



Predictive equivalent consumption minimization strategy for power-split hybrid electric vehicles using Monte Carlo algorithm

Merve Nur Gül¹, Ozan Yazar^{1,2}, Serdar Coşkun^{1*}, Fengqi Zhang³, Lin Li⁴, İrem Ersöz Kaya⁵

¹Department of Mechanical Engineering, Faculty of Engineering, Tarsus University, 33400, Tarsus, Mersin, Türkiye

²Department of Rail Transport, Sorgun Vocational School of Technical Sciences, Bozok University, 66000, Sorgun, Yozgat, Türkiye

³School of Mechanical and Precision Instrument Engineering, Xi'an University of Technology, 710048, Xi'an, China

⁴School of Traffic and Transportation, Northeast Forestry University, 150040, Harbin, China

⁵Department of Computer Engineering, Faculty of Engineering, Tarsus University, 33400, Tarsus, Mersin, Türkiye

Highlights:

- A predictive equivalent consumption minimization strategy for a power-split hybrid electric vehicle is proposed
- To predict drive cycles under uncertainties, Monte Carlo algorithm is proposed
- Simulations are performed to compare the proposed strategy with a standard method under different driving cycles

Keywords:

- Hybrid electric vehicles
- Equivalent consumption minimization strategy
- Predictive control
- Monte Carlo algorithm
- Speed prediction

Article Info:

Research Article

Received: 24.12.2021

Accepted: 24.07.2022

DOI:

10.17341/gazimmfd.1040940

Acknowledgement:

This work is supported by the Turkish Scientific and Technological Research Council with Project Number 121E260 under the grant name CAREER.

Correspondence:

Author: Serdar Coşkun

e-mail:

serdarcoskun@tarsus.edu.tr

phone: +90 324 600 0000 /

2091

Graphical/Tabular Abstract

This article proposes a speed prediction algorithm based on MC estimation, wherein the predicted speed profiles are incorporated into ECMS, forming a P-ECMS, shown in Figure A. The P-ECMS determines the optimal power distribution over a prediction horizon for improved fuel economy under various drive cycles.

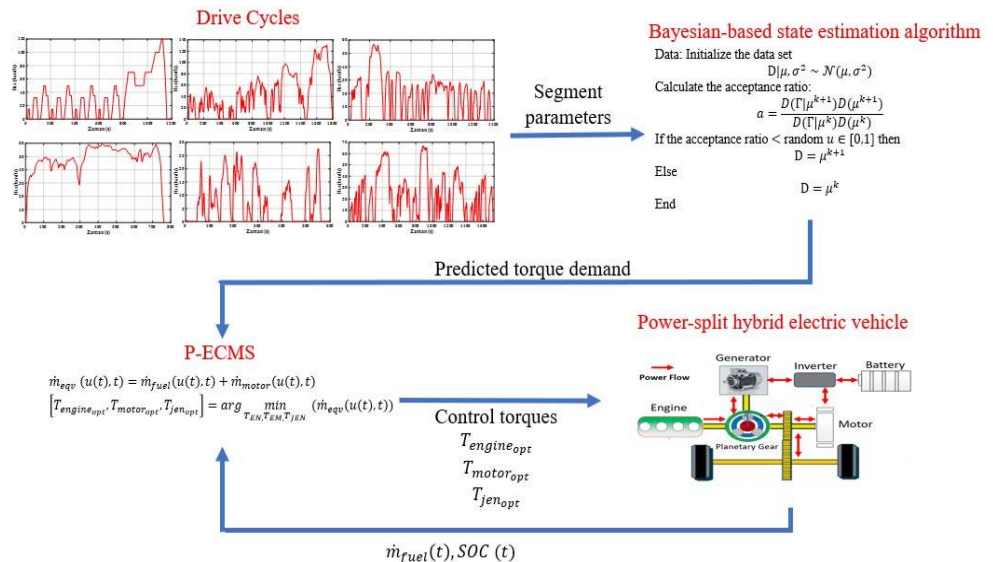


Figure A. The proposed P-ECMS closed-loop control diagram.

Purpose: The underlying research goal of this article is to put forward a reliable fuel saving performance based on the forecasted velocities of drive cycles for a power-split hybrid electric vehicle.

Theory and Methods: The power distribution between energy sources is devised by utilizing the P-ECMS for the power-split hybrid electric vehicle using the uncertain drive cycle velocity estimation based on MC algorithm.

Results: The effectiveness and accuracy of the method are evaluated under seven drive cycles. The MC provides good prediction results of the velocities. On the basis of it, the P-ECMS method decreases fuel consumption up to 6.01% under NEDC, up to 9.09% under WLTP, up to 6.33% under UDDS, up to 5.14% under HWFET, up to 1.96% under NYCC, up to 11.47% under LA-92, and up to 7.92% under ALL-CYC compared to a standard ECMS method.

Conclusion: It is seen from the analysis results that battery SOC decreases slightly using the P-ECMS since the electric motor is actively used to meet power demand instead of the engine over the predicted speed profiles. In the end, the MC algorithm-based P-ECMS strategy can verify the optimal power distribution based on fuel-saving potentials as compared to the baseline ECMS strategy while keeping the battery SOC at a reasonable interval.



Güç paylaşımli hibrit elektrikli araçlar için Monte Carlo algoritması kullanarak öngörülü eşdeğer tüketim minimizasyon stratejisi

Merve Nur Gül¹, Ozan Yazar^{1,2}, Serdar Coşkun^{1*}, Fengqi Zhang³, Lin Li⁴, İrem Ersöz Kaya⁵

¹Tarsus Üniversitesi, Mühendislik Fakültesi, Makina Mühendisliği Bölümü, 33400, Tarsus, Mersin, Türkiye

²Bozok Üniversitesi, Sorgun Teknik Bilimler Yüksekokulu, Raylı Sistemler Bölümü, 66000, Sorgun, Yozgat, Türkiye

³Xi'an Teknoloji Üniversitesi, Makina ve Enstrümantasyon Fakültesi, 710048, Xi'an, Çin

⁴Northeast Forestry Üniversitesi, Trafik ve Ulaştırma Fakültesi, 150040, Harbin, Çin

⁵Tarsus Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 33400, Tarsus, Mersin, Türkiye

ÖNEÇIKANLAR

- Güç paylaşımli bir hibrit elektrikli araç için, öngörülü eşdeğer tüketim minimizasyon stratejisi önerilmiştir
- Belirsizlikler altında sürüş çevrimlerini tahmin etmek için Monte Carlo algoritması önerilmiştir
- Önerilen strateji farklı sürüş döngüleri altında, standart bir yöntemle karşılaştırmak için simülasyonlar gerçekleştirilmiştir

Makale Bilgileri

Araştırma Makalesi

Geliş: 24.12.2021

Kabul: 24.07.2022

DOI:

10.17341/gazimmfd.1040940

Anahtar Kelimeler:

Hibrit elektrikli araçlar,
eşdeğer tüketim
minimizasyonu stratejisi,
öngörülü kontrol,
Monte Carlo algoritması,
hız tahmini

ÖZ

Bu çalışma, güç paylaşımli bir hibrit elektrikli araç (HEA) için, Monte Carlo (MC) algoritmasına dayalı olarak tahmin edilen sürüş çevrimi hızlarını kullanan öngörülü eşdeğer tüketim minimizasyonu stratejisi (Ö-ETMS) önermektedir. Önerilen Ö-ETMS, enerji kaynakları arasındaki güç dağılımını en iyi şekilde belirlemek için MC algoritması tarafından tahmin edilen hız profillerinden tam olarak yararlanmaktadır. Bu çalışmada; MC tabanlı Ö-ETMS metodunu doğrulamak için, New European Driving Cycle (NEDC), Worldwide Harmonised Light Vehicles Test Procedure (WLTP), Urban Dynamometer Driving Schedule (UDDS), Highway Fuel Economy Test (HWFET), New York City Cycle (NYCC), California Unified Cycle (LA-92) ve tüm döngülerin kombinasyonu (ALL-CYC) çevrimleri kullanılmış; toplam yedi tekrarlı sürüş döngüsü altında bir dizi simülasyon çalışması gerçekleştirilmiştir. MC tabanlı Ö-ETMS stratejisi, standart ETMS ile yakıt ekonomisi bakımında karşılaştırılmıştır. NEDC çevriminde %6,01, WLTP çevriminde %9,09, UDDS çevriminde %6,33, HWFET çevriminde %5,14, NYCC çevriminde %1,96, LA-92 çevriminde %11,47 ve ALL-CYC çevriminde %7,92 oranla yakıt tasarrufu elde edilmiştir. Bu makaledeki sonuçlar, önerilen stratejinin yaygın olarak kullanılan temel yöntemle kıyasla, rekabetçi bir yakıt tasarrufu sağladığını ortaya koymaktadır.

Predictive equivalent consumption minimization strategy for power-split hybrid electric vehicles using Monte Carlo algorithm

HIGHLIGHTS

- A predictive equivalent consumption minimization strategy for a power-split hybrid electric vehicle is proposed
- To predict drive cycles under uncertainties, Monte Carlo algorithm is proposed
- Simulations are performed to compare the proposed strategy with a standard method under different driving cycles

Article Info

Research Article

Received: 24.12.2021

Accepted: 24.07.2022

DOI:

10.17341/gazimmfd.1040940

Keywords:

Hybrid electric vehicles,
equivalent consumption
minimization, predictive
control, Monte Carlo
algorithm, speed prediction

ABSTRACT

This work proposes a predictive equivalent consumption minimization (P-ECMS) strategy for a power-split hybrid electric vehicle (HEV) using predicted driving cycle speed based on Monte Carlo (MC) algorithm. The proposed P-ECMS fully takes advantage of the predicted speed profiles by the MC algorithm to optimally determine the power split among energy sources. In this study, to validate the workings of the MC-based P-ECMS scheme, a series of simulations under a total of seven replicated driving cycles including New European Driving Cycle (NEDC), Worldwide Harmonised Light Vehicles Test Procedure (WLTP), Urban Dynamometer Driving Schedule (UDDS), Highway Fuel Economy Test (HWFET), New York City Cycle (NYCC), California Unified Cycle (LA-92), and a combination of all (ALL-CYC) are conducted. The MC-based P-ECMS strategy is compared with a baseline ECMS in terms of fuel-saving. The fuel economy saving up to 6.01% under NEDC, 9.09% under WLTP, 6.33% under UDDS, 5.14% under HWFET, 1.96% under NYCC, 11.47% under LA-92, and 7.92% under ALL-CYC is achieved. The results in this article put forward that the proposed strategy delivers competitive fuel savings compared to the widely used baseline method.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : merve_gul@tarsus.edu.tr, ozan_yazar@tarsus.edu.tr, *serdarcoskun@tarsus.edu.tr, fengqizhang@xaut.edu.cn, lilin@nefu.edu.cn, iremer@tarsus.edu.tr / Tel: +90 324 600 0000 / 2091

