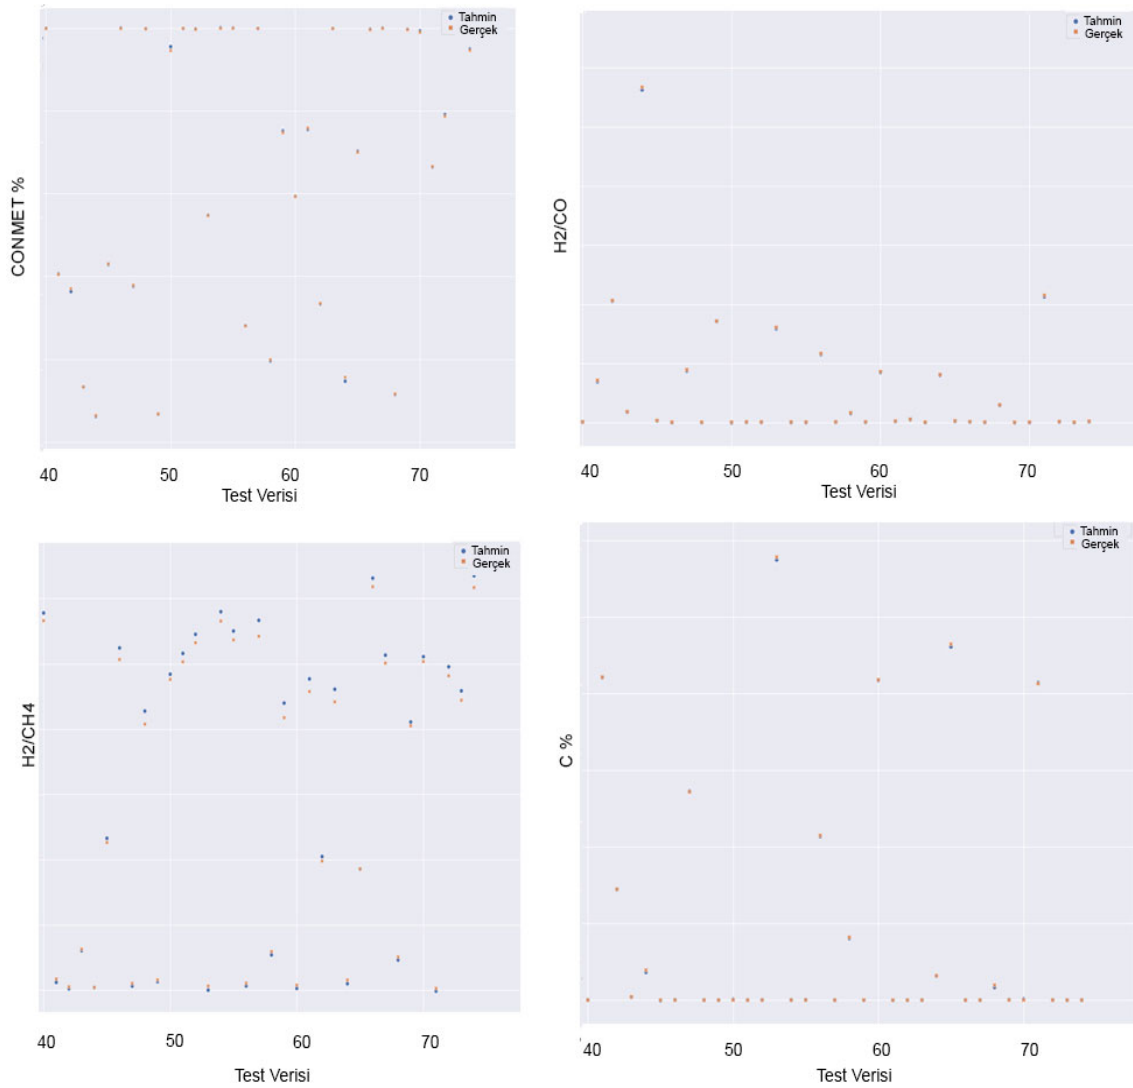
Şekil 4’te sunulan dört farklı grafik, LSTM modeli kullanılarak elde edilen tahmin sonuçlarının gerçek değerlerle karşılaştırılmasını göstermektedir. CONMET (%) için tahminlerin gerçek değerlerden önemli ölçüde sapmalar gösterdiği gözlemlenmektedir. H2/CO parametresi için de benzer bir durum söz konusudur. C (%) parametresinde ise tahminlerin genel olarak gerçek değerler ile örtüştüğü, daha düşük bir sapma ile yer aldığı görülmektedir. H2/CH4 grafiğinde, tahminlerin gerçek değerlere göre daha homojen bir dağılım gösterdiği ancak az miktarda da olsa sapmalar içerdiği belirlenmiştir.



