

Elektrikli Araç Şarj İstasyonları İçin Yüksek Verimli AA-DA Dönüştürücü Topolojileri ve Yapay Sinir Ağı Tabanlı Harmonik Bozunum Tahmini

High-Efficiency AC-DC Converter Topologies for Electric Vehicle Charging Stations and Artificial Neural Network-Based Harmonic Distortion Estimation

Murat ÜNLÜ¹, Ahmet BÜYÜKDAĞ¹

¹Kocaeli Üniversitesi (KOÜ), Mühendislik Fakültesi, Elektrik Mühendisliği Bölümü, Kocaeli, Türkiye

Öz

Elektrikli araçlardaki yüksek şarj süreleri ve menzil sorunları, bu araçların yaygınlaşmasını engelleyen önemli faktörler arasındadır. Şehirlerde ve yollarda şarj istasyonlarının yaygınlaşması, özellikle uzun yolculuklarda yaşanan menzil sorunlarını azaltmada etkili olacaktır. Bununla birlikte, elektrikli araçların cazibesini artırmak amacıyla şarj sürelerinin kısaltılması ve enerji verimliliğinin yükseltilmesi gerekmektedir. Bu doğrultuda, hızlı şarj cihazlarının geliştirilmesi hem araçların daha kısa sürede şarj edilmesini sağlamakta hem de şarj istasyonlarının etkinliğini arttırmaktadır. Literatürde, bu hedeflere ulaşmak için verimliliği arttırmayı amaçlayan farklı dönüştürücü topolojilerine dayalı çeşitli hızlı şarj istasyonu tasarımları incelenmiştir. Elektrikli araçların verimli kullanımı sağlamak için kritik konulardan biri de şarj işlemlerinde harmonik bozulmaların ve reaktif güç artışının kontrol altına alınmasıdır. Şebekeden sinüsoidal olmayan akımlar çekilmesi, harmonik bozulmalara ve reaktif gücün artmasına neden olarak güç kalitesini düşürmekte, enerji kayıplarına ve cihazların verimsiz çalışmasına yol açmaktadır. Bu nedenle, lineer olmayan yüklerin yönetimi ve etkilerinin sınırlandırılması, PFC (Power Factor Correction - Güç Faktörü Düzeltme) açısından büyük önem taşımaktadır. Bu makalede, elektrikli araç şarj istasyonlarında kullanılan AA-DA dönüştürücü topolojileri incelenmiş; geleneksel AA-DA dönüştürücüler ile PFC içeren topolojiler avantajları ve dezavantajları üzerinden karşılaştırılmıştır. Çalışmanın temel amacı, Totem-Kutuplu PFC Yükseltici topolojisinde toplam harmonik bozunum (THD) değerini yapay sinir ağı (YSA) kullanarak tahmin etmektir. Geliştirilen YSA tabanlı model, PFC topolojilerinde verimliliği artırmanın bir adımı olarak, THD değerini doğru bir şekilde tahmin edebilmekte ve böylece güç kalitesinin iyileştirilmesine katkı sunmaktadır. Modelin performansı MATLAB/Simulink ortamında test edilmiş ve başarılı sonuçlar elde edilmiştir. Bu çalışma, yapay sinir ağı tabanlı modelleme yaklaşımıyla güç dönüştürücülerde verimliliği artırma amacına yönelik bir katkı sunmaktadır.

Anahtar Kelimeler: Elektrikli araç şarj istasyonları, Güç faktörü düzeltme PFC Topolojileri, Toplam Harmonik Bozunum (THB), AA-DA Dönüştürücüler, Yapay Sinir Ağı (YSA)

Abstract

The high charging times and range issues in electric vehicles are among the significant factors hindering their widespread adoption. The proliferation of charging stations in cities and along roads will effectively mitigate range issues, especially on long journeys. However, to increase the appeal of electric vehicles, it is necessary to shorten charging times and enhance energy efficiency. In this direction, the development of fast chargers not only enables quicker vehicle charging but also improves the efficiency of charging stations. In the literature, various fast charging station designs based on converter topologies aiming to improve efficiency have been examined to achieve these goals. One of the critical aspects for the efficient use of electric vehicles is controlling harmonic distortions and reactive power increases during charging processes. Drawing non-sinusoidal currents from the grid causes harmonic distortions and an increase in reactive power, thereby reducing power quality, leading to energy losses, and causing devices to operate inefficiently. Therefore, managing non-linear loads and limiting their effects is crucial in terms of Power Factor Correction (PFC). This paper examines AC-DC converter topologies used in electric vehicle charging stations, comparing traditional AC-DC converters with topologies that include PFC based on their advantages and disadvantages. The main goal of the study is to predict the Total Harmonic Distortion (THD) value using an Artificial Neural Network (ANN) in a Totem-Pole PFC Boost topology. The developed ANN-based model can accurately predict the THD value, which is a step toward improving efficiency in PFC topologies, thereby contributing to the improvement of power quality. The model's performance was tested in the MATLAB/Simulink environment, yielding successful results. This study presents a contribution toward the goal of enhancing efficiency in power converters through an ANN-based modeling approach.