1. Giriş (Introduction)

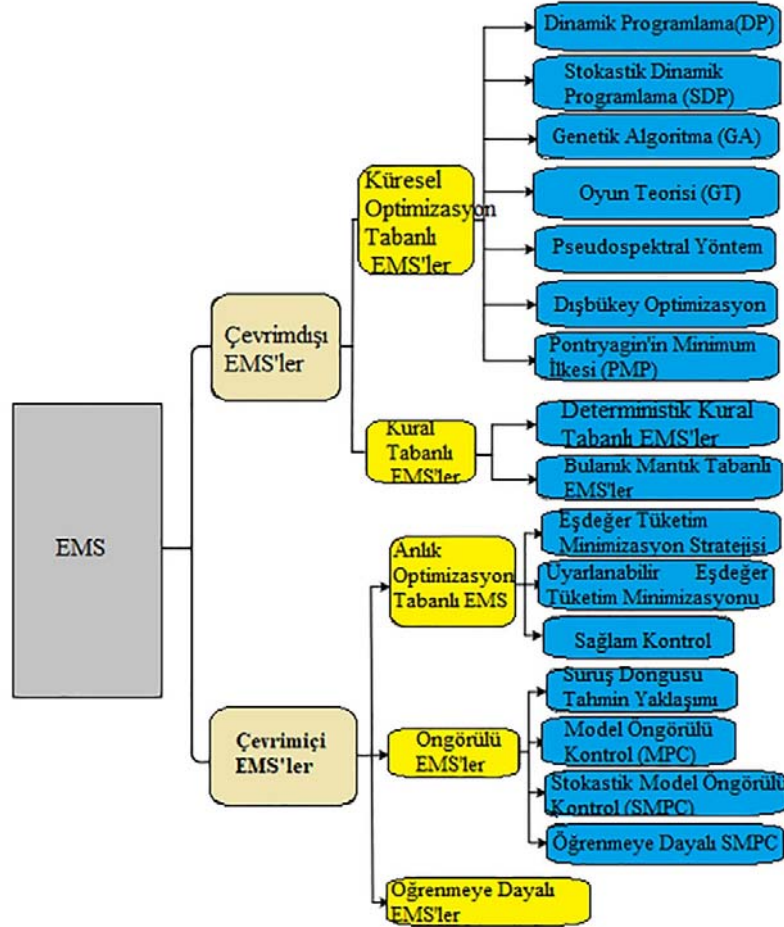
Günümüzün önemli problemlerinden biri olan çevre kirliliği ve beraberinde getirdiği iklim değişikliği gibi konular hidrokarbon yakıtlı araçların kullanımını bir sorun haline getirmiştir. Bu nedenle, karbon bazlı yakıtlarla çalışan araçlara nazaran daha az enerji harcayan, çevre dostu elektrikli hibrit araçlar, potansiyel bir çözüm olarak görülmektedir [1]. Hibrit elektrikli araçlar (HEA'lar), aracın yakıt ekonomisini artırmak için, güç kaynağı olarak yakıt ve elektrik gücünün bir kombinasyonunu kullanır. HEA'lar, genel olarak paralel, seri ve paralel-seri karışımı (güç paylaşımı) olarak üçe ayrılmaktadır [2]. Geleneksel içten yanmalı motor (İYM) tahrikli araçlarla karşılaştırıldığında; ek tahrik olan elektrikli motor güç aktarma sistemlerindeki güç kaynağı, ekstra kontrol serbestliği derecesine yol açar. Bu sebeple; çoklu güç kaynağı olan sistemlerde, iyi tasarlanmış bir enerji yönetim stratejisi (EYS) kullanılmalıdır.

EYS'nin ana işlevi, enerji tasarrufu potansiyelinden tam olarak yararlanmanın yanı sıra yakıt/elektrik tüketimi, emisyon veya bunların dikkatli bir kombinasyonu gibi ölçümleri optimize etmek amacıyla, alt sistemler içindeki güç üretimini, enerji depolamasını ve güç akışını kontrol etmek ve koordine etmektir. EYS'ler, yalnızca yerleşik elektrik gücü gereksinimi ve tahrik yükü gibi her türlü güç talebini karşılamak için besleme gücünü birden fazla tahrik kaynağı arasında bölmeyi değil, aynı zamanda aracın genel verimliliğini en üst düzeye çıkarmayı ve emisyon seviyelerini en aza indirmeyi amaçlar

[3-4]. Sürüş menzili, hızlanma, konfor ve rahatlık gibi faktörler, araç performansını etkileyen önemli araç tasarım kriterleridir [5]. Bununla birlikte, yakıt ekonomisinin iyileştirilmesi ve kirlenici emisyonun azaltılması birbiriyle çelişen hedefler olduğu kanıtlanmıştır. Bu nedenle, EYS aralarındaki dengeyi sağlayacak bir şekilde ayarlanmalıdır [6-9].

Literatürde, HEA için birçok EYS kontrolörü tasarımı önerilmiştir. Yakıt ekonomisini ve performansını iyileştirmek amacı ile EYS'lerin, çeşitli tekniklerin (çevrimdışı ve çevrimiçi) bir karışımını içerebileceği belirtilmektedir. Literatürden yararlanılarak ortaya çıkarılan, EYS sınıflandırması Şekil 1'de gösterilmektedir [10].

Bu çalışmada, gerçek trafik koşullarına uygunluğu açısından, Şekil 1'de verilen anlık optimizasyona dayalı EYS sınıfı üzerinde durulacaktır. Anlık optimizasyona dayalı EYS'ler, mevcut sürüş döngüsü bilgisini kullanan bir optimizasyon algoritması ile güç ayarını belirler. Bununla birlikte, performans endekslerini (örneğin yakıt ekonomisi, emisyonlar ve sürdürülebilirlik) her an göz önünde tutarak, optimum güç dağılımını belirlemeye odaklanırlar. Mantıksal kurallar önceden tanımlanmadığından, anlık optimizasyon EYS'leri ile basit kural tabanlı EYS'lere kıyasla daha iyi yakıt ekonomisi ve ayarlanabilirlik sağlanır [11]. Anlık optimizasyon tabanlı EYS'ler, makul hesaplama yükü ve ön izleme (tüm sürüş çevrim bilgileri) bilgisi gerektirmediğinden, gerçek zamanlı bir kontrolöre uygulanabilir ve çoğunlukla, işlem yükü ağır olan dinamik



Şekil 1. EYS'lerin Sınıflandırılması [10] (Classification of energy management strategies (EMSs))

programlamaya yakın optimal sonuçlara ulaşabilir. Çevrimiçi EYS'ler yerel (lokal) optimizasyona dayanır ve tüm sürüş döngüsü hakkında önceden bilgi sahibi olmayı gerektirmez. Çevrimdışı EYS'ler, global optimizasyon problemini anlık optimizasyon problemine dönüştürerek, sınırlı bir hesaplama yükü ile gerçek zamanlı olarak da uygulanabilirler [12-14]. Son yıllarda birçok araştırmacı; eşdeğer tüketim minimizasyon stratejileri (ETMS), uyarlanabilir ETMS, öngörülü ETMS ve dayanıklı kontrol dahil olmak üzere, temel olarak 4 grupta verilen anlık optimizasyon EYS'lerine odaklanmaktadır [15-18]. Pontryagin'in minimum ilkesine (PMI) dayanan ETMS, ilk olarak, HEA için Paganelli tarafından önerilmiştir [19-21]. ETMS'nin ana fikri, elektrik tüketimini eşdeğer yakıt tüketimine çevirip anlık eşdeğer yakıt tüketimini en aza indirerek gücün dağıtılmasıdır. Güç paylaşımı HEA'larda, ETMS'nin temel prensibi; batarya boşalırken, elektrik motorunun mekanik güç sağlamasıdır. Kullanılan elektrik enerjisi, eşdeğer tüketime dönüşmektedir. İYM mekanik gücü sağladığı durumda ise, batarya şarj olur. Mekanik enerji İYM tarafından alınır; elektrik enerjisine dönüştürülür ve bataryada depolanır. Depolanan bu elektrik enerjisi, elektrik motorunda mekanik güç üretmek için kullanılır. Böylece, mekanik enerjinin yakıt tasarrufu olarak kabul edilen bu kısmı, motor tarafından üretilmek zorunda kalmayacaktır. Bu şekilde, güç dağılımı, eşdeğer yakıt tüketimi en aza indirilerek belirlenir [10]. Bu yöntem, gerçek zamanlı kontrol için uygulanması kolaydır ve sürüş döngüsü hakkında önceden bilgi sahibi olmadan optimale yakın sonuçlar elde edilir. Diğer EYS'lerden farklı olarak, ETMS'deki kontrol değişkeni, ikincil güç kaynağının (elektrik motorunun), enerji tüketimi ile güç gereksinimi arasındaki ilişkiyi tanımlayan eşdeğer faktördür (EF). Standart ETMS, genellikle sabit bir optimal EF'yi benimser [22]. Fakat bu, değişen sürüş koşullarına uyum sağlayamaz [23, 24]. EF, yakıt ekonomisinin iyileştirilmesinde önemli bir rol oynar. Bu nedenle, farklı sürüş çevrimlerine göre, uygun bir eşdeğer faktörün seçilmesi önemli bir konudur. EF adaptasyonuna dayalı ETMS'ler, genellikle uyarlanabilir ETMS kategorisine girmektedir (Şekil 1). EF adaptasyonu, batarya şarj seviyesini (SOC) kontrol etmeye dayanmaktadır. Literatürde sürüş durumu tahminine dayalı birçok EF uyarlama algoritması önerilmiştir [25]. Örneğin, Zhang vd. çalışmasında, yapay sinir ağları kullanarak hız tahmini yaparak bir EF uyarlama algoritması geliştirmiştir [26]. Benzer şekilde, geçmiş sürüş verilerinden öğrenerek dinamik enerji yönetimi sağlayan bir sistemin önerildiği bir çalışma da bulunmaktadır [27]. Bir başka çalışmada bulanık mantık tabanlı EF uyarlama algoritması ETMS yöntemi için önerilmiştir [28]. Önceki çalışmalarda, gelecekteki sürüş belirsizliklerine dayalı güç tahmini hesabı yapılmadığından, enerji yönetimi performansı yeterince iyi olamamaktadır. Bu bağlamda, öngörülü EYS'lerin temel amacı, bir sürüş döngüsünün belirsizliği ve bozulmasıyla ilgili, tahmine dayalı bilgileri kullanarak güç dağılımını optimize etmektir. Bu nedenle, sürüş belirsizlikleri altında araç hızının doğru bir şekilde tahmin edilmesi önemlidir. Bu amaçla, bu çalışmada, karayolu araçlarının, sürüş döngüleri sırasındaki öngörülü stokastik hız tahminleri yapılacaktır. Tahmin doğruluğunu etkileyen faktörler arasında; sürücü davranışı, yol durumu, dinamik trafik koşulları, önceki araçlar vb. durumlar sayılabilir. Yanlış tahmin, bir EYS'nin performansını kötüleştirebilir. Bu nedenle, tahmin doğruluğunu geliştirmek için, daha fazla bilginin etkin bir şekilde dikkate alınması gerekir. Optimal kontrol girdisi, belirli bir durumda performans endekslerini (örneğin yakıt tüketimi ve emisyonlar) en aza indirerek elde edilebilir. Bu yaklaşım, değişen sürüş koşullarına uyum sağlamayan gerçek zamanlı bir uygulamayı benimser. Öngörülü ETMS (Ö-ETMS), temel bir ETMS ile karşılaştırıldığında, karmaşık gerçek sürüş koşullarına uyum sağlama yetenekleri nedeniyle, gerçek zamanlı uygulamalarda kullanmak için daha uygundur. [29-32].

Verimli bir HEA tasarımı, trafik ortamının doğru tahmin edilmesiyle başlar [33]. Monte Carlo simülasyonu, belirli bir trafik ortamında, trafik araçlarının göreceli hızlarını değerlendirmenin bir yoludur. Monte

Carlo tahmini farklı uygulama alanlarında kullanılmaktadır [34]. Bu çalışmada, ilk defa, HEA'lar için, Monte Carlo yöntemine dayalı sürüş döngülerinin belirsizliği altında hız tahmini yapılarak, EYS algoritması ile birleştirilerek gerçek zamanlı bir güç paylaşımı önerilmiştir. Bu amaçla; ilk olarak, güç paylaşımı bir HEA için bir Ö-ETMS stratejisi önerilmiştir; daha sonra, sürüş çevriminde kullanılan hız profillerini, belirsizlikleri altında tahmin etmek için bir Monte Carlo algoritması geliştirilmiştir; son olarak, önerilen tasarımın yakıt ekonomisindeki avantajlarını göstermek için, çeşitli sürüş döngüleri altında standart bir yöntemle karşılaştırılarak kapsamlı simülasyonlar gerçekleştirilmiştir.