Şekil 4. LSTM modeli ile tahmin edilen ve gerçek değerlerinin karşılaştırmalı analizi.

4.4. CNN-LSTM Modeli ile CONMET (%), H2/CO, C(%), H2/CH4 Verilerinin Tahmini

Bu çalışmada geliştirilen CNN-LSTM modeli, belirli bir veri seti üzerinden CONMET (%), H2/CO, C (%), ve H2/CH4 değerlerinin tahmini için kullanılmıştır. Modelin test sürecinde, model eğitimi sırasında kullanılmamış olan veriler kullanılarak modelin genelleme kabiliyeti değerlendirilmiştir. Model 250, 500 ve 750 eğitim dönemi süresince eğitilmiş olup, kayıp (loss) değerleri bu eğitim dönemleri boyunca incelenmiştir. Analiz sonuçlarına göre model 250 eğitim döneminden sonrasında kayıp değerlerinde belirgin bir iyileşme göstermiş, bu da modelin bu noktadan itibaren daha iyi sonuçlar vermeye başladığını göstermektedir. Bu bulgular CNN-LSTM modelinin belirlenen parametreler altında nasıl performans gösterdiğine dair önemli bilgiler sunmakta ve modelin daha ileri düzeyde optimizasyonu için yol gösterici olmuştur. Şekil 5'te CNN-LSTM modelinin gerçek değerler ve tahmin edilen değerler arasındaki ilişkiyi gösteren grafik verilmiştir.



Şekil 5. CNN-LSTM modeli ile tahmin edilen ve gerçek değerlerinin karşılaştırmalı analizi.

Şekil 5'te CNN-LSTM modeli kullanılarak elde edilen tahmin sonuçlarının gerçek değerlerle karşılaştırılması gösterilmektedir. CONMET (%) grafiğinde, tahminlerin genel olarak gerçek değerlerden düşük olduğu ve özellikle daha yüksek değerlerde tahminlerin gerçek değerlerden uzaklaştığı görülmektedir. H2/CO parametresi için tahminler, gerçek değerlere nispeten daha düzgün bir dağılım sergilese de bazı noktalarda önemli sapmalar mevcuttur. C (%) için tahminlerin gerçek değerlere oldukça yakın olduğu gözlemlenmektedir, bu da modelin bu parametre üzerinde daha iyi performans gösterdiğini işaret etmektedir. H2/CH4 grafiğinde, tahminlerin genel olarak düşük olduğu ve gerçek değerlerin üzerine çıkmadığı görülmektedir.

Geliştirilen CNN-LSTM modelinin tahmin yeteneğinin hem klasik SVR modeline hem de tek başına LSTM modeline kıyasla daha üstün olduğu gözlemlenmiştir. Modelin kayıp (loss) değerleri üzerinde yapılan inceleme, 500 eğitim dönemine ulaştığında kayıpların önemli ölçüde azaldığını ortaya koymuştur. Bu azalma tahminlerin doğruluğunu artırmıştır. CNN'in karmaşık yapıları öğrenme yeteneği, LSTM'in zaman serisi verileri üzerindeki başarısı ile entegre edilerek güçlendirilmiştir. Katman sayısındaki optimizasyon çalışmalarının, modelin performansını önemli ölçüde artırdığını göstermiştir. 48 katmanlı LSTM yapısına kıyasla 64 katmanlı modeller daha iyi sonuçlar elde etmiştir.