Keywords: Electric Vehicle Charging Stations, Power Factor Correction PFC Topologies, Total Harmonic Distortion (THD), AC-DC Converters, Artificial Neural Network (ANN)

I. GİRİŞ

Teknolojinin hızla ilerlemesi, enerji ihtiyacımızı her geçen gün artırmaktadır. Fosil yakıtların azalması ve enerji kaynaklarının sınırlı hale gelmesi, yenilenebilir enerji kaynaklarının önemini vurgularken, mevcut enerjinin daha verimli kullanılmasını da zorunlu kılmaktadır. Bunun yanı sıra, elektrik enerjisine olan talebin sürekli artması, elektrik şebekeleri üzerindeki yükü artırmakta ve bu şebekelerin karmaşıklığını derinleştirmektedir. Bu durum, enerji sistemlerinin daha verimli ve kararlı hale getirilmesi için yenilikçi çözümlerin gerekliliğini ortaya koymaktadır.

Şebekeye bağlı lineer olmayan yüklerin etkisi de bu süreçte önemli bir faktör haline gelmiştir. Güç kaynakları, elektronik cihazlar ve endüksiyon motorları gibi yükler, şebekeden sinüsoidal olmayan akımlar çekerek harmonik bozulmalara ve reaktif güç artışına neden olmaktadır. Bu bozulmalar, güç kalitesini olumsuz etkileyerek enerji kayıplarına ve cihazların verimsiz çalışmasına yol açabilmektedir. Bu nedenle, lineer olmayan yüklerin yönetimi ve etkilerinin sınırlandırılması, PFC açısından kritik bir önem taşımaktadır [1].

Günümüzde en yaygın kullanılan AA-DA dönüştürücü topolojilerinden biri, basit bir köprü diyot ve DA-DA dönüştürücüyü içeren Yükseltici anahtarlama modlu doğrultuculardır. Bu topoloji, yapısal basitliği ve yüksek güç faktörü avantajları ile öne çıkmaktadır. Ancak, köprü diyotların yüksek iletim direnci, özellikle yüksek güç seviyelerinde devrenin verimliliğini önemli ölçüde düşürmektedir [2].

Elektrik enerji sistemlerinde güç kalitesini olumsuz etkileyen faktörlerden biri de harmoniklerdir [3,4]. Lineer olmayan yüklerden kaynaklanan harmonikler, sistemdeki akım ve gerilim dalga formlarının temel frekanstan sapmasına neden olarak cihazların düzgün çalışmasını engellemektedir. Harmoniklerin önlenmemesi, sistemde rezonansa yol açarak aşırı gerilim ve akımlara neden olur, bu da sistem elemanlarının zarar görmesine yol açmaktadır [5,6]. Bu nedenle, sistemlerin güvenilir bir şekilde çalışması için güç sistemi harmoniğini hızlı ve doğru bir şekilde tahmin etmek büyük önem taşımaktadır [7].

Son yıllarda, güç dönüştürücülerinin analizine yönelik çeşitli modelleme teknikleri geliştirilmiştir. PWM anahtar modeli, transformatör modeli ve durum-uzayı ortalama modeli gibi yaklaşımlar dönüştürücüler için büyük önem taşımaktadır [8,9]. Bu modelleme teknikleri, dönüştürücünün kayıplarını, transfer fonksiyonunu ve diğer önemli parametrelerini, devre fiziksel olarak inşa edilmeden önce tahmin etmeyi mümkün kılmaktadır. Ayrıca, bu yöntemler, birçok güç elektroniği simülasyon aracının temelini oluşturmaktadır [10]. Bunun yanında, model tabanlı ve öngörücü kontrol stratejilerine yönelik ilgi de artmaktadır [11]. Bu gelişmeler, veri toplama ve işleme

tekniklerindeki ilerlemelerle birleşerek güç elektroniği alanında önemli fırsatlar yaratmıştır. Bu da sistem tasarımına daha bütüncül bir yaklaşım gerektiren modelleme ve analiz tekniklerinde ek gelişmeleri teşvik etmektedir.


Makine öğrenmesi kullanarak veri odaklı modelleme, sistem davranışını geniş bir çalışma koşulları yelpazesi altında modelleme ve tahmin etmek için farklı alanlarda yaygın olarak kullanılmaktadır. Örneğin, görüntü sınıflandırma, konuşma tanıma, güç sistemleri, dalga formu büyüklüğü tahmini ve kontrol sistemleri gibi uygulamalarda popülerlik kazanmıştır [12-15]. YSA'lar, güç dönüştürücülerinin hem geçici hem de kararlı durum özelliklerini yüksek doğrulukla modelleyebilmekte olup, aynı zamanda düşük maliyetli yazılımlar aracılığıyla da uygulanabilmektedir.

Bu tür çalışmalar sayesinde, makine öğrenmesi modern güç elektroniği endüstrisinde yaygın kabul görmeye başlamıştır.

Bu çalışmada, geleneksel AA-DA dönüştürücüler ile güç faktörü düzeltilmesi (PFC) içeren AA-DA topolojileri; devre şemaları, çalışma prensipleri, avantajları ve dezavantajları gibi çeşitli parametreler açısından incelenmiştir. Ardından, Totem-Kutuplu PFC Yükseltici devre için toplam harmonik bozunum değerini tahmin etmeye yönelik bir YSA modeli, Levenberg-Marquardt algoritması ile eğitilerek geliştirilmiştir. Model, test aşamasında değerlendirilmiş ve sonuçlar gözlemlenmiştir.