2. Deneysel Metot / Teorik Metot (Theoretical Method/ Experimental Method)

2.1. Önerilen Algoritma (Proposed Algorithm)

Monte Carlo (MC) yöntemleri, belirli bir verinin ilk dağılımını kullanarak, deterministik hesaplamasını gerçekleştiren ve birleştirilmiş sonuçları toplayan bir algoritma sınıfıdır [35]. Yapılan çalışmada, sürüş çevrimlerini belirsizlik altında tahmin etmek için MC yöntemleri kullanılmıştır. Literatürde çok çeşitli MC algoritmaları bulunmakla birlikte; bu çalışmada, Metropolis-Hasting algoritması tercih edilmiştir. Bu algoritma ile, geleneksel yöntemlerin aksine, verilen ilk Gauss verilerinin önceki dağılımının ortalama değerinin (sürüş döngüsü hızını) bilinmediği varsayılır. Algoritmanın stokastik doğasını, sürüş çevrimlerini ölçmedeki belirsizlikleri yansıtır. Bilinmeyen ortalama hız, atanan ortalama hız (m) ve varyans parametreleri (η), normal dağılıma sahiptir. Matematiksel ifadeler aşağıda verilmektedir [36];

$$D|\mu, \sigma^2 \sim \mathcal{N}(\mu, \sigma^2) \quad (1)$$

Burada σ , önceki (prior) bilinen varyansadır

Eş. 1'de,

$$-\infty < \mu < \infty, \sigma^2 > 0 \\ \mu|m, \eta^2 \sim \mathcal{N}(m, \eta^2), m, \eta^2 \text{ olarak kabul edilir.}$$

Çalışmada, bilinmeyen ortalama hızın, alt sınır değeri 0 alınmıştır. Sürüş verileri (D) elde edildikten sonra, bilinmeyen parametrenin sonraki (posterior) olasılık dağılımı olan μ , tahminin ilk (prior) dağılımı yardımıyla bir dizi analitik işlem gerçekleştirilerek hesaplanır. Tahminin ortalaması ve varyansı aşağıda verilmektedir.

$$\hat{\mu} = \frac{\left(\frac{m}{\eta^2} + \frac{n\bar{m}}{\sigma^2}\right)}{\left(\frac{1}{\eta^2} + \frac{n}{\sigma^2}\right)}, \hat{\sigma}^2 = \frac{\eta^2 \sigma^2}{\sigma^2 + n\eta^2} \quad (2)$$

Eş. 2'de $\hat{\mu}$ tahmini ortalama, $\hat{\sigma}^2$ tahmini varyans ve n örnek sayısıdır. Tahminin sonraki (posterior) dağılımı, önceki (prior) dağılımı ve amaç fonksiyonunun (support function) çarpımının integrali ile tanımlandığından, analitik olarak değerlendirilmesi zordur. Metropolis-Hasting algoritması, bu integrali rastgele değer çekme (sampling) yöntemini kullanarak hesaplar [36]. Belirtilen varsayımlar altında, geliştirilen algoritma Şekil 2'de verilmektedir;

Algoritmadaki k , öngörü adımdır. Monte Carlo simülasyonunun ana özelliklerinden biri, hesaplamaların deterministik olmamasıdır; yani sonuçlar örnekleme boyutuna göre farklılık gösterebilir. Yukarıdaki algoritmada, sürüş döngüsü hız tahmininin doğruluğu, daha yüksek bir örnek sayısı ile artırılmıştır. Ancak, örnek sayısı ve simülasyon hızı arasında bir ters orantı bulunduğundan, örnek sayısının kontrollü artırılması gerekir.

Veri: İlk data setini başlatma

$$D|\mu, \sigma^2 \sim \mathcal{N}(\mu, \sigma^2)$$

Kabul oranını hesaplayın:

$$\alpha = \frac{D(\Gamma|\mu^{k+1})D(\mu^{k+1})}{D(\Gamma|\mu^k)D(\mu^k)}$$

Kabul oranı < rastgele $u \in [0,1]$ ise

$$D = \mu^{k+1}$$

Aksi halde

$$D = \mu^k$$

Son

Şekil 2. Bayesian tabanlı hız tahmin algoritması
(Bayesian-based speed prediction algorithm)

2.2. Enerji Yönetimi Problem Formülasyonu (Energy Management Problem Formulation)


Bu yazıda, çalışma nesnesi olarak güç paylaşımlı bir HEA seçilmiştir. Hem seri hem de paralel konfigürasyon avantajlarına sahip olduğundan, ticari olarak en başarılı HEA güç aktarma organlarından biri olarak kabul edilir [37]. Güç paylaşımlı HEA topolojisi Şekil 3'te gösterilmektedir.

2.2.1. Kontrol tabanlı araç modeli (Control-oriented vehicle model)

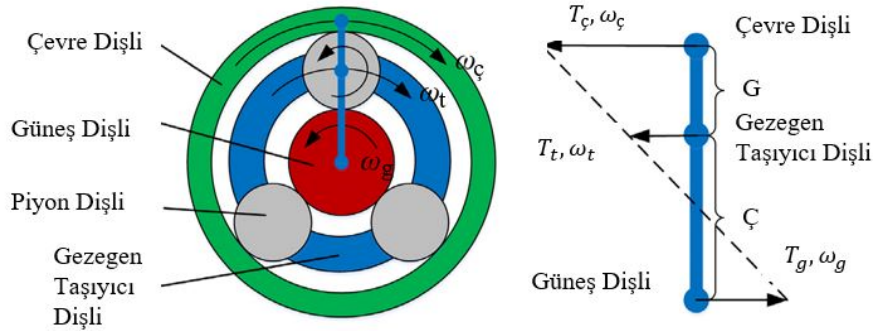
Bu çalışmada HEA için vites kutusu modeli olarak, bir planet dişli sistemi kullanılmaktadır. Planet dişli sisteminde, EM'nin planet taşıyıcıya bağlı olduğu, JEN'in güneş dişlisine bağlı olduğu ve nihai tahrike güç sağlamak için halka dişliyi EM ile birleştirmek için bir tork kuplörünün kullanılarak güç bölme işlevine sağlar. Şekil 4'te planet dişli yapısını ve kaldıraç diyagramını gösterilmektedir. Dişli sisteminin kinematik denklemleri; çevre dişli, güneş dişli ve gezegen taşıyıcının açısal hızları cinsinden türetilmektedir.

$$\omega_g(t) * G + \omega_\zeta(t) * \zeta = \omega_t(t) * (G + \zeta) \quad (3)$$

Eş. 3'te, G ve ζ , sırasıyla güneş dişlisinin ve çevre dişlinin yarıçaplarıdır. Çevre, güneş ve taşıyıcı dişlilerin açısal hızları sırasıyla; ω_ζ , ω_g , ω_t ile gösterilmiştir. Jeneratör (JEN), içten yanmalı motor gücünü kullanarak, akünün şarj edilmesine imkân sağlar veya doğrudan elektrik motorunu (EM)'i besleyebilir. Pinyon dişlilerinin, ataletini ihmal edilerek ve tüm güç aktarma şaftlarının rijit olduğu varsayılarak, güç aktarma sisteminin dinamikleri, Eş. 4-6'da verildiği şekilde türetilir:



Şekil 3. Güç paylaşımlı hibrit elektrikli araçların yapısı [10] (Structure of power-split hybrid electric vehicles)



Şekil 4. Planet dişli sisteminin yapısı (The structure of planetary gear system)

$$J_{JEN}\dot{\omega}_{JEN}(t) = T_{JEN}(t) + F * G \quad (4)$$

$$J_{IYM}\dot{\omega}_{IYM}(t) = T_{IYM}(t) - F * (G + \zeta) \quad (5)$$

$$J_{EM}\dot{\omega}_{EM}(t) = T_{EM}(t) - (T_{\text{saft}}(t)/g_f) + F * \zeta \quad (6)$$

Eş. 4, 5 ve 6'da J_{jen} ; J_{IYM} ve J_{EM} sırasıyla, JEN, İYM ve EM 'in ataletleridir; $T_{IYM}=T_t$ motor torku, $T_{JEN}=T_g$ ve $T_{EM}=T_c$, JEN ve EM torklarıdır (motor sürüş modunda pozitif); F pinyon dişlileri üzerindeki iç kuvveti temsil eder; g_f nihai tahrikin dişi oranı, T_{saft} ise tahrik aksındaki güç aktarma organından üretilen torktur. Daha basitleştirilmiş dinamik denklemler kullanmak için, Eş. 4-6'daki denklemlerin sol tarafında bulunan atalet kayıplarını ihmal edilip, türevi sifra eşitlenerek yok sayılır. Bu durumda, EM'in dönüş hızı ve saft tork gereksinimi Eş. 7-8 ile ifade edilir;

$$\omega_{EM}(t) = \frac{g_f}{R_{tekerlek}} V(t) \quad (7)$$

$$m\dot{V}(t) = \frac{T_{\text{saft}}(t)+T_{fren}(t)}{R_{tekerlek}} - mg\sin(\theta(t)) - \frac{1}{2}\rho AC_d V^2(t) - C_c mg\cos(\theta(t)) \quad (8)$$

Eş. 7'de, $R_{tekerlek}$ tekerlek yarıçapıdır; V araç hızıdır. Eş. 8'de, m araç kütlesi; T_{fren} , sürtünmeli fren torkudur; θ yol eğimini belirtir ve sıfır olduğu varsayılır; $\frac{1}{2}\rho AC_d$, aerodinamik sürtünme direncidir; C_c yuvarlanma direnci katsayısını temsil eder.

İYM, JEN ve EM arasında ideal bir tork paylaşımını gerçekleştirerek, yakıt tüketimini minimuma indirmek için bir denetleyici tasarlanır. JEN ve EM'in verimlilikleri, deneysel verilerden elde edilir. Yakıt tüketimi, verimlilik, açılma hız ve torklar arası ilişki aşağıda verilmiştir (Eş. 9-11).

$$\dot{m}_{\text{yakıt}}(t) = \Psi_1(\omega_{IYM}(t), T_{IYM}(t)) \quad (9)$$

$$\eta_{JEN}(t) = \Psi_2(\omega_{JEN}(t), T_{JEN}(t)) \quad (10)$$

$$\eta_{EM}(t) = \Psi_3(\omega_{EM}(t), T_{EM}(t)) \quad (11)$$

Burada; Ψ_1 , Ψ_2 ve Ψ_3 sembolleri sırasıyla İYM, JEN ve EM'in deneysel haritasını temsil etmektedir ve [14]'te verilmiştir.

Güç paylaşımli bir HEA'daki batarya (pil), bir invertör aracılığıyla elektrik için güç sağlamak veya elektrikten enerji geri kazanmak için kullanılmaktadır. Pili tanımlamak için bir temel direnç modeli kullanılır [38, 39]. Şarj durumu (SOC) aşağıdaki denklemlerle hesaplanmaktadır;

$$S\dot{O}C(t) = -\frac{I_{bat}(t)}{Q_{bat}} \quad (12)$$

$$I_{bat}(t) = \frac{V_{ac}(t) - \sqrt{V_{ac}^2(t) - 4 * R_{bat}(t) * P_{bat}(t)}}{2 * R_{bat}(t)} \quad (13)$$

Burada; Q_{bat} maksimum batarya kapasitesi, $I_{bat}(t)$ batarya akımı, V_{ac} batarya açık devre gerilimi, R_{bat} batarya iç direnci, $P_{bat}(t)$ batarya gücüdür. Terminal batarya güç gereksinimi aşağıda verilmektedir.

$$P_{bat}(t) = P_{JEN}(t) / (\eta_{JEN}(t) \eta_{\text{dönüştürücü}})^{k_{JEN}(t)} + P_{EM}(t) / (\eta_{EM}(t) \eta_{\text{dönüştürücü}})^{k_{EM}(t)} \quad (14)$$

Eş. 14'te, P_{JEN} ve P_{EM} , sırasıyla, JEN ve EM'in mil güçleridir. η_{JEN} , η_{EM} , ve $\eta_{\text{dönüştürücü}}$ sırasıyla, JEN, EM ve dönüştürücünün verimliliğidir.