Katman sayısındaki bu artış, modelin karmaşık ilişkileri ezberlemesine olanak tanımaktadır. Ancak bu durumun olumsuz etkilerinden kaçınmak için büyük veri setleri ile çalışmak gereklidir. Yapılan çalışmalarda 500 ve sonrasındaki eğitim döneminden sonra modelin performansının stabil bir duruma geldiği belirlenmiştir.

4.5. RMSE, MADE ve MAPE Sonuçları

Gerçekleştirilen tahminlerin doğruluğunu ölçmek için RMSE, MADE ve MAPE gibi istatistiksel hata metrikleri kullanılmıştır. Bu metrikler, modelin tahmin edilen değerlerinin gerçek değerlerden ne kadar sapma gösterdiğini niceliksel olarak ifade etmektedir. Elde edilen sonuçlar Çizelge 3'te sunulmuştur.

Çizelge 3. CONMET (%), H2/CO, C (%) ve H2/CH4 Verilerindeki Hata Değerlerinin Karşılaştırılması.

Veriler	Metrikler	Regresyon Modelleri									
		SVR	LSTM			CNN-LSTM					
			250 Eğitim Dönemi		500 Eğitim Dönemi		750 Eğitim Dönemi				
			1.Model	2.Model	1.Model	2.Model	1.Model	2.Model			
Conmet(%)	RMSE	2,1683	1,1371	0,8461	1,2299	0,8467	0,1905	2,0022	0,1905	0,3581	0,2389
	MADE	1,8609	0,7834	0,5749	1,0994	0,6906	0,1311	1,4904	0,1312	0,2384	0,1754
	MAPE	5,4385	0,0341	0,0281	0,0426	0,0208	0,0036	0,0523	0,0036	0,0091	0,0048
H2/CO	RMSE	83,7562	12,3617	8,1898	9,3711	23,2664	3,4602	21,5748	3,0421	33,7274	4,6341
	MADE	32,0024	5,20623	3,7232	5,8658	19,8081	2,0192	9,8081	1,3465	11,6791	2,3651
	MAPE	444,5652	0,6861	0,4875	1,2395	5,4562	0,3479	1,9628	0,0914	2,2284	0,1515
C (%)	RMSE	0,8045	0,2418	0,3245	0,3319	0,7631	0,1282	0,1619	0,0866	0,3672	0,0747
	MADE	0,5811	0,1573	0,2098	0,2526	0,5632	0,0645	0,0831	0,0481	0,2011	0,0391
	MAPE	0*	0*	0*	0*	0*	0*	0*	0*	0*	0*
H2/CH4	RMSE	0,0697	0,0174	0,0261	0,0448	0,0093	0,0083	0,0063	0,0132	0,0071	0,0054
	MADE	0,0613	0,0136	0,0227	0,0406	0,0062	0,0061	0,0045	0,0111	0,0053	0,0041
	MAPE	8,5456	0,0618	0,1823	0,2653	0,0172	0,0151	0,0123	0,0326	0,0132	0,0094

Çizelge 3, farklı modeller (SVR, LSTM, CNN-LSTM) için çeşitli eğitim dönemlerinde (250, 500, 750) ve farklı modeller (Model 1, Model 2) kullanılarak elde edilen tahmin sonuçlarını değerlendirmekte olan istatistiksel hata metrikleri (RMSE, MAE, MAPE) ile sunulmuştur. Değerlendirme, dört farklı veri türü (CONMET (%), H2/CO, C (%), H2/CH4) üzerinde yapılmıştır. CONMET (%) verileri için CNN-LSTM modelinin farklı eğitim dönemleri sonrasında elde edilen RMSE, MADE ve MAPE değerleri sırasıyla 0,1905, 0,1311 ve 0,0036 olarak kaydedilmiştir. Bu değerler, modelin veri seti üzerinde oldukça düşük hata oranları ile yüksek doğrulukta tahminler yapabildiğini göstermektedir. Benzer şekilde, veri setinde yer alan diğer özellikler ve modeller için de performans değerlendirilmiş ve genel olarak eğitim dönemi sayısı arttıkça modelin performansının iyileştiği gözlemlenmiştir. Ancak 500 eğitim döneminden sonra modelin başarısında negatif yönde bir etkinin olduğu gözlemlenmiştir. H2/CO verileri için ise LSTM ve CNN-LSTM modellerinin özellikle yüksek eğitim dönemi değerlerinde oldukça düşük RMSE, MAE ve MAPE değerleri elde ettiği