II. MATERYAL VE METOD

Elektrik araç bataryaları genellikle 400VDC gerilim ile şarj edilirler. Bu durumda, şebekeden beslenen piller için AC şebekenin DC'ye dönüştürülmesi ve 230VAA olan şebeke geriliminin 400VDC'ye yükseltilmesi gerekir. Bu özellikte çeşitli şarj devreleri kullanılmaktadır [16]. Bu işlem Şekil 1'de de görüldüğü gibi çeşitli dönüştürücüler yardımıyla yapılmaktadır.




Şekil 1. Şebeke ile şarj edilen pil şarj Devre şeması.

2.1. AA-DA Dönüştürücü Topolojileri

2.1.1. Geleneksel AA-DA dönüştürücüler

Geleneksel AA-DA dönüştürücü topolojisi genel olarak Şekil 2'de görüldüğü yapıya sahiptir. Bu tip dönüştürücülerde giriş gerilimi önce bir transformatör yardımıyla yükseltilir, daha sonra kontrollü veya

kontsüz doğruhtucular kullanılarak AA gerilim doğruhtulur. Ardından filtre devresi kullanılarak daha düzgün bir DC gerilimi elde edilmeye çalışılır.




Şekil 2. Geleneksel AA-DA dönüştürücü devre şeması

Geleneksel AA-DA Dönüştürücü devreleri basit yapıları sebebiyle yaygın kullanıma sahiptir. Ancak filtre devresi ve trafo, devrenin hacimsel olarak büyümesine sebep olur. Ayrıca diyotların yüksek iletim dirençleri; iletim kayıpları ve ısı problemlere sebep olmaktadır. Geleneksel dönüştürücüler, giriş kaynağının akımını ciddi şekilde bozar ve kaynaktan harmoniklere neden olarak düşük bir güç faktörüne yol açar [17].

2.1.2. PFC'li AA-DA dönüştürücüler

PFC'li dönüştürücü topolojileri transformatör kullanmadan gerilimi artırır. Bu da devrenin boyutunu büyük oranda azaltır. Aynı zamanda Güç Faktörünü düzenleyerek kayıpları ve harmonikleri minimuma indirir. Şekil 3'te PFC'li AA-DA dönüştürücü topolojisinin genel devre şeması görülmektedir.




Şekil 3. PFC'li AA-DA dönüştürücü devre şeması

Güç faktörü düzeltmesi için en yaygın kullanılan topoloji, Köprülü PFC Yükseltici topolojisidir. Ancak geniş bant aralıklı yeni nesil yarı iletkenlerin ortaya çıkışı, Totem Kutuplu PFC Yükseltici gibi köprüsüz topolojilerin uygulanmasını mümkün kılmıştır.

2.1.2.1. Geleneksel köprülü PFC yükseltici AA-DA dönüştürücüler


Geleneksel Köprülü PFC Yükseltici devreleri AA-DA dönüştürücüler arasında en çok kullanılan topolojidir. Topolojiye ait devre şeması Şekil 4'de yer gösterilmektedir. Bu devrede AA gerilim önce köprü diyotlar ile doğruhtulur. Daha sonradan Yükseltici devresi ile daha yüksek bir gerilime çıkartılır.



Şekil 4. Geleneksel köprülü PFC yükseltici devre şeması

Tek bir yükseltici dönüştürücü kullanılarak da güç faktörü düzeltmesi sağlanabilir, ancak bu durumda yüksek güçlü ve büyük bileşenlere ihtiyaç duyulabilir. Bu, pratik olmayabilir ve maliyeti artırabilir.

Daha yaygın olarak tercih edilen yöntem ise Şekil 5'de gösterildiği gibi iki veya daha fazla dönüştürücünün, birbirleriyle bir faz kayması olacak şekilde paralel olarak bağlanmasıdır. Bu durumda, dönüştürücüler birbirlerini tamamlayarak çalışırlar. Bu durum "faz kaydırma (interleaved)" olarak adlandırılır.




Şekil 5. Faz kaydırmalı PFC yükseltici devre şeması

Faz kaydırma, birincil dönüştürücünün çalışma döngüsünün, ikincil dönüştürücünün çalışma döngüsünün ortasına gelecek şekilde zamanlamasını ifade eder. Bu, her iki dönüştürücünün de giriş akımını doğru şekilde şekillendirmesine ve böylece güç faktörünü düzeltilmesine yardımcı olur.

Faz kaydırma tek bir dönüştürücüye göre daha verimli bir şekilde çalışabilir ve daha küçük bileşenler kullanılmasını sağlar. Ayrıca, giriş akımındaki dalgalanmaları azaltarak elektrik şebekesine daha az yük bindirir. Bu, enerji verimliliğini artırır ve elektrik sisteminin daha istikrarlı bir şekilde çalışmasını sağlar.

Geleneksel Köprülü PFC Yükseltici devresi, MOSFET'lerin yüksek frekanslarda anahtarlama kayıplarına, köprü diyotları ile yüksek iletim kayıplarına ve ayrıca yükseltici diyotun da iletim ve ters toparlanma kayıplarına sahiptir. Bu kayıplara ait grafik Şekil 6'da yer almaktadır [17]. Bu nedenle bu topoloji 3,5 kW'tan küçük uygulamalar için kullanılmalıdır [18].