1620

$$k_i = \begin{cases} 1 & P_i > 0 \\ -1 & P_i \leq 0 \end{cases}, \text{ için } i = \{JEN, EM\} \quad (15)$$

Eş. 3 – 15, uygulamada kullanılan enerji yönetimi stratejisi odaklı modeli açıklamaktadır.

2.2.2. Eşdeğer tüketim minimizasyonu yöntemi (Equivalent consumption minimization strategy)

ETMS; tüm sürüş çevrimi için ön bilgi gerektirmeksizin, İYM, EM, JEN ve bataryadaki kısıtlamaları kullanarak elektrik tüketimini eşdeğer yakıt tüketimine çevirip anlık eşdeğer yakıt tüketimini en aza indirmeyi amaçlayan bir optimizasyon yöntemidir. Elektrik tüketimini eşdeğer yakıt tüketimine dönüştürmek için EF gereklidir. Optimizasyon problemi için genel çözümü Eş. 16 ve Eş. 17'de verilmektedir.

$$\begin{aligned} \dot{m}_{EYT}(u(t), t) &= \dot{m}_{\text{yakıt}}(u(t), t) + \dot{m}_{EM}(u(t), t) \\ &= \dot{m}_{\text{yakıt}}(u(t), t) + s(t) \frac{P_{EM}(u(t), t)}{Q_{AID}} \end{aligned} \quad (16)$$

$$\left[T_{IYM_{opt}}, T_{EM_{opt}}, T_{JEN_{opt}} \right] = \arg \min_{T_{IYM}, T_{EM}, T_{JEN}} (\dot{m}_{EYT}(u(t), t)) \quad (17)$$

Alt ve üst sınırlar;

$$\begin{aligned} SOC^{min} &\leq SOC(t) \leq SOC^{max}, \\ I_{bat}^{min} &\leq I_{bat}(t) \leq I_{bat}^{max}, \\ T_{IYM}^{min} &\leq T_{IYM}(t) \leq T_{IYM}^{max}, \\ T_{JEN}^{min} &\leq T_{JEN}(t) \leq T_{JEN}^{max}, \\ T_{EM}^{min} &\leq T_{EM}(t) \leq T_{EM}^{max}, \\ P_{bat}^{min} &\leq P_{bat}(t) \leq P_{bat}^{max}, \\ \omega_{IYM}^{min} &\leq \omega_{IYM}(t) \leq \omega_{IYM}^{max}, \\ \omega_{JEN}^{min} &\leq \omega_{JEN}(t) \leq \omega_{JEN}^{max}, \\ \omega_{EM}^{min} &\leq \omega_{EM}(t) \leq \omega_{EM}^{max}, \end{aligned}$$

Eş. 16, anlık yakıt tüketimini, içten yanmalı motor, elektrik motoru ve jeneratör alt ve üst tork/hız değerleri altında, batarya gücü ve akımını da hesaba katarak minimize etmeyi amaçlar. Eş. 17'de bulunan optimal tork değerleri, mevcut tork değerleri arasında optimizasyon probleminde en iyi sonucu veren değerlerdir, diğer bir ifade ile $\left[T_{IYM_{opt}}, T_{EM_{opt}}, T_{JEN_{opt}} \right]$ karar değişken değerleri T_{IYM} , T_{EM} , ve T_{JEN} değişken setleri içinde, $\dot{m}_{EYT}(u(t), t)$ ifadesini minimum yapmaktadır. Bu optimizasyon problemine göre, eğer kontrol yasası $u^*(t)$ optimal ise (yukarıdaki çözümü minimum yapıyorsa), PMİ gereği gerekli koşullar sağlanır. Bulunan $u^*(t)$ değeri için, optimal kontrol probleminin Hamilton değeri her zaman en aza indirilir ve aşağıdaki denklemlerle (Eş. 18-21) ifade edilir.

$$H(x, u, \lambda) \geq H(x, u^*, \lambda) \quad (18)$$

x kontrol edilmek istenen sistem durumlarını göstermektedir ve Eş. 18'de verilen eşitsizlik ifadesi amaç fonksiyonu cinsinden tanımlanarak Eş. 19 ile ifade edilir.

$$H(x, u, \lambda) = \lambda f(x, u) + m'_{\text{yakıt}}(u) \quad (19)$$

Yardımcı değişken λ , Eş 20'de belirtilen durumu sağlamak zorundadır.

$$\dot{\lambda} = -\frac{\partial H}{\partial x} = -\frac{\partial f(x, u)}{\partial x} \quad (20)$$

Yukarıdaki koşulları sağlayan her değer, bir çözüm adayıdır. PMİ, Hamilton'u en aza indirerek, zamana bağlı olarak bir dizi çözüm

adayının bulunmasına yardımcı olur. Burada, λ , denklik faktörünü belirler. Yakıt enerjisi kullanımı ile elektrik enerjisi kullanımı arasındaki ilişki, denklik faktörü λ 'dan Eş. 21'de verildiği şekilde türetilir.

$$s(t) = -\lambda(t) * \frac{Q_{AID}}{E_{bat}} \quad (21)$$

Eş. 21'de, Q_{AID} kullanılan yakıtın alt ısı değerini gösterir ve E_{bat} pil enerji kapasitesi anlamına gelir.

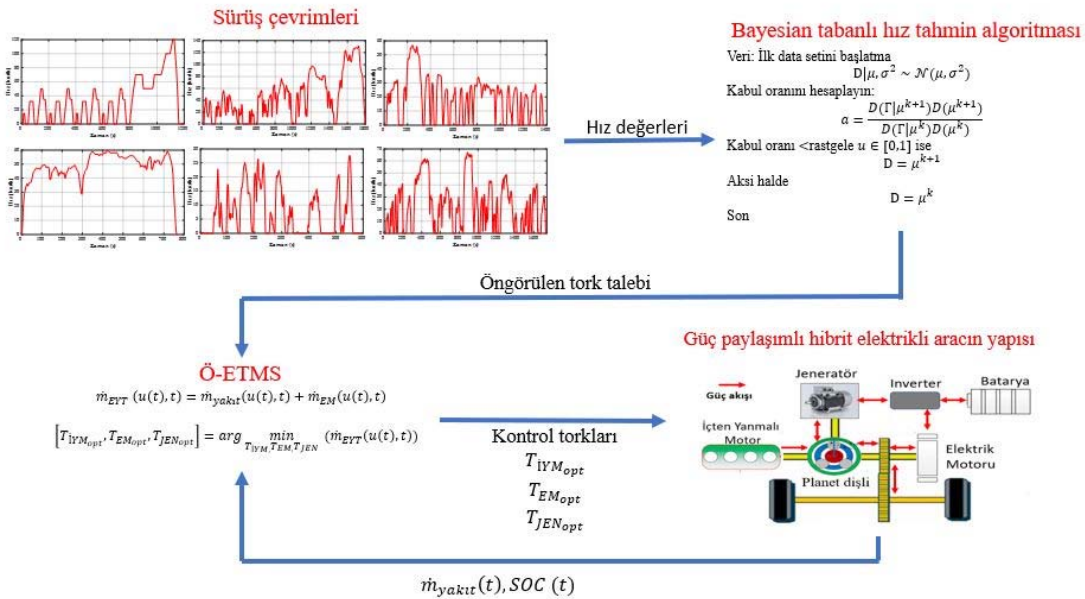
Şekil 5'te kapalı döngü kontrol diagramı gösterilmektedir. Burada, mevcut sürüş çevrimleri, simülasyonun o saniyesinde bozucular altında 3 s öngörü yapılarak, hem değeri bu aralıkta tahmin edilmiş hem de ETMS'nin çözümünde kullanılarak Ö-ETMS yöntemini ortaya çıkarmıştır. 0.2 s data toplama zamanı (sampling time) ve 3 s öngörü ufuğu ile, 15 öngörü adımı k oluşturmuştur, diğer bir ifade ile, 15 adım boyunca gelecek hız profilleri bozucular altında tahmin edilmiş ve Ö-ETMS bu ufuk boyunca ve her simülasyon adımında çözülmüştür. ETMS, anlık yakıt tüketimi minimizasyonunu, bir sonraki simülasyon adımı için sunmaktadır. Ö-ETMS, yine bir sonraki simülasyon adımı için çözüm sunmaktadır, ancak arka planda 3 s öngörü ufuğu boyunca (15 öngörü adımında) yakıt tüketimi minimizasyonu çözümü gerçekleştirerek, en iyi sonucu bir sonraki simülasyon adımı için vermektedir. Bu da avantaj sağlamaktadır. Kullanılan güç paylaşımli hibrit elektrikli aracın ana parametreleri Tablo 1'de verilmektedir.

3. Sonuçlar ve Tartışmalar (Results and Discussions)

Oluşturulan Ö-ETMS modelinin analizi yapılırken beş farklı sürüş çevrimi kullanılmıştır. Kullanılan bu sürüş çevrimleri, Yeni Avrupa Sürüş Döngüsü - New European Driving Cycle (NEDC), Dünya Çapında Uyumlu Hafif Araçlar Test Prosedürü - Worldwide Harmonised Light Vehicles Test Procedure (WLTP), Kentsel Dinamometre Sürüş Programı - Urban Dynamometer Driving Schedule (UDDS), Otayol Yakıt Ekonomisi Testi - Highway Fuel Economy Test (HWFET), New York Şehri Döngüsü - New York City Cycle (NYCC), Los Angeles (LA 92) ile tüm döngülerin kombinasyonu (ALL-CYC) çevrimleridir. Sürüş çevrimlerinin her zaman tam olarak tahmin edilememesinden dolayı, çalışmada, Bayesian yöntemlerine dayanan yeni bir tahmin yöntemi önerilmiştir. İlk olarak, tahminlerin doğruluğu (nominal değerlerden sapma), artırılan örnek sayısı (n) ile iyileştirilir. Öte yandan, Simulink modeli hızının yavaşlamaması amacıyla, hız verilerini analiz etmek için örnek sayısı olan $n = 1000$ olarak alınmıştır. η ve σ değerler, 0,05 olarak belirlenmiştir. Çalışmada önerilen algoritma, hız durumlarının tam değeri bilinmeyen μ için bir tahmin yapabilmektedir. Burada asıl amaç; araç sensörleri genellikle ölçüm yaparken bozucuların etkisini de hesaba katmaktır. Bu bağlamda, hibrit elektrikli bir aracın referans hızı, sensörler yardımıyla algıladığı varsayımı ile, referans hız çevrimlerin MATLAB'ın rand komutu ile gerçek değerlerinde saptırma gerçekleştirilmiştir. Bu da gerçek bir trafik durumunu oluşturmuştur. MC algoritması, stokastik ifadelerin

Tablo 1. Güç paylaşımli hibrit elektrikli aracın ana parametreleri (Main parameters of power-split hybrid electric vehicle) [40]


Bileşen	Parametre	Değer
İçten Yanmalı motor	Tipi	Dört silindirli sıralı benzinli motor
	Maksimum güç	57 kW @ 4500 RPM
Elektrik motoru	Maksimum tork	110 Nm @ 4500 RPM
	Tipi	AC motor
Pil	Maksimum güç	35 kW @ 1040-5600 RPM
	Maksimum tork	30 kW @ 3000-5500 RPM
	Enerji kapasitesi	5 kWh/pil paketi
	Şarj kapasitesi	2.3 Ah/akü ünitesi
	Pil hücresi düzeni	110 seri x 6 paralel




Şekil 5. Önerilen Ö-ETMS kapalı çevrim kontrol döngüsü (The proposed P-ECMS closed-loop control diagram)

tahmininde/hesaplanmasında, Bayesian yöntemi kullanarak çok yararlı sonuçlar vermiştir. Problem için yazılan, MC algoritmasının parametreleri, kullanılan çevrimlerin doğru hesaplanabilmesi, manuel simülasyon testleri gerçekleştirilerek belirlenmiştir.