görülmektedir. Bu da zamanla modelin bu veri türünü daha iyi tahmin edebildiğini göstermektedir. C (%) ve H₂/CH₄ veri setlerinde de benzer iyileşmeler ve düşük hata oranları dikkat çekmektedir.

5. Tartışma ve Sonuç

Bu çalışmada, farklı regresyon modellerinin (SVR, LSTM, CNN-LSTM) performansları, CONMET (%), H₂/CO, C (%), ve H₂/CH₄ gibi zaman serisi veriler üzerinde değerlendirilmiştir. Model performanslarını değerlendirmek için kullanılan RMSE, MADE ve MAPE metrikleriyle, CNN-LSTM modelinin özellikle 500 eğitim dönemi sonunda diğer modellere göre üstün performans sergilediği belirlenmiştir. Diğer modellere göre daha düşük performans gösteren SVR modelinin, özellikle karmaşık zaman serisi verileri gibi yüksek boyutlu ve karmaşık yapıya sahip veri setlerinde daha düşük performans gösterdiği bilinmektedir. Bu durumun çalışmada kullandığımız veri seti üzerinde düşük performans göstermesinin temel nedenleri arasında modelin doğrusal ve doğrusal olmayan ilişkileri modelleme kapasitesinin sınırlı olması yer almaktadır. SVR, veriler arasındaki ilişkileri yalnızca belirli bir çekirdek fonksiyonu aracılığıyla yakalamakta ve bu da modelin karmaşık ilişkileri öğrenme yeteneğini sınırlamaktadır.

CNN-LSTM modeli, CNN'in karmaşık özellikleri algılama yeteneği ve LSTM'in zaman serisi verilerdeki uzun süreli bağımlılıkları öğrenme kabiliyeti ile güçlendirilmiştir. CNN katmanları, verilerden çok düzeyli özellikler çıkarabilir ve bu özellikler LSTM katmanlarına beslenir. LSTM, bu özelliklerin zaman içinde nasıl değiştiğini anlamak için hafıza mekanizmasını kullanır. Böylece uzun vadeli bağımlılıklar ve ilişkiler model içinde korunur ve tahmin edilir. Bu bütünleşmiş yaklaşım, CNN-LSTM modelinin zaman serisi veriler üzerinde özellikle etkili olmasını sağlar ve SVR modeline göre daha dinamik ve karmaşık veri yapılarını daha başarılı bir şekilde modelleyebilmesine olanak tanır. CNN-LSTM modeli için 750 eğitim dönemi sonunda elde edilen RMSE, MADE ve MAPE değerleri eğitim dönemi süresinde farklılıklar göstermektedir. RMSE, MADE ve MAPE değerleri sırasıyla 0.1905, 0.1311 ve 0.0036 olarak ölçülmüştür. Bu değerler modelin farklı eğitim dönemlerinde modellerin tahmin doğruluğu hakkında bilgi vermektedir. Elde edilen sonuçlar incelendiğinde, eğitim dönemlerinin artırılmasının model başarısı üzerinde her zaman pozitif etki yapmadığı görülmüştür.

