

Gerilim Kaynaklı Eviricinin Faz Akımlarının İzlenmesiyle Açık Devre Arızalarının Teşhisi

Serenay ÇELİK^{1*}, Servet TUNCER²

^{1,2} Elektrik Elektronik Mühendisliği, Teknoloji Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

*¹ serenay.celik@firat.edu.tr, ² stuncer@firat.edu.tr

(Geliş/Received: 11/07/2024;

Kabul/Accepted: 25/09/2024)

Öz: Gerilim kaynaklı eviricilerin endüstriyel uygulamalarda yaygın olarak kullanılmasıyla, meydana gelen arızaların tanımlanması önemli bir araştırma konusu haline gelmiştir. Bu çalışmada, üç-fazlı iki-seviyeli eviricideki 24 farklı tekli ve çoklu açık anahtar devre arızaları incelenmiş, arızanın bulunduğu kol ve arızalı anahtarın tespiti yapılmıştır. Matlab/Simulink ortamında benzetimi yapılan eviricinin çıkış faz akımlarının ortalama, rms (etkin) değerlerinin yanı sıra ortalama/rms oranları da kullanılarak yük bağımlılığı problemi giderilmiştir. Çalışmada, destek vektör makineleri (SVM: Support Vector Machines), K-en yakın komşular (KNN: K-Nearest Neighbours), yapay sinir ağı (ANN: Artificial Neural Network) ve uzun kısa süreli bellek (LSTM: Long Short Term Memory) gibi dört farklı sınıflandırma modeli kullanılmış olup her bir modelin başarımını ayrı ayrı değerlendirilmiştir. Benzetim sonuçlarından, önerilen arıza teşhis ve sınıflandırma tekniklerinin tekli, çiftli ve üçlü anahtar arıza durumlarındaki tahmin başarısı yüksek doğrulukla sağlanmıştır.

Anahtar kelimeler: Açık devre arızası, makine öğrenmesi, derin öğrenme, faz akımları.

Diagnosis of Open Circuit Faults by Monitoring Phase Currents of Voltage Source Inverter

Abstract: With the widespread use of voltage source inverters in industrial applications, the identification of faults has become an important research topic. In this study, 24 different single and multiple open switch circuit faults in a three-phase two-level inverter were examined, and the branch where the fault was located and the faulty switch were identified. The load dependency problem was eliminated by using the average, rms (effective) values of the output phase currents of the inverter simulated in the Matlab/Simulink environment as well as the average/rms ratios. In the study, four different classification models such as Support Vector Machines (SVM), K-nearest Neighbors (KNN), Artificial Neural Network (ANN) and Long Short Term Memory (LSTM) were used and the performance of each model was evaluated separately. From the simulation results, the prediction success of the proposed fault diagnosis and classification techniques in single, double and triple switch fault cases was achieved with high accuracy.

Key words: Open circuit fault, machine learning, deep learning, phase currents.

1. Giriş

Gerilim kaynaklı eviriciler; ayarlanabilir hız sürücü uygulamaları, yenilenebilir enerji sistemleri gibi değişken gerilimlerin ihtiyaç duyulduğu vb. endüstriyel alanlarda önemli bir rol oynamaktadır [1]. Eviricilerin güç devresinde anahtarlama elemanı olarak yüksek performans özelliklerine sahip kapıdan yalıtımlı bipolar transistörler (IGBT: Insulated Gate Bipolar Transistor) yaygın olarak kullanılmaktadır [2]. Bununla birlikte IGBT'ler, evirici devre yapılarındaki arızaların %38'ini oluşturan en hassas bileşenlerdir [3]. Güç anahtarları arızaları kısa devre ve açık devre arızaları olmak üzere iki sınıfta incelenmektedir. Aşırı ısınma, aşırı gerilim veya yanlış tetikleme sinyallerinden kaynaklanan kısa devre arızaları sistem üzerinde ciddi hasarlara sebep olmaktadır. Açık devre arızaları ise sistem çıkışındaki performansı düşüren, diğer devre bileşenlerinde ikincil arızalara sebep olan yumuşak arızalardır. Bu nedenle açık devre arızalarının tespiti ve sınıflandırılması son zamanlarda en çok araştırılan konularından biri olmuştur [3-6]. Arızaları kısa sürede tanımlamak ve doğru sınıflandırmak sistem sağlamlığı ve güvenirliliği açısından önemli görülmektedir.

Güç anahtarlarının açık devre durumunda sistem performansını iyileştirmek için birçok yöntem geliştirilmiştir [3,7]. Açık devre arızaları; kapı sürücüsü arızaları, açık anahtar arızaları, açık diyot arızaları ve açık faz bacağı arızaları olarak sınıflandırılabilir [8,9]. Kapı sürücüsü arızası güç anahtarına gönderilen tetikleme sinyalinin kesilmesiyle IGBT anahtarında açık devre arızasına sebep olmaktadır. IGBT anahtarlarına bağlı anti-paralel diyotların devreyle bağlantısının kesilmesi ise açık diyot arızalarını meydana getirmektedir. IGBT anahtarlarının açılması ve böylece içerisinden akan akımın herhangi bir sebeple kesilmesi ile doğrudan açık devre arızaları meydana gelmektedir [8-11].