NEDC, 4 kez tekrarlanan şehir içi sürüş döngüsü ile 1 şehir dışı sürüş döngüsünden oluşan, bir otomobilin Avrupa'daki tipik kullanımını temsil eden bir sürüş çevrimidir. NEDC'nin hız profili Şekil 6'da gösterilmektedir. WLTP, hafif araçlar için dünya ortalama sürüş koşullarına uyumlu bir sürüş çevrimini temsil etmektedir. WLTP sürüş çevriminin hız profili Şekil 7'de verilmektedir.




Şekil 6. NEDC hız profili (NEDC velocity profile)

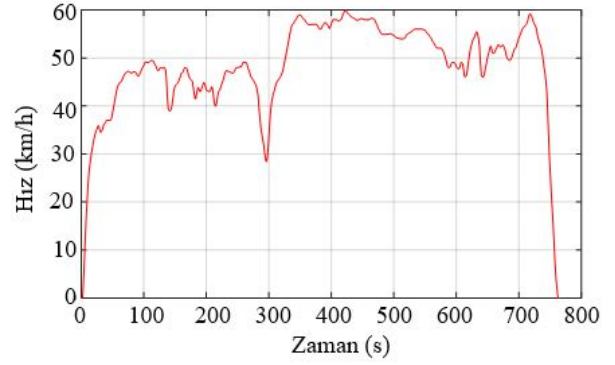


Şekil 7. WLTP hız profili (WLTP velocity profile)

UDDS, hafif ticari araçlar için oluşturulan bir sürüş çevrimidir. UDDS sürüş çevriminin hız profili Şekil 8'de verilmektedir. HWFET, hafif araçlar için, otoyolda yakıt ekonomisi sağlayan bir sürüş döngüsünü temsil etmektedir. HWFET sürüş çevriminin hız profili Şekil 9'da verilmektedir.

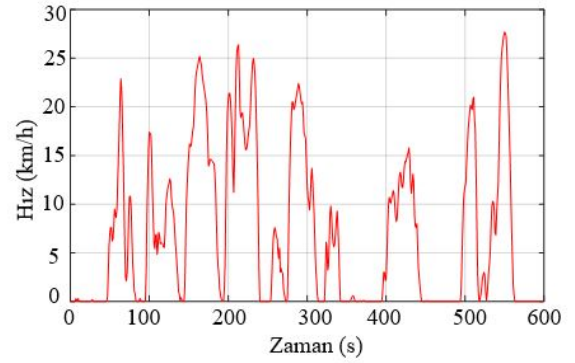


Şekil 8. UDDS hız profili (UDDS velocity profile)




Şekil 9. HWFET hız profili (HWFET velocity profile)

NYCC; New York'da, şehir içinde, düşük hızlı, dur ve kalk trafik koşullarına sahip bir sürüş çevrimidir. NYCC sürüş çevriminin hız profili Şekil 10'da verilmektedir. LA92; Los Angeles'da, şehir içinde, düşük ve orta hızlarda, dur ve kalk trafik koşullarına sahip bir sürüş çevrimidir. LA92 sürüş çevriminin hız profili Şekil 11'de verilmiştir. Bütün döngülerin olduğu sürüş çevrimi ise Şekil 12'de verilmektedir. Çevrimlere ait detaylı özellikler Tablo 2'de sunulmuştur.



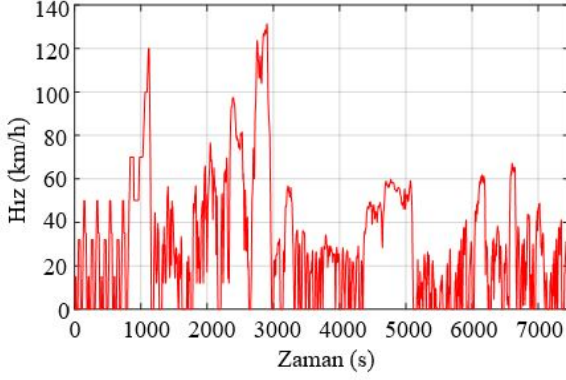
Şekil 10. NYCC hız profili (NYCC velocity profile)



Şekil 11. LA92 hız profili (LA92 velocity profile)

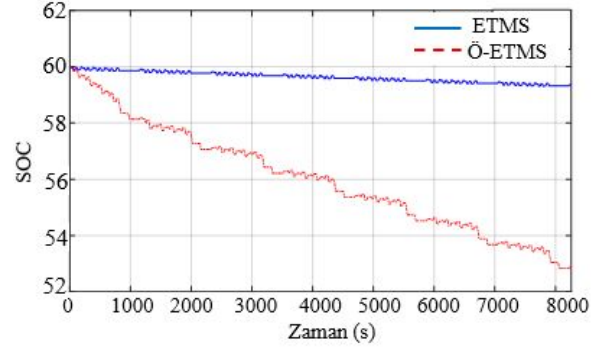
ETMS ve Ö-ETMS modellerinin daha iyi incelenebilmesi için, sürüş çevrimleri birkaç kez tekrarlanacak şekilde simülasyon gerçekleştirilmiştir. NEDC sürüş çevrimi 7, WLTP sürüş çevrimi 4, UDDS sürüş çevrimi 6, HWFET sürüş çevrimi 10, NYCC sürüş çevrimi 12, LA92 sürüş çevrimi ise 5 kez tekrarlanarak simülasyon

yapılmıştır. Oluşturulan sürüş çevrimi, orijinal ismi ile adlandırılmış; takip eden tekrarlar için numaraları eklenmiştir. Örneğin, NEDC_7, yapılandırılmış sürüş döngüsünün 7 kez tekrarlanan NEDC'den oluştuğunu ifade etmektedir. MC algoritması ile hesaplanan hata kareler toplamı-Integral Squared Error (ISE) Tablo 3'de sunulmuştur. Burada görüldüğü gibi; hız hesaplama hatası, tekrar eden döngüler boyunca çok küçük değerler almaktadır.




Şekil 12. ALL-CYC hız profili (Speed profile of ALL-CYC)

Monte algoritması, belirli bir zaman aralığında (3 s), öngörü (prediction) yapmaktadır. Hız çevrimleri 3 s zaman aralığında ve bozucu altında MC algoritması ile tahmin edilmektedir. Tahmin edilen bu hız aralığı, gelecekte HEA'nın hızlanma ve yavaşlama durumuna daha hazırlıklı olmasını, diğer bir deyişle, Ö-ETMS, 3 s aralığında çözülerek, minimum yakıt tüketimi sağlayacak şekilde güç kaynakları arasında tork dağılımı yapıp, daha az yakıt tüketimi sağlamaktadır. Sürüş çevrimlerinin direkt kullanıldığı, ETMS çözümü anlık olarak sadece bir sonraki zaman aralığında hesaplanmaktadır. Bu durumda, gelecekte oluşacak hızlanma ve yavaşlama durumları tahmin edilmediğinden, daha fazla yakıt tüketimi gerçekleşmiştir. Oluşturulan ETMS ve Ö-ETMS modelini bu 5 sürüş çevriminde incelemek için, MATLAB/Simulink'te tüm kodlar birlikte paketlenmiştir. ETMS ve Ö-ETMS yöntemleri kullanılarak; hibrit elektrikli aracın, tüm sürüş çevrimlerindeki şarj durumları - state of charge (SOC), yakıt tüketimi ve içten yanmalı motor, elektrik motoru, jeneratörün tork değerleri incelenmiştir. Başlangıçta, araçların batarya şarj durumu %60 seviyesindedir. SOC^{min} %50 ve SOC^{max} %70 olarak alınmıştır ancak yakıt tüketimi tasarrufuna karşı, Ö-ETMS'de yumuşak sınır değişkeni olarak alınmıştır. Elde edilen sonuçlara göre; NEDC_7 sürüş çevrimi için elektrikli hibrit aracın SOC değerleri Şekil 13'te gösterilmektedir.



Şekil 13. NEDC_7 SOC grafiği (NEDC_7 SOC graph)



Şekil 14. WLTP_4 SOC grafiği (WLTP_4 SOC graph)

NEDC_7 sürüş çevrimi için aracın SOC değerleri incelendiğinde; bataryanın şarj durumunun %60'tan, ETMS ile %59,37, Ö-ETMS ile %52,88 seviyesine düştüğü saptanmıştır. Bu çevrimde ETMS'nin, genellikle, İYM'yi aktif olarak kullandığı tespit edilmiştir. Bu yüzden, SOC seviyesinde gözle görünür bir fark görülmemiştir. Ancak, Ö-ETMS, 3 saniyelik bir öngörü ufuğu boyunca yaptığı tahmini kullanarak, İYM yerine EM'yi daha fazla kullanmıştır. Bu çalışmanın temel amacı, yakıt ekonomisi geliştirme ve SOC değerini belirli aralıklarda tutmaktır. Yakıt tüketimi, %6,01 oranında iyileştirilmiştir. WLTP_4 sürüş çevrimi için, bataryanın şarjı başlangıç durumundan, ETMS yöntemi ile %0,57, Ö-ETMS yöntemi ile %17,88 seviyesinde azaldığı belirlenmiştir (Şekil 14). Ancak bu çevrimde; yakıt tüketimi, Ö-ETMS ile %9,09 oranında iyileştirilmiştir. UDDC_6 sürüş çevrimi

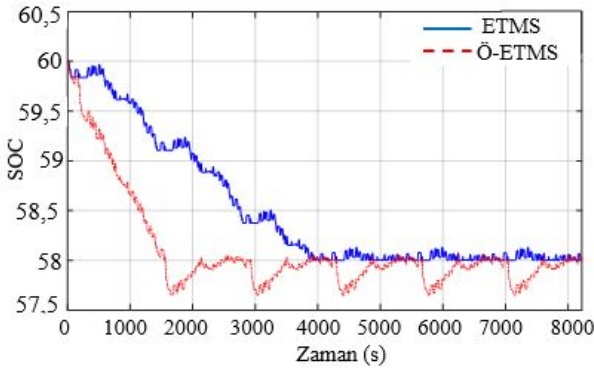
Tablo 2. Sürüş çevrimleri ve özellikleri (Driving cycles and characteristics)

Özellik	Birim	NEDC	WLTP	UDDS	HWFET	NYCC	LA92
Mesafe	km	10,9314	23,27	11,99	16,45	1,9	17,70
Toplam zaman	s	1180	1800	1369	765	598	1735
Rölanti süresi	s	267	235	259	4	210	300
Ortalama hız	km/h	33,35	46,5	31,51	48,3	11,5	36,74
Maksimum hız	km/h	120	131,3	56,7	60	27,5	67,24

Tablo 3. Öngörülen hızın hata kareler toplamı (Integral squared error of predicted speed)