Birçok çalışmada göz ardı edilen modelin hesaplama sürecine dair detaylar, bir makine öğrenmesi projesinin uygulanabilirliği ve sürdürülebilirliği açısından önem taşır. Bu bilgiler, modelin gerçek dünya koşullarında ne kadar etkin ve verimli çalışabileceğini gösterir. Özellikle, modelin eğitim ve test süreleri, kullanılan donanımın kapasitesi ve maliyeti, modelin farklı donanımlarda nasıl performans gösterdiği gibi faktörler, modelin son kullanıcılar tarafından kabul edilebilirliğini doğrudan etkiler. Bu nedenle modelin hesaplama sürecinin detayları, akademik araştırmaların yanı sıra endüstriyel uygulamalar için de büyük önem taşır. Çalışma kapsamında geliştirilen CNN-LSTM modeli, 750 eğitim dönemi sonucunda test kümesindeki verileri 83 saniyede tahmin edebilmiştir. Her bir veri noktasının işleme süresi ise yaklaşık 0,05 saniye olmuştur. İlgili modelin eğitim süreci NVIDIA Geforce RTX 3060 Ti ekran kartı kullanılarak gerçekleştirilmiş ve bu süreç yaklaşık 2 saat 75 dakika sürmüştür. Modelin test işlemleri ise ekran kartı kullanılmadan, Intel i7 işlemci ve 16 GB RAM kapasitesine sahip bir bilgisayar ile yapılmıştır. Bu bilgiler, modelin gerçek dünya uygulamalarında kullanımının maliyet ve zaman açısından değerlendirilmesine olanak tanımaktadır.

Gelecek çalışmalarda, modelin başarısını artırmak için farklı endüstrilerden ve farklı türde veri kümelerinden veriler kullanılabilir. Ayrıca modelin hesaplama verimliliğini artırmak için donanım optimizasyonları, paralel işleme teknikleri ve daha gelişmiş parametre ayarlama yöntemleri entegre edilebilir. Bu yaklaşım modelin daha geniş uygulama alanlarında etkin bir şekilde kullanılmasını sağlayarak, endüstriyel uygulamalar ve bilimsel araştırmalar için yenilikçi çözümler sunabilir. Modelin eğitim ve test süreçlerinde kullanılan donanımın detaylarını dikkate almak, modelin uygulama maliyetini ve erişilebilirliğini optimize edecektir. Bu çalışmanın sonuçları, karmaşık zaman serisi verilerinin modelleme ve tahmin yeteneklerini geliştirme potansiyeli taşıdığından, gelecekteki teknolojik ve bilimsel ilerlemeler için bir zemin hazırlamıştır.