Şekil 6. Geleneksel köprülü PFC yükseltici kayıpları

2.1.2.2. Totem-kutup PFC yükseltici dönüştürücüler

Totem Kutuplu PFC Yükseltici devresi, Şekil 7’de gösterildiği gibi yarı iletkenlerin iki farklı kolda kullanıldığı yapıya sahiptir.

D1 ve D2 diyotlarını içeren düşük frekans kolu şebeke frekansında (50-60 Hz) çalışmaktadır. Bu kol gelen gerilimi doğrultmak ile görevlidir.

Q1 ve Q2 anahtarlarını içeren kol ise yüksek frekanslarda çalışmaktadır. Bu kol ise gelen gerilimi yükseltmek ile görevlidir. Ayrıca kolda bulunan yarıiletkenlerin doluluk oranı üzerinden Güç Faktörü düzeltilir.



Şekil 7. Diyotlu totem kutuplu PFC yükseltici devre şeması

Yüksek anahtarlama frekanslarında yarı iletkenlerin anahtarlama kayıpları artmaktadır. Bu durum yarıiletken üzerindeki elektriksel ve termal kayıpları da artırmaktadır. Yüksek frekans kolunda yüksek frekanslarda dahi düşük anahtarlama kayıpları ve iletim dirençlerine sahip yeni nesil yarı iletkenler kullanılarak bu devrenin kayıpları minimize edilebilmektedir.


Bu topoloji, diyotların ters toparlanma süresinin ve harmonik bozulmaların azaltılması gibi avantajlara sahiptir.

Ayrıca devrede köprü diyotların olmaması sebebiyle düşük iletim kayıpları, trafo olmaması sebebiyle minimum boyut gibi avantajlara da sahiptir.

Bu topoloji, köprü aralıklı PFC’ler ile kıyaslandığı zaman verim, boyut ve maliyet açısından avantajlıdır [19,20].

Şekil 8’de yer alan diyotlarda oluşan fazla gerilim düşümünü engellemek amacıyla, diyotlar yerine iletim direnci çok daha düşük olan MOSFET’leri kullanılması önerilmektedir. Bu sayede daha yüksek verimle çalışacak Totem-Kutuplu PFC Yükseltici devresine yönelik çalışmalar da literatürde yer almaktadır.

Ancak bu devre daha fazla anahtar sürücü devresine ihtiyaç duymaktadır. Bu da devrenin dezavantajlarından [20].



Şekil 8. Totem kutuplu MOSFET’li PFC yükseltici devre şeması

2.2. Makine Öğrenimi Tabanlı Model Geliştirme

Bu çalışmada önerilen YSA tabanlı modelleme tekniğinin temel amacı, güç dönüştürücü devresinin toplam harmonik bozunum (THD) değerini tahmin etmektir. Model, THD’yi etkileyen ana parametreler olan bobin değeri ve anahtarlama frekansını girdi olarak almaktadır. Bu parametreler doğrultusunda, modelin toplam harmonik bozunum seviyesini doğru bir şekilde tahmin etmesi ve sunması beklenmektedir.

Model geliştirme süreci dört aşamadan meydana gelmektedir:

2.2.1. Veri toplama

Geliştirilen modelin performansı, kullanılan veri setinin kalitesi ile doğrudan ilişkilidir; bu nedenle veri toplama aşaması son derece önemlidir. Veri, donanım prototipinden veya bu donanımın doğru bir simülasyon modelinden elde edilir. Daha fazla veri kullanımı, daha hassas bir modele ulaşmayı sağlamaktadır; ancak bu durum hesaplama süreçlerini daha zorlayıcı hale getirmektedir.

Bu çalışmada, metodolojiye odaklanmak amacıyla veriler MATLAB simülasyonları üzerinden elde edilmiştir. Toplanan veri seti, endüktans ve anahtarlama frekansı parametre değerlerini ve bu parametrelere karşılık gelen toplam harmonik bozunum yanıtlarını içermektedir. Veri toplama aşaması, devrenin kararlı hale gelmesiyle başlatılmıştır.

Tablo 1, veri setinden alınan örnek verileri göstermektedir. Bu tabloda, aynı endüktans değeri için üç farklı anahtarlama frekansında elde edilen THD değerleri ile aynı anahtarlama frekansında üç farklı endüktans değerinde elde edilen THD değerleri sunulmuştur. Bu sayede, anahtarlama frekansı ve endüktans değerlerinin THD üzerindeki etkilerinin incelenmesi hedeflenmiştir.

Veri seti hazırlanırken anahtarlama frekans aralığının her 10 kHz değeri için, bobin değer aralığının ise her 25 uH değeri için ölçümler yapılmıştır.