Sürüş çevrimi	NEDC_7	WLTP_4	UDDS_6	HWFET_10	NYCC_12	LA92_5	ALL-CYC
Hata kareler toplamı (m/s)	28,98	48,17	9,503	35,92	1,583	14,86	24,99

için, elektrikli hibrit aracın SOC değerleri Şekil 15'te verilmektedir. Buna göre; SOC değerleri, bataryanın şarj durumunun, başlangıçtan, ETMS yöntemi ile %58,03 seviyesine, Ö-ETMS ile %58,03 seviyesine düştüğünü göstermektedir. Burada, Ö-ETMS ile yakıt tüketiminin %6,33 oranında iyileştirildiği görülmektedir. Şekil 16'daki, HWFET_10 sürüş çevrimi için verilen, SOC değerlerine göre bataryanın şarj durumu %60'tan, ETMS ile %60,43 seviyesine çıktığı, Ö-ETMS yöntemi ile %50,23'e düştüğü saptanmıştır. Bu çevrim, otoyol hızlarında, ancak 60 km/saat geçmeyen bir hız profiline sahip olduğundan dolayı, yakıt ekonomisi, Ö-ETMS tarafından %5,14 olarak iyileştirilmiştir. Aynı şekilde, şehir içi trafiği profiline sahip, NYCC_12 sürüş çevrimi için elektrikli hibrit aracın SOC değerleri Şekil 17'de verilmektedir. NYCC_12 sürüş çevrimi için aracın SOC değerleri incelendiğinde; bataryanın şarj durumu, ETMS ile %58,07 seviyesine, Ö-ETMS modeli için %58,05'e düştüğü belirlenmiştir. Bu çevrim için önemli bir tespit olarak; düşük hızlarda EM'nin her iki enerji yönetimi metodu tarafından aktif olarak kullanıldığı ve buna bağlı olarak, yakıt tüketiminin %1,96 oranında azaldığı söylenebilir. Şekil 18'de, LA92_5 sürüş çevrimi için, batarya şarj durumunun %60'tan, ETMS kullanarak %58,06 seviyesine, Ö-ETMS ile %52,99'a düştüğü gösterilmiştir. Bu çevrimde yakıt tüketimi, Ö-ETMS ile %11,47 oranında azaltılmıştır. Bunun başlıca sebebi, artan ve azalan hız profillerini iyi tahmin edebilme özelliği ve bu sayede Ö-ETMS'nin İYM'yi fazla kullanmaması; EM'nin hızlanma ve yavaşlamada aktif olarak kullanılmasıdır. Son olarak, tüm çevrimlerin kullanıldığı, ALL-CYC sürüş çevrimi için, SOC değerleri incelendiğinde (Şekil 19); bataryanın şarj durumu %60'tan, ETMS ile %58,06 seviyesine, Ö-ETMS ile %52,39 seviyesine düştüğü saptanmıştır. Yakıt ekonomisi, %7,92 oranında iyileştirilmiştir. ETMS ve Ö-ETMS metotları kullanılarak 7 sürüş çevriminde elektrikli hibrit aracın için elde edilen çevrim sonu şarj durumları ve yüzdelik değişimleri Tablo 4'de verilmektedir. Görüldüğü gibi, SOC seviyelerinde büyük değişimler bulunmamaktadır. Sürüş çevrimlerinin uzunluğu göz önüne alındığında; Ö-ETMS yönteminin SOC seviyesindeki değişime karşın yakıt tüketiminde azalma sağlaması önemli bir buluş ortaya koymaktadır.

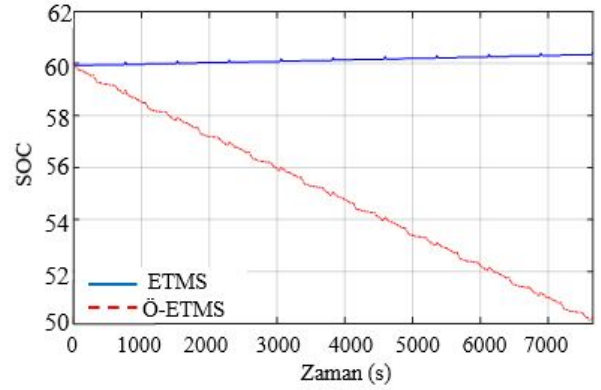


Şekil 15. UDDS_6 SOC grafiği (UDDS_6 SOC graph)

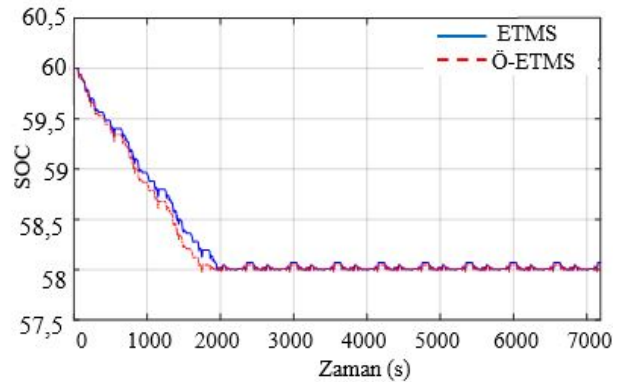
Elde edilen simülasyon sonuçlarına göre, NEDC_7, WLTP_4, UDDS_10, HWFET_6, NYCC_12, LA92_5, ALL-CYC sürüş çevrimleri için yakıt tüketimi değerleri Tablo 5'de verilmiştir. Yakıt tüketimleri hesaplanırken benzinin özgül ağırlığı 0,7 g/cm³ alınmıştır.

Bu çalışmanın bir sonraki adımı, ETMS ve Ö-ETMS yöntemlerini kullanarak, tüm sürüş çevrimleri altındaki tork dağılımının analiz edilmesidir. ETMS'nin temel olarak hedeflediği anlık yakıt tüketimini en aza indirmektir. Bunu gerçekleştirmek, İYM ve EM arasındaki tork dağılımına bağlıdır. Jeneratör ise, frenleme esnasında şarj seviyesini artırmaktadır. NEDC_7 sürüş çevrimi için, elektrikli hibrit aracın, ETMS ve Ö-ETMS yöntemlerini kullanarak elde edilen tork

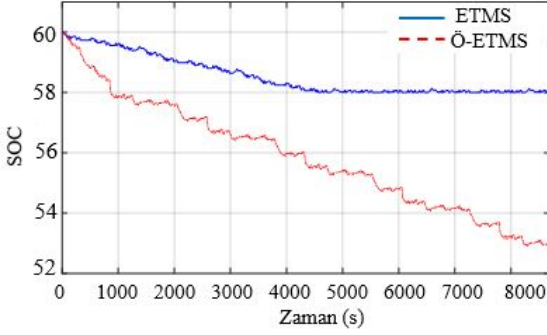
değerleri Şekil 20'de verilmiştir. Burada, İYM'nin, ETMS tarafından, EM'nin, Ö-ETMS tarafından aktif olarak kullanıldığı görülmektedir. WLTP_4 sürüş çevrimi için, elektrikli hibrit aracın tork değerleri Şekil 21'te gösterilmektedir. Burada, İYM, ETMS ile güç ihtiyacını karşılamak için, yüksek tork değerlerine çıkmaktadır ve bunun yakıt tüketimine olumsuz etkisi söz konusudur. Diğer taraftan şekilde, EM'nin, Ö-ETMS tarafından daha aktif kullanıldığı görülmektedir. UDDS_6 sürüş çevrimi için elektrikli hibrit aracın tork değerleri Şekil 22'de verilmektedir. İYM'nin, ETMS ile, güç gereksinimini karşılamak için yüksek tork değerlerine çıktığı açıkça görülmektedir. Diğer taraftan, Ö-ETMS ile EM, verimli bir şekilde bataryadan enerji kullanmaktadır. HWFET_10 sürüş çevriminde, elektrikli hibrit aracın tork değerleri için Şekil 23'te verilmiştir. NYCC_12 sürüş çevrimi, şehir içi trafiğini göstermektedir ve elektrikli hibrit aracın tork değerleri, özellikle her iki stratejinin benzer güç dağılımı yönelimleri ile Şekil 24'de gösterilmektedir. LA92_5 sürüş çevrimi için; ETMS ve Ö-ETMS ile elde edilen, elektrikli hibrit aracın tork değerleri Şekil 25'de verilmektedir. Bununla birlikte, önerilen stratejinin çalışması, farklı çevrimlerin kombinasyonu olan ALL-CYC sürüş çevrimi için de incelenmiştir. İYM, EM ve jeneratörün tork dağılımları, önceki döngülerde elde edilen sonuçları ispat edecek nitelikte Şekil 26'da gösterilmiştir. Bütün çevrimler için genel sonuçlar şu şekilde sıralanabilir; İYM'nin daha fazla kullanıldığı EYS, daha fazla yakıt tüketimine neden olmaktadır ve İYM bu yüzden batarya şarj seviyesini korumaktadır; EM'nin daha fazla kullanıldığı durumlarda ise, bataryadan daha fazla enerji çekilmekte, dolayısıyla şarj seviyesi düşmektedir. Ancak, şarj seviyesinin, başlangıç değerine göre %10 civarında düşüşü kabul edilebilir bir orandır. Jeneratör torku değeri, ETMS ve Ö-ETMS yöntemleri ile çok fazla bir değişim göstermemekle birlikte, yavaşlama durumlarında, her iki strateji de şarj seviyesini korumayı ve EM'yi beslemeyi amaçlamaktadır.



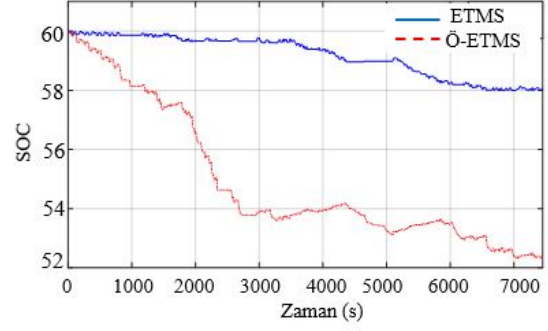
Şekil 16. HWFET_10 SOC grafiği (HWFET_10 SOC graph)



Şekil 17. NYCC_12 SOC grafiği (NYCC_12 SOC graph)



Şekil 18. LA92_5 SOC grafiği (LA92_5 SOC graph)



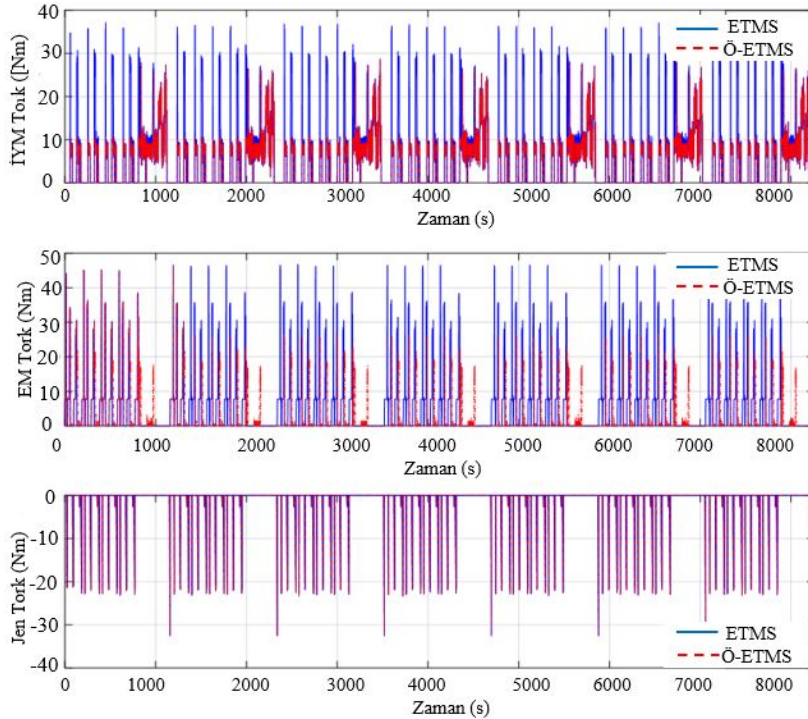
Şekil 19. ALL-CYC SOC grafiği (ALL-CYC graph SOC graph)

Tablo 4. Hibrit elektrikli aracın çevrim sonu SOC değerleri (End-of-cycle SOC values of hybrid electric vehicle)