Kaynaklar

- [1] Kougias PG, Angelidaki I. Biogas and its opportunities - A review Keywords. *Front. Environ. Sci.* 2018; 12(June):1-22.
- [2] Abanades S. A conceptual review of sustainable electrical power generation from biogas. *Energy Sci. Eng.* 2022; 10(2):630-655, doi: 10.1002/ese3.1030.
- [3] Phan TS. Hydrogen production from biogas: Process optimization using ASPEN Plus. *International Journal of Hydrogen Energy*; 47(100): 42027-42039. 2022. HAL Id: hal-03563223.
- [4] Vita A, Italiano C, Previtali D, Fabiano C, Paella A, Freni F, Bozzano G, Pino L, Manenti F. Methanol synthesis from biogas: A thermodynamic analysis. *Renew. Energy* 2018; 118: 673-684, doi: 10.1016/j.renene.2017.11.029.
- [5] da Silva Pinto RL, Vieira AC, Scarpetta A, Marques FS, Jorge RMM, Bail A, Jorge LMM, Corazza ML, Ramos LP. An overview on the production of synthetic fuels from biogas. *Bioresour. Technol. Reports*, 2022; 18(1): 101104. doi: <https://doi.org/10.1016/j.biteb.2022.101104>.
- [6] Minutillo M, Perna A, Sorce A. Green hydrogen production plants via biogas steam and autothermal reforming processes: energy and exergy analyses. *Appl. Energy*, 2020; 277: 115452. doi: <https://doi.org/10.1016/j.apenergy.2020.115452>.
- [7] Chein RY, Chen WH, Chyuan Ong H, Loke Show P, Singh Y. Analysis of methanol synthesis using CO₂ hydrogenation and syngas produced from biogas-based reforming processes. *Chem. Eng. J.* 2021; 426:130835. doi: <https://doi.org/10.1016/j.cej.2021.130835>.
- [8] Marchese M, Giglio E, Santarelli M, Lanzini A. Energy performance of Power-to-Liquid applications integrating biogas upgrading, reverse water gas shift, solid oxide electrolysis and Fischer-Tropsch technologies. *Energy Convers. Manag.* 2020; 6: 100041. doi: <https://doi.org/10.1016/j.ecmx.2020.100041>.
- [9] Al-Wahaibi A, Osman AI, Al-Muhtaseb AAH, Alqaisi O, Baawain M, Fawzy S, Rooney DW. Techno-economic evaluation of biogas production from food waste via anaerobic digestion. *Sci. Rep.* 2020; 10(1):1-16. doi: 10.1038/s41598-020-72897-5.
- [10] Roy PS, Song J, Kim K, Park CS, Raju ASK. NCO₂ conversion to syngas through the steam-biogas reforming process. *J. CO₂ Util.* 2018; 25:275-282. doi: <https://doi.org/10.1016/j.jcou.2018.04.013>.
- [11] Zhao X, Joseph B, Kuhn J, Ozcan S. Biogas Reforming to Syngas: A Review. *iScience*, 2020; 23(5): 101082. doi: <https://doi.org/10.1016/j.isci.2020.101082>.
- [12] Lee J, Hong S, Cho H, Lyu B, Kim M, Kim J, Moon I. Machine learning-based energy optimization for on-site SMR hydrogen production. *Energy Convers. Manag.* 2021; 244: 114438. doi: <https://doi.org/10.1016/j.enconman.2021.114438>.
- [13] Byun M, Lee H, Choe C, Cheon S, Lim H. Machine learning based predictive model for methanol steam reforming with technical, environmental, and economic perspectives. *Chem. Eng. J.* 2021; 426: 131639. doi: <https://doi.org/10.1016/j.cej.2021.131639>.
- [14] Abdelkareem MA, Soudan B, Mahmoud MS, Sayed ET, AlMallahi MN, Inayat A, Olabi AG. Progress of artificial neural networks applications in hydrogen production. *Chem. Eng. Res. Des.* 2022; 182: 66-86. doi: <https://doi.org/10.1016/j.cherd.2022.03.030>.
- [15] Irie K, Tüske Z, Alkhoul T, Schlüter R, Ney H. LSTM, GRU, highway and a bit of attention: An empirical overview for language modeling in speech recognition. *Annu. Conf. Int. Speech Commun. Assoc.* 08-12-Sept, pp. 3519–3523, 2016, doi: 10.21437/Interspeech.2016-491.
- [16] Chen Y, Fu Z. Multi-Step Ahead Forecasting of the Energy Consumed by the Residential and Commercial Sectors in the United States Based on a Hybrid CNN-BiLSTM Model. *Sustain.* 2023;15(3):1-15. doi: 10.3390/su15031895.
- [17] Chicco D, Warrens MJ, Jurman G, The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Comput. Sci.* 2021; 7:1-24. doi: 10.7717/PEERJ-CS.623.
- [18] Barupal DK, Fiehn O. Generating the blood exposome database using a comprehensive text

- mining and database fusion approach. *Environ. Health Perspect.* 2019; 127(9): 2825-2830. doi: 10.1289/EHP4713.
- [19] Khair U, Fahmi H, Al Hakim S, Rahim R. Forecasting Error Calculation with Mean Absolute Deviation and Mean Absolute Percentage Error. *J. Phys. Conf. Ser.* 2017; 930(1):1-9. doi: 10.1088/1742-6596/930/1/012002.
- [20] De Myttenaere A, Golden B, Le Grand B, Rossi F. Mean Absolute Percentage Error for regression models. *Neurocomputing* 2016; 192: 38-48. doi: 10.1016/j.neucom.2015.12.114.