Tablo 1. Veri setinde yer alan örnek veriler

Endüktans (uH)	Anahtarlama Frekansı (kHz)	THD (%)
250	10	3.133
250	50	3.134
250	100	3.279
100	50	7.427
275	50	2.879
450	50	1,93

2.2.2. YSA eğitim algoritması

Levenberg-Marquardt (LM) algoritması, çok katmanlı yapay sinir ağlarında eğitim sürecini hızlandırmak ve doğruluğu artırmak amacıyla geliştirilmiş güçlü bir optimizasyon yöntemidir. Bu algoritma, Newton-Raphson ve gradyan inişi yöntemlerinin avantajlarını birleştirerek özellikle hata fonksiyonunu en aza indirmek için kullanılır. Yapay sinir ağlarının çok katmanlı yapısında hızlı ve güvenilir bir yakınsama sağladığından dolayı LM algoritması tercih edilmektedir.

LM algoritmasının işleyişinde, her iterasyonda ağın hatasını hesaplamak ve her katmandaki ağırlıkları güncellemek önemli bir rol oynar. Bu süreçte sinir ağı genellikle Şekil 9'da da görüldüğü gibi üç temel katmandan oluşur: giriş katmanı, gizli katmanlar ve çıkış katmanı.



Şekil 9. LM algoritması katman gösterimi

İlk olarak, giriş katmanı, verilerin sinir ağına girdiği ilk adımdır. Giriş katmanı, modele öğrenilmesi gereken özellikleri aktarır, ancak ağırlık güncellemesi bu katmanda gerçekleşmez. Bu katmandaki nöronlar, veriyi sonraki katmanlara taşımak için bir köprü görevi görür. Dolayısıyla, giriş katmanında yalnızca verinin ağ boyunca yayılması sağlanır.

Sonraki adımda, gizli katmanlar, modelin öğrenme sürecinin gerçekleştiği ana katmanlardır. LM algoritması, her bir gizli katmandaki nöronlarda bulunan ağırlıkları ve kaymaları (biasları), modelin toplam hatasını en aza indirecek şekilde iteratif olarak günceller. Bu süreçte adaptif lambda değeri devreye girer. Lambda, algoritmanın gradyan inişi veya Newton-Raphson yöntemine göre daha güvenli veya daha hızlı bir adım atmasını sağlar. Yüksek bir lambda değeri olduğunda gradyan inişi yaklaşımı kullanılarak güvenli adımlar atılır; düşük lambda değeri ise daha hızlı Newton-Raphson yöntemine ağırlık verir. Gizli katmanlarda yapılan güncellemeler, hata fonksiyonunun türevlerine dayalı Jacobian matrisi kullanılarak yapılır ve bu, sinir ağına her katmanında hata oranını hızla düşürür.

Son olarak, çıkış katmanı, modelin tahmin ettiği sonucun hesaplandığı yerdir. Çıkış katmanında, modelin çıktısı ile gerçek değer arasındaki fark (örneğin Mean Squared Error - MSE) hesaplanır. LM algoritması bu hatayı en aza indirmek için her bir katmandaki ağırlık ve kayma değerlerini günceller. Çıkış katmanında hesaplanan hata, modelin genel doğruluğunu artırmak için geri yayılım yoluyla ağı tüm katmanlarında güncellemeler yapılmasını sağlar.

LM algoritmasını bu projede seçmemizin en önemli nedeni, çok katmanlı yapılarda modelin hata fonksiyonunu hızlı ve güvenilir bir şekilde minimize edebilmesidir. Özellikle karmaşık ve çok sayıda gizli katmanı olan sinir ağlarında, gradyan inişi yönteminin yavaş kalabileceği durumlarda LM algoritması adaptif yapısı sayesinde hızlı bir çözüm sunar. Adaptif lambda değeri ile gradyan inişi ve Newton yöntemleri arasında geçiş yaparak her bir katmanda hata oranını azaltır ve modelin öğrenme sürecini hızlandırır. [22,23]


2.2.3. Model doğrulama

Genellikle, veri satırlarının %70'i eğitim için, %30'u ise modelin test edilmesi için kullanılmaktadır. Bu oran ihtiyaca göre değiştirilebilir. Doğrulama süreci, verilerin örneklemeyle gerçekleştirilir. Eğer model bu

aşamada iyi sonuçlar vermezse, yeniden eğitilmesi gerekir. Model performansı, hata histogramları ve regresyon grafikleri kullanılarak değerlendirilebilir.

2.2.4. Model uygulaması

Model, test verileri ile tatmin edici sonuçlar verdiğinde, yeni test giriş değerleri kullanılarak doğrulanması gerçekleştirilmelidir. MATLAB'ın YSA araç kutusu kullanılarak model, bir kod veya Simulink bloğu olarak dışa aktarılabilir. Model, belirli bir giriş seti için bir çıktı üretecek ve bu çıktı, donanım veya simülasyon modeli ile karşılaştırılarak doğruluğu test edilecektir. Bu aşama, modelleme sürecini tamamlar.



Şekil 10. Totem kutuplu MOSFET'li PFC yükseltici devresinin Matlab Simulink modeli

III. BULGULAR VE TARTIŞMA

Veri toplama aşamasında kullanılan Totem-Kutuplu PFC Yükseltici devresinin MATLAB Simulink modeli Şekil 10'da gösterilmiştir. Eğitim esnasında kullanılan parametreler ise Tablo 2'de verilmiştir.