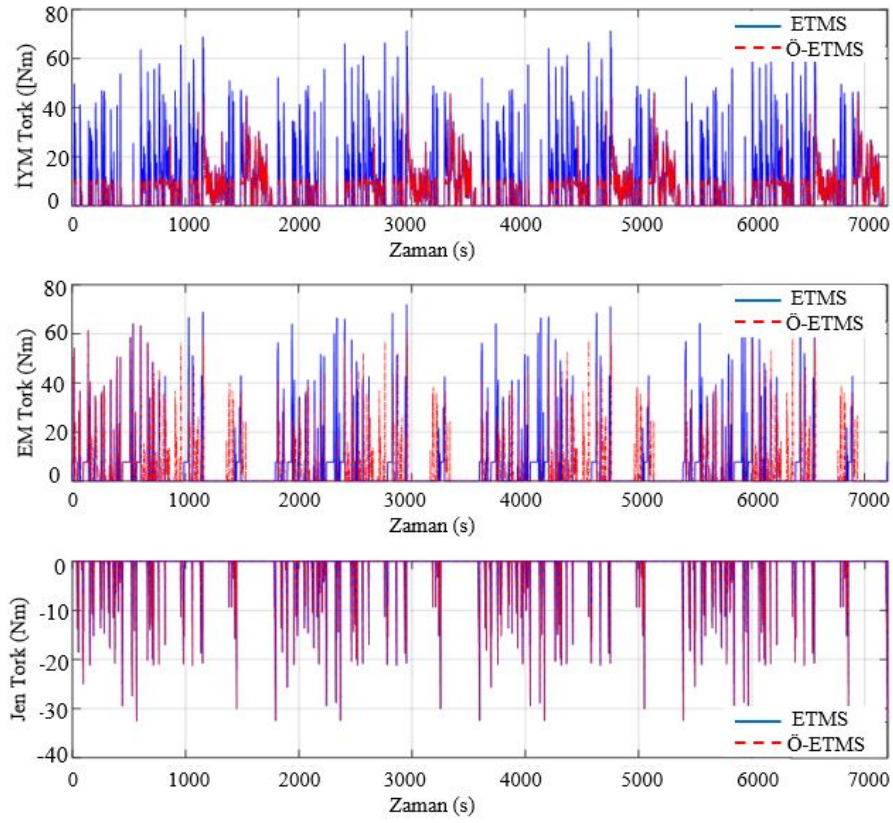
Sürüş çevrimi	SOC			
	ETMS	Yüzdelerik değışim (%)	Ö-ETMS	Yüzdelerik değışim (%)
NEDC_7	59,37	1,05	52,88	11,86
WLTP_4	59,43	0,95	42,12	29,8
UDDS_6	58,03	3,28	58,03	3,28
HWFET_10	60,43	-0,71	50,23	16,28
NYCC_12	58,07	3,21	58,05	3,25
LA92_5	58,06	3,23	52,99	11,68
ALL-CYC	58,06	3,23	52,39	12,68

Tablo 5. Hibrit elektrikli aracın yakıt tüketimi (Fuel consumption of hybrid electric vehicle)

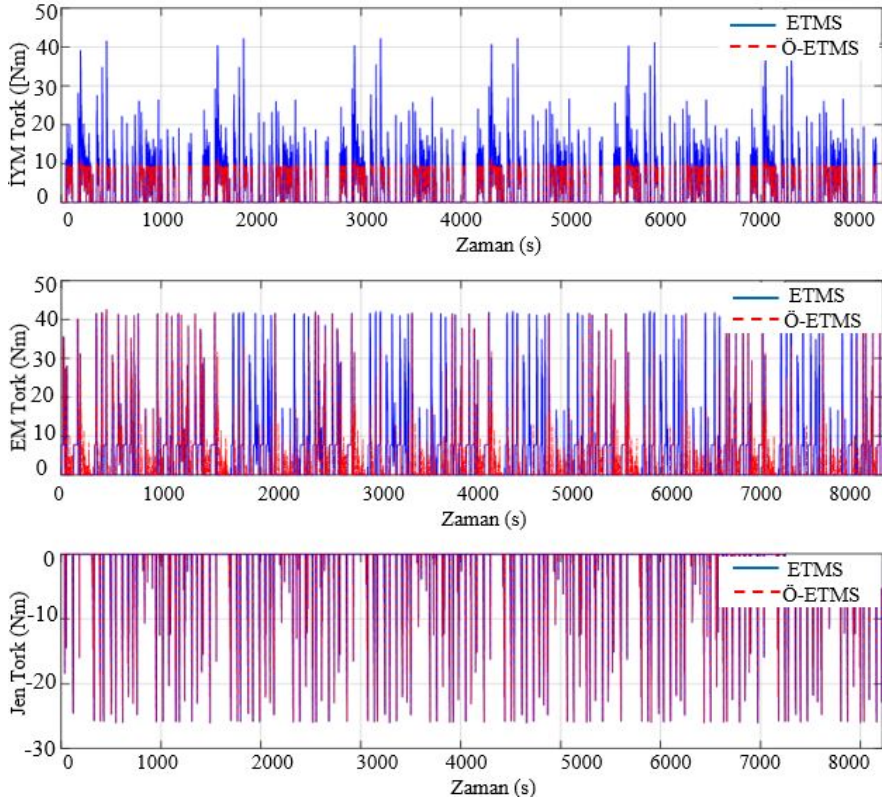
	Toplam alınan mesafe (km)	Harcanan yakıt (L)		100 km de harcanan yakıt miktarı (L/100km)		Fark (%)
		ETMS	Ö-ETMS	ETMS	Ö-ETMS	
NEDC_7	76,52	2,83	2,66	3,69	3,47	6,01
WLTP_4	93,05	3,63	3,30	3,90	3,54	9,09
UDDS_6	44,4	1,42	1,33	3,19	2,99	6,33
HWFET_6	102,6	3,11	2,95	3,03	2,87	5,14
NYCC_12	14,160	0,51	0,50	3,60	3,53	1,96
LA92_5	88,5	1,83	1,62	3,34	2,96	11,47
ALL-CYC	63,756	2,27	2,09	0,003	0,003	7,92



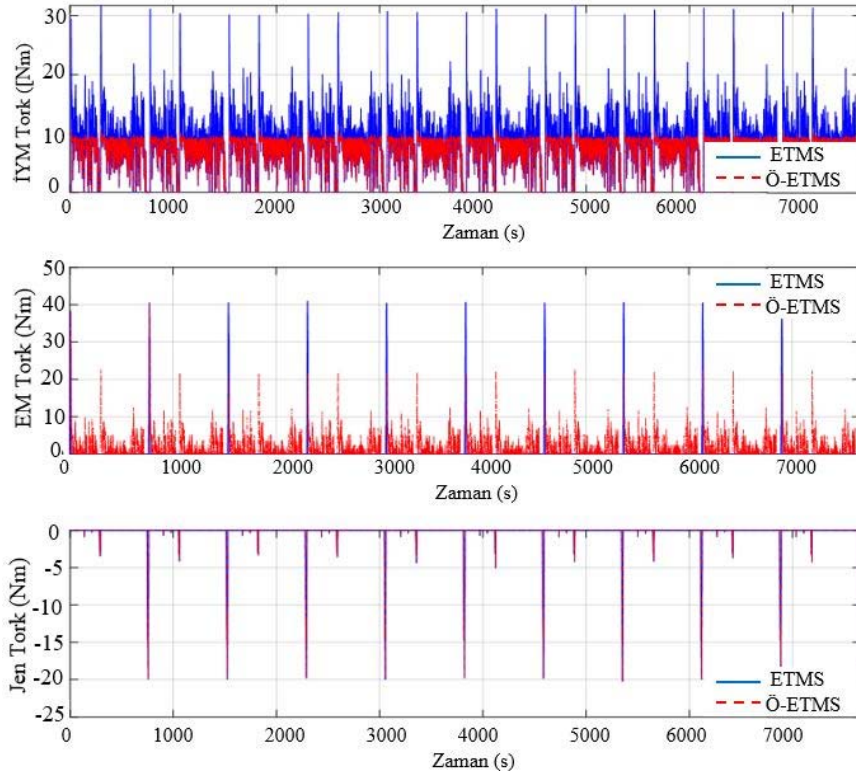
Şekil 20. NEDC_7 tork değerleri (NEDC_7 torque values)




Şekil 21. WLTP_4 tork değerleri (WLTP_4 torque values)



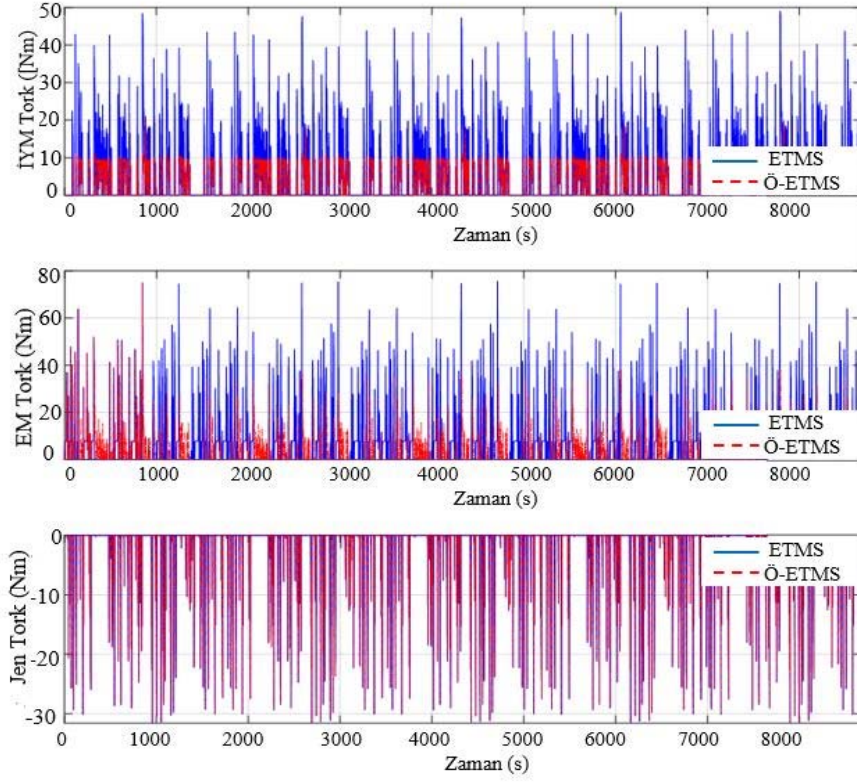
Şekil 22. UDDS_6 tork değerleri (UDDS_6 torque values)



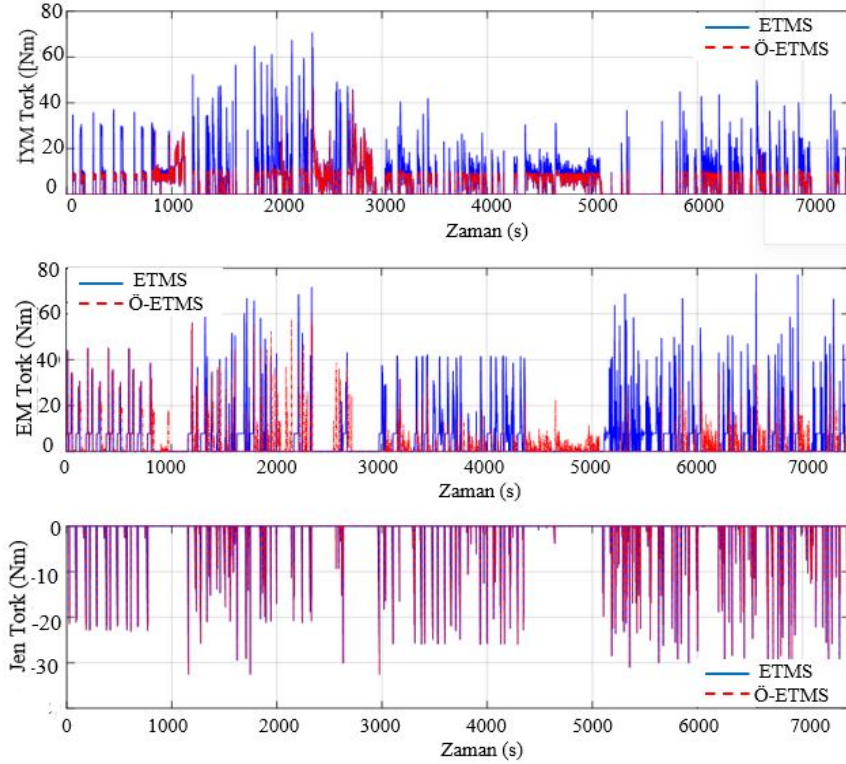
Şekil 23. HWFET_10 tork değerleri (HWFET_10 torque values)