* Sorumlu yazar: serenay.celik@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-4774-2381, ² 0000-0002-7435-0906

Eviricilerde arıza tespit yöntemleri: model tabanlı yöntemler, sinyal tabanlı yöntemler ve veriye dayalı yöntemler olmak üzere üç kategoride incelenmektedir [12]. Model tabanlı yöntemler, sensör bilgileri veya ölçüm donanım bileşenleri gerektirmeksizin matematiksel model ve analitik bilgiye dayanmaktadır [2,13]. Gözlemciye dayalı yöntemler [14,15], eşlik denklemlerine dayalı yöntemler [16,17] ve parametre tahmin denklemlerine dayalı yöntemler [18-20] yaygın olarak kullanılan model tabanlı yöntemlerdir. Model tabanlı yöntemlerde matematiksel modelden hesaplanan değerler ile elde edilen veriler arasında oluşan farkların izlenmesiyle arızalar tespit edilebilmektedir. Ancak model belirsizlikleri veya parametrelere duyarlılığına bağlı olarak sistem performansının etkilenmesi ve çoklu anahtar arıza tespitlerindeki eksiklik bu yöntemin en önemli dezavantajını oluşturmaktadır [2,4,21].

Sinyal tabanlı yöntemler, arıza tespiti için akım ve gerilim sinyallerini veya her iki sinyalin birleşimini kullanırlar. Gerilim tabanlı yöntemlerde sinyal bilgilerini almak için ek sensörlere ihtiyaç duyulmaktadır. Bu durum yöntemin karmaşıklığını ve maliyeti artırmaktadır [22,23]. Akım tabanlı yöntemler daha yaygın olarak kullanılmaktadır. Bunun sebebi evirici parametrelerine bağlı olmamasıdır [24-29]. Sinyal işleme tekniklerinin hesaplama yükü fazlalıkları ve uzun tespit sürelerinin bulunması sinyal tabanlı yaklaşımların eksiklikleri olarak görülmektedir [2,4,5,21,30].

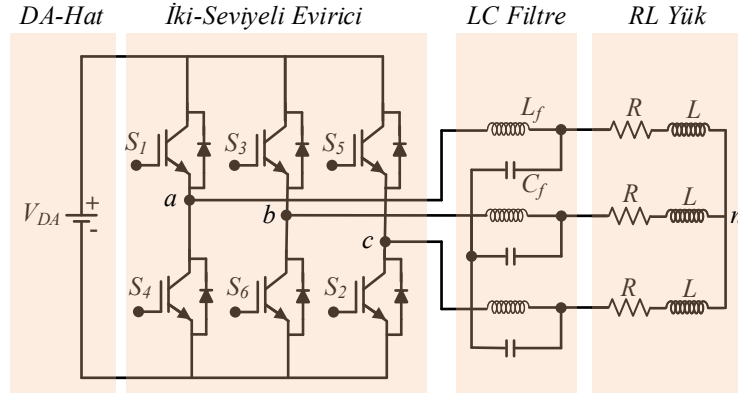
Veri tabanlı yöntemlerde mevcut verilerden arıza özellikleri elde edilerek arıza etiketleri ile eşleştirilmektedir [31-36]. Model tabanlı ve sinyal tabanlı yöntemlerden farklı olarak veri tabanlı yöntemler modelden ve yük durumundan bağımsız olduğundan değişken sistem durumları için daha esnek, karmaşık arıza durumları için ise daha sağlam performans göstermektedirler. Veriye dayalı yöntemler arasında uzman sistemler, bulanık mantık, karar ağaçları, yapay sinir ağları, destek vektör makineleri vb. yapay zekâ yaklaşımları bulunmaktadır [2,5,21]. Algoritmaların eğitiminin ve doğrulanmasının sağlanması için büyük veri kümelerinin gerekliliği bu yöntemin temel problemi [4].

Eviricilerdeki arıza durumlarının tespitine yönelik literatürde yapılan çalışmalar incelendiğinde, kapı sürme arızaları üzerinde açık anahtar arızalarından daha çok çalışıldığı görülmektedir. Evirici anahtarlarındaki arızaları tanımlamak ve sınıflandırmak tüm sistemin güvenliği ve olası risklerin azaltılması açısından önemli bir konu olarak görülmektedir. Bu çalışmada; üç-fazlı iki-seviyeli eviricinin açık anahtar arıza durumları incelenmiş, arıza teşhis ve sınıflandırılması için SVM, KNN gibi makine öğrenmesi algoritmaları, ANN ve LSTM gibi derin öğrenme modelleri kullanılmıştır. Veri kümesini elde etmek için evirici üzerinde oluşturulan açık anahtar