Tablo 2. Simülasyonda kullanılan parametre değerleri

Parametre	Değer
Giriş Gerilimi (VAA)	220
Çıkış Gerilimi (VDA)	400
Anahtarlama Frekansı (kHz)	10-100
Bobin Değeri (uH)	100-450
Kapasite Değeri (uF)	1963
Yük (Ω)	43
Zaman (saniye)	3

Veriler toplandıktan sonra model eğitimi gerçekleştirilmiştir. Eğitim sonucunda elde edilen modelin doğruluğunu kontrol edilmesini sağlayan grafikler aşağıda yer almaktadır.


Şekil 11'de gösterilen hata histogramı, modelin eğitim, doğrulama ve test aşamalarında elde edilen hata değerlerinin dağılımını görselleştirmektedir. Grafik, hedef değerler ile modelin tahmin ettiği değerler arasındaki farkları (hata değerlerini) farklı renklerle temsil etmektedir.

Yatay eksen, hata miktarlarını (hedef - çıktı) gösterirken; dikey eksen, her bir hata aralığında kaç örnek bulunduğunu ifade etmektedir. Modelin eğitim aşamasında oluşan hata değerleri mavi, doğrulama aşamasındaki hata değerleri yeşil, test aşamasındaki hata değerleri ise kırmızı renkle gösterilmiştir. Grafikteki turuncu çizgi ise sıfır hatayı temsil etmektedir ve modelin ideal durumda hedef değerle tam eşleşen tahminler yapması durumunu ifade etmektedir.

Hata dağılımının merkezde yoğunlaşmış olması, modelin büyük bir kısmının hedef değerlere oldukça yakın tahminler yaptığını göstermektedir. Bu durum,

modelin eğitim verilerinde başarılı bir öğrenme gerçekleştirdiğini ve genelleme yeteneğinin yüksek olduğunu işaret etmektedir. Hata değerleri simetrik bir dağılım göstermekte olup, modelin hedef değerler etrafında dengeli bir tahmin performansı sergilediği gözlemlenmiştir. Negatif ve pozitif hata değerlerinin dengeli olması, modelin herhangi bir yönde aşırı sapma göstermediğini belirtmektedir.

Sonuç olarak, bu hata histogramı, modelin genellikle hedef değerlere yakın tahminler yaptığını ve doğrulama ile test aşamalarında da genelleme yeteneğini koruduğunu göstermektedir. Bu analiz, modelin tahmin doğruluğunu ve güvenilirliğini vurgulamakta, gelecekte yapılacak iyileştirme çalışmaları için önemli bir temel oluşturmaktadır.




Şekil 11. Hata histogram grafiği

Şekil 12'de sunulan grafik, sinir ağı modelinin eğitim sürecinde ortalama kare hatanın (Mean Squared Error, MSE) iterasyonlar boyunca nasıl azaldığını göstermektedir. Modelin hata oranlarının dönemler (iterasyonlar) boyunca değişimini gösteren grafik, modelin öğrenme süreci ve genelleme yeteneği hakkında önemli bilgiler sunmaktadır.

Grafikte, yatay eksen dönemleri temsil ederken dikey eksen, logaritmik bir ölçekle ifade edilen ortalama kare hata (MSE) değerlerini göstermektedir. Başlangıçta yüksek hata oranıyla başlayan eğitim sürecinde, modelin eğitim verilerindeki hata oranı hızlı bir düşüş göstermektedir. Bu düşüş, modelin her bir iterasyon ile hedef değerlerine daha fazla uyum sağladığını göstermektedir.

Doğrulama setinde ise 16. dönemde en düşük hata değeri olan 0.0012752 MSE elde edilmiştir. Bu noktada model, doğrulama setinde en iyi performansını sergilemiştir. Bu aşamadan sonra, eğitim ve doğrulama hataları yatay bir seyir izleyerek stabil hale gelmiştir. Bu durum, modelin öğrenme sürecini tamamladığını ve daha fazla eğitim ile hata oranında büyük bir iyileşme sağlanamayacağını işaret etmektedir. Ayrıca, doğrulama ve test setindeki hata oranlarının eğitim setine yakın değerlerde stabil olması, modelin

genelleme yeteneğinin yüksek olduğunu ve aşırı öğrenme (overfitting) yapmadığını göstermektedir. Bu analiz, modelin eğitim süreci boyunca hedef değerlere uyum sağlama ve hata oranını azaltma yeteneğini ortaya koymakta ve modelin genelleme performansının yüksek olduğunu vurgulamaktadır.



Şekil 12. Performans grafiği


Şekil 13'de sunulan dört alt grafikteki her bir alt bölüm, farklı veri setleri üzerinde modelin hedef değerler ile tahmin ettiği değerler arasındaki uyumu göstermektedir. Bu grafikler, modelin genelleme yeteneğini ve doğruluğunu değerlendirmek açısından kritik öneme sahiptir.

Yatay eksen hedef değerleri, dikey eksen ise modelin tahmin ettiği çıktı değerlerini göstermektedir. Grafikteki kesikli doğrusal çizgi, ideal durumda hedef ve çıktı değerlerinin eşleştiği durumu ifade etmektedir. Her bir grafik üzerinde yer alan korelasyon katsayısı (R), modelin tahmin performansını sayısal olarak değerlendirmemize olanak tanır.