Şekil 24. NYCC_12 tork değerleri (NYCC_12 torque values)



Şekil 25. LA92_5 tork değerleri (LA92_5 torque values)



Şekil 26. ALL-CYC tork değerleri (ALL-CYC torque values)

5. Sonuçlar (Conclusions)

Bu çalışmada, hibrit elektrikli araçların (HEA'ların) yakıt ekonomisini artırmak ve sürüş performansını iyileştirmek için, öngörülü eşdeğer tüketim minimizasyonu (Ö-ETMS) stratejisi önerilmektedir. Bu strateji, güç paylaşımlı bir HEA için, Monte Carlo (MC) algoritmasına dayalı olarak belirsizlikler altında tahmin edilen sürüş çevrimi hız tahminlerini kullanarak, Ö-ETMS yakıt ekonomisi ve batarya şarj durumunun korunması gibi zıt hedeflere ulaşabilmek amacı ile geliştirilmiştir. MC tabanlı Ö-ETMS metodu ile, New European Driving Cycle (NEDC), Worldwide Harmonised Light Vehicles Test Procedure (WLTP), Urban Dynamometer Driving Schedule (UDDS), Highway Fuel Economy Test (HWFET), New York City Cycle (NYCC), California Unified Cycle (LA-92) ve tüm döngülerin kombinasyonu (ALL-CYC) çevrimleri için, toplam yedi tekrarlı sürüş döngüsü altında; yakıt ekonomisi, batarya şarj durumu, içten yanmalı motor torku, elektrik motoru torku ve jeneratör torkları, bir dizi simülasyon çalışması yapılarak detaylı bir şekilde incelenmiştir. MC tabanlı Ö-ETMS stratejisi, standart ETMS ile karşılaştırıldığında; NEDC çevriminde %6,01, WLTP çevriminde %9,09, UDDS çevriminde %6,33, HWFET çevriminde %5,14, NYCC çevriminde %1,96, LA-92 çevriminde %11,47 ve ALL-CYC çevriminde %7,92 oranla yakıt tasarrufu elde edilmiştir.

Teşekkür (Acknowledgement)

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu tarafından 121E260 numaralı proje ile desteklenmektedir.

Kaynaklar (References)

- Zhang F., Hu X., Langari R., Cao D., Energy management strategies of connected HEVs and PHEVs: Recent progress and outlook, *Progress in Energy and Combustion Science*, 73, 235-256, 2019.
- Zhao Z., Tang P., Li, H., Generation, screening, and optimization of powertrain configurations for power-split hybrid electric vehicle: A comprehensive overview, *IEEE Transactions on Transportation Electrification*, 8 (1), 325-344, 2021.
- Omanovic, A., Zsiga, N., Soltic, P., Onder, C., Optimal degree of hybridization for spark-ignited engines with optional variable valve timings, *Energies*, 14 (23), 8151, 2021.
- Yazar O, Coskun S, Zhang F, Li L., A comparative study of energy management systems under connected driving: cooperative car-following case, *Complex Engineering Systems*, 2, 7, 2022.
- Li L., Coskun S., Langari R., Xi J., Incorporated vehicle lateral control strategy for stability and enhanced energy saving in distributed drive hybrid bus, *Applied Soft Computing*, 111, 107617, 2021.
- Wirasingha S.G., Emadi A., Classification and review of control strategies for plug-in hybrid electric vehicles, *IEEE Transactions on Vehicular Technology*, 60 (1), 111-122, 2010.
- Salmasi F.R., Control strategies for hybrid electric vehicles: Evolution, classification, comparison, and future trends, *IEEE Transactions on Vehicular Technology*, 56 (5), 2393-2404, 2007.
- Riaz M., Hanif A., Masood H., Khan M. A., Afaq K., Kang B. G., Nam, Y., An optimal power flow solution of a system integrated with renewable sources using a hybrid optimizer, *Sustainability*, 13 (23), 13382, 2021.
- Başlamışlı S. Ç., İnce B., Design of energy management system algorithms for the improvement of fuel economy of intracity hybrid buses and development of an adaptive hybrid algorithm, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (1), 559-576, 2021.
- Zhang F., Wang L., Coskun S., Pang H., Cui Y., Xi J., Energy management strategies for hybrid electric vehicles: Review, classification, comparison, and outlook, *Energies*, 13, 3352, 2020.
- Chen Z., Liu Y., Zhang Y., Lei Z., Chen Z., Li G., A neural network-based ECMS for optimized energy management of plug-in hybrid electric vehicles, *Energy*, 243, 122727, 2021.
- Liu J., Chen Y., Zhan J., Shang F., Heuristic dynamic programming based online energy management strategy for plug-in hybrid electric vehicles, *IEEE Transactions on Vehicular Technology*, 68 (5), 4479-4493, 2019.
- Chen H., Kessels J.T., Weiland S., Online adaptive approach for a game-theoretic strategy for complete vehicle energy management, In *Proceedings of the 2015 European Control Conference (ECC)*, Linz-Austria, 135-141, 15-17 July, 2015.
- Markel, T., Brooker, A., Hendricks, T., Johnson, V., Kelly, K., Kramer, B., ... & Wipke, K., ADVISOR: a systems analysis tool for advanced vehicle modeling, *Journal of Power Sources*, 110 (2), 255-266, 2002.
- Khodabakhshian M., Feng L., Wikander J., Improving fuel economy and robustness of an improved ECMS method, In *Proceedings of the 2013 10th IEEE International Conference on Control and Automation (ICCA)*, Hangzhou-China, 598-603, 12-14 June, 2013.
- Hemi H., Ghouili J., Cheriti A., A real time energy management for electrical vehicle using combination of rule-based and ECMS, In *Proceedings of the 2013 IEEE Electrical Power & Energy Conference*, Halifax, NS, Canada, 1-6, 21-23 August, 2013.
- Musardo C., Rizzoni G., Staccia B., A-ECMS: An adaptive algorithm for hybrid electric vehicle energy management, In *Proceedings of the 2005 44th IEEE Conference on Decision and Control and 2005 European Control Conference (CDC-ECC '05)*, Seville-Spain, 1816-1823, 12-15 December, 2005.
- Xie S., Li H., Xin Z., Liu T., Wei L., A Pontryagin minimum principle-based adaptive equivalent consumption minimum strategy for a plug-in hybrid electric bus on a fixed route, *Energies*, 10 (9), 1379, 2017.
- Zhang J., Zheng C., Cha S.W., Duan S., Co-state variable determination in Pontryagin's minimum principle for energy management of hybrid vehicles, *International Journal of Precision Engineering and Manufacturing*, 17 (9), 1215-1222, 2016.
- Li X., Wang Y., Yang D., Chen Z., Adaptive energy management strategy for fuel cell/battery hybrid vehicles using Pontryagin's minimal principle, *Journal of Power Sources*, 440, 227105, 2019.
- Paganelli, G., Design and control of a parallel hybrid car with electric and thermal powertrain. M. Sc., 1999.
- Xie P., Tan S., Guerrero J. M., Vasquez J. C., MPC-informed ECMS based real-time power management strategy for hybrid electric ship, *Energy Reports*, 7, 126-133, 2021.
- Onori S., Serrao L., On adaptive-ECMS strategies for hybrid electric vehicles, In *Proceedings of the International Scientific Conference on Hybrid and Electric Vehicles*, Malmaison-France, 6-7 December, 2011.
- Zeng Y., Cai Y., Kou G., Gao W., Qin D., Energy management for plug-in hybrid electric vehicle based on adaptive simplified-ECMS, *Sustainability*, 10 (6), 2060, 2018.
- Choi K., Byun J., Lee S., Jang I. G., Adaptive equivalent consumption minimization strategy (A-ECMS) for the HEVs with a near-optimal equivalent factor considering driving conditions, *IEEE Transactions on Vehicular Technology*, 71 (3), 2538-2549, 2021.
- Zhang F., Xi J., Langari R., Real-time energy management strategy based on velocity forecasts using V2V and V2I communications, *IEEE Transactions on Intelligent Transportation Systems*, 18 (2), 416-430, 2016.
- Lei Z., Qin D., Liu Y., Peng Z., Lu L., Dynamic energy management for a novel hybrid electric system based on driving pattern recognition, *Applied Mathematical Modelling*, 45, 940-954, 2017.
- Wang S., Huang X., López J. M., Xu X., Dong P., Fuzzy adaptive-equivalent consumption minimization strategy for a parallel hybrid electric vehicle, *IEEE Access*, 7, 133290-133303, 2019.
- Chen Z., Liu Y., Ye M., Zhang Y., Chen Z., Li G., A survey on key techniques and development perspectives of equivalent consumption minimisation strategy for hybrid electric vehicles, *Renewable and Sustainable Energy Reviews*, 151, 111607, 2021.
- Han J., Kum, D., Park Y., Synthesis of predictive equivalent consumption minimization strategy for hybrid electric vehicles based on closed-form solution of optimal equivalence factor, *IEEE Transactions on Vehicular Technology*, 66 (7), 5604-5616, 2017.
- Bayram A., Almalı M. N., Al-Naqshbandi F. M., Path following of an unmanned ground vehicle with GPS feedback using model predictive control method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38 (1), 345-355, 2023.
- Han J., Shu H., Tang X., Lin X., Liu C., Hu X., Predictive energy management for plug-in hybrid electric vehicles considering electric motor thermal dynamics, *Energy Conversion and Management*, 251, 115022, 2022.
- Wang L., Cui Y., Zhang F., Coskun S., Liu K., Li G., Stochastic speed prediction for connected vehicles using improved bayesian networks

- with back propagation, *Science China Technological Sciences*, 65 (7), 1524–1536, 2022.
34. Kim T., Poplin G., Bollapragada V., Daniel T., Crandall J., Monte Carlo method for estimating whole-body injury metrics from pedestrian impact simulation results, *Accident Analysis & Prevention*, 147, 105761, 2020.
 35. Chen M. H., Shao Q. M., Monte Carlo estimation of Bayesian credible and HPD intervals, *Journal of Computational and Graphical Statistics*, 8 (1), 69-92, 1999.
 36. Gill J., *Bayesian methods: A social and behavioral sciences approach*, 20, CRC press, USA, 2014.
 37. Yang Y., Hu X., Pei H., Peng Z., Comparison of power-split and parallel hybrid powertrain architectures with a single electric machine: Dynamic programming approach, *Applied Energy*, 168, 683–690, 2016.
 38. Hu X, Li S, Peng H., A comparative study of equivalent circuit models for Li-ion batteries, *Journal of Power Sources*, 198, 359–67, 2012.
 39. Moura SJ, Chaturvedi NA, Krstic' M., Adaptive partial differential equation observer for battery state-of-charge/state-of-health estimation via an electrochemical model, *Journal of Dynamic Systems, Measurement, and Control*, 136 (1), 011015, 2014.
 40. Rousseau A., Kwon J., Sharer P., Pagerit S., Duoba M., Integrating data, performing quality assurance, and validating the vehicle model for the 2004 Prius using PSAT[R]. SAE Technical Paper, 2006.