Eğitim setinde elde edilen R değeri 0.99971 olup, modelin hedef değerlere oldukça yakın bir doğrulukla tahmin yaptığını göstermektedir. Doğrulama setindeki R değeri ise 0.99948 olarak belirlenmiştir; bu değer, modelin eğitim sürecinde aşırı öğrenme yapmadığını ve yeni verilere genellelebildiğini gösterir. Test setinde elde edilen R değeri de 0.99968 olup, modelin daha önce görmediği verilere karşı da yüksek bir doğruluk sağladığını kanıtlamaktadır.

Toplam veri seti üzerinde hesaplanan R değeri 0.99969 olarak bulunmuştur. Bu yüksek korelasyon değeri, modelin tüm veri setlerinde güvenilir tahminler yaptığını ve hedef değerlere yakın sonuçlar verdiğini doğrulamaktadır. Tüm bu sonuçlar, modelin yüksek bir genelleme yeteneğine sahip olduğunu ve yeni veriler üzerinde başarılı bir performans sergileyebileceğini göstermektedir.

Bu analiz, modelin performansını daha detaylı bir şekilde ortaya koymakta ve doğruluk ile genelleme yeteneği açısından güvenilir bir yapay sinir ağı geliştirdiğimizi desteklemektedir.



Şekil 13. Regresyon grafiği


Bu sonuçlar, modelin hem eğitim hem de test aşamalarında tatmin edici performans gösterdiğini ortaya koymaktadır. Eğitilen model, Şekil 14'te gösterildiği gibi bir Simulink bloğu olarak elde edilmiştir. Eğitim aşaması tamamlandıktan sonraki adım, eğitilen modelin yeni parametre değerleri ile test edilerek doğruluğunun değerlendirilmesidir.

Test aşaması için parametreler, anahtarlama frekansı 85 kHz ve bobin değeri 365 μ H olarak belirlenmiştir. Bu parametreler, modelin eğitiminde kullanılan veri seti dışında seçilmiştir. Böylece, modelin farklı veri kümelerine karşı nasıl bir performans sergilediği gözlemlenmek istenmiştir.

Girilen parametre değerlerine ait Simülasyon sonucunda elde edilen toplam harmonik bozunum değeri Şekil 14'de görüldüğü gibi %2.307 olarak ölçülmüştür. Şekil 15'de görüldüğü üzere eğitilen modelin cevabı ise %2.294 olmuştur.




Şekil 14. Simülasyon Ölçüm Değeri



Şekil 15. Model Çıktısı

Şebekeden çekilen akımın dalga şekli Şekil 16'da yer almaktadır.



Şekil 16. Şebekeden Çekilen Akım

IV. SONUÇ VE DEĞERLENDİRMELER

Bu çalışmada, elektrikli araçların şarj istasyonlarında kullanılmak üzere Geleneksel AA-DA dönüştürücü, Faz Kaydırmalı PFC Yükseltici ve Totem Kutuplu PFC Yükseltici topolojileri incelenmiş ve karşılaştırılmıştır. Çalışmanın temel amacı, Totem-Kutuplu PFC Yükseltici devresine ait toplam harmonik bozunum (THD) değerini yapay sinir ağı kullanarak hesaplamaktır. Bu amaç doğrultusunda, THD değerinin doğru bir şekilde tahmin edilebilmesi için veri toplama, işleme, eğitim, test ve doğrulama gibi aşamaları içeren bir model geliştirilmiştir. Elde edilen modelin simülasyon sonuçlarına yakın yanıtlar verdiği gözlemlenmiştir.

Bu çalışma, makine öğrenimi teknikleriyle güç dönüştürücülerde THD analizine yönelik bir yaklaşım sunmaktadır. Gelecekteki çalışmalar, farklı çalışma senaryolarını kapsayacak şekilde modellerin daha da geliştirilmesini, daha yüksek doğruluk için alternatif makine öğrenimi yöntemlerinin araştırılmasını ve bu yöntemlerin diğer dönüştürücü topolojilerine genellenmesini içerecektir.

V. TEŞEKKÜR

Bu akademik çalışma TÜBİTAK 2209-B - Üniversite Öğrencileri Sanayiye Yönelik Araştırma Projeleri Desteği Programı kapsamında desteklenmiştir.

Ayrıca, makalemizin hazırlanmasında değerli zamanlarını ayırarak bilimsel titizlikle değerlendirme yapan saygıdeğer hakemlerimize en derin teşekkürlerimizi iletmek isteriz. Kıymetli yorumları, yapıcı eleştirileri ve önerileri ile çalışmamızın kalitesini ve bilimsel katkısını artırmamıza yardımcı oldular. Çalışmamızın alanımıza sağladığı katkılarda, onların rehberlik ve desteklerinin payı büyüktür. Teşekkür ederiz.

KAYNAKLAR

- [1] Balci, I., Bodur, H., & Gundogan, A. (2022). Investigation of Single-Phase Single-Stage Isolated Power Factor Correction Circuits. ELECO 2022 Electrical-Electronics and Biomedical Engineering Conference, Bursa, Turkey, 24-26 November 2022.
- [2] Choi, W.Y., Kwon, J.M., Kim, E.H., Lee, J.J., & Kwon, B.H. (2007). Bridgeless Boost Rectifier With Low Conduction Losses and Reduced Diode Reverse-Recovery Problems. IEEE Transactions on Industrial Electronics, 54(2), 769-780.

- [3] Shuai, Z., Huang, W., Shen, C., Ge, J., & Shen, Z.J. (2017). Characteristics and Restraining Method of Fast Transient Inrush Fault Currents in Synchronverters. *IEEE Transactions on Industrial Electronics*, 64(9), 7487-7497.
- [4] Zobaa, A.F., & Abdel Aleem, S.H.E. (2014). A New Approach for Harmonic Distortion Minimization in Power Systems Supplying Nonlinear Loads. *IEEE Transactions on Industrial Informatics*, 10(2), 1401-1412.
- [5] Meng, F., Xu, X., & Gao, L. (2017). A Simple Harmonic Reduction Method in Multipulse Rectifier Using Passive Devices. *IEEE Transactions on Industrial Informatics*, 13(5), 2680-2692.
- [6] Guzman, J. I., Melin, P. E., Espinoza, J. R., Moran, L. A., Baier, C. R., Munoz, J. A., & Guinez, G. A. (2012). Digital implementation of selective harmonic elimination techniques in modular current source rectifiers. *IEEE Transactions on Industrial Informatics*, 9(2), 1167-1177.
- [7] Wen, H., Teng, Z., Wang, Y., & Hu, X. (2013). Spectral Correction Approach Based on Desirable Sidelobe Window for Harmonic Analysis of Industrial Power System. *IEEE Transactions on Industrial Electronics*, 60(3), 1001-1010.
- [8] Erickson, R.W., & Maksimovic, D. (2001). *Fundamentals of Power Electronics*. Kluwer Academic.
- [9] Pan, C.T., & Chen, T.C. (1993). Modeling and Design of an AC to DC Converter. *IEEE Transactions on Power Electronics*, 8(4), 501-508.
- [10] Van Dijk, E., Spruijt, J.N., O'Sullivan, D.M., & Klaassens, J.B. (1995). PWM-Switch Modeling of DC-DC Converters. *IEEE Transactions on Power Electronics*, 10.
- [11] Karamanakos, P., Liegmann, E., Geyer, T., & Kennel, R. (2020). Model Predictive Control of Power Electronic Systems: Methods, Results, and Challenges. *IEEE Open Journal of Industry Applications*, 1, 95-114.
- [12] Wang, H., Li, G., Ma, Z., & Li, X. (2012). Application of Neural Networks to Image Recognition of Plant Diseases. *International Conference on Systems and Informatics (ICSAI2012)*, Yantai, China, 2159-2164.
- [13] Wu, B., Han, S., Shin, K.G., & Lu, W. (2018). Application of Artificial Neural Networks in Design of Lithium-ion Batteries. *Journal of Power Sources*, 128-136.
- [14] Simões, M.G., & Bose, B.K. (1996). Fuzzy Neural Network Based Estimation of Power Electronic Waveforms. *Eletrônica de Potência*, 1(1), 64-70.
- [15] Manitsas, E., Singh, R., Pal, B.C., & Strbac, G. (2012). Distribution System State Estimation Using an Artificial Neural Network Approach for Pseudo Measurement Modeling. *IEEE Transactions on Power Systems*, 27(4), 1888-1896.
- [16] Texas Instruments. (2024). 4-kW, Single-Phase Totem Pole PFC Reference Design With C2000 and GaN. Technical Document.
- [17] Indalkar, S.S., & Sabnis, A. (2019). Comparison of AC-DC Converter Topologies Used for Battery Charging in Electric Vehicle. *2nd International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICICT)*, Kannur, India, 1624-1627.
- [18] Musavi, F., Edington, M., Eberle, W., & Dunford, W.G. (2012). Evaluation and Efficiency Comparison of Front End AC-DC Plug-in Hybrid Charger Topologies. *IEEE Transactions on Smart Grid*, 3(1), 413-421.
- [19] Jimoh, B.A., & Roşu, Ş.G. (2023). Single-Phase AC-DC PFC Converters for EV Chargers: An Overview. *15th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*, Bucharest, Romania, 1-6.
- [20] Ortiz-Castrillón, J.R., Mejía-Ruiz, G.E., Muñoz-Galeano, N., López-Lezama, J.M., & Saldarriaga-Zuluaga, S.D. (2021). PFC Single-Phase AC/DC Boost Converters: Bridge, Semi-Bridgeless, and Bridgeless Topologies. *Applied Sciences*, 11, 7651.
- [21] Zhu, H., Hu, S., Fujishima, N., & Onishi, Y. (2021). Design Method of Totem-Pole PFC and CLLC Resonant Converter Based on SiC MOSFET. *6th International Conference on Power and Renewable Energy (ICPRE)*, Shanghai, China, 383-389.
- [22] Yan, Z., Zhong, S., Lin, L., & Cui, Z. (2021). Adaptive Levenberg–Marquardt Algorithm: A New Optimization Strategy for Levenberg–Marquardt Neural Networks. *Mathematics*, 9, 2176.
- [23] Zhao, L., & Otoo, C.O.A. (2019). Stability and Complexity of a Novel Three-Dimensional Environmental Quality Dynamic Evolution System. *Complexity*, 2019, 3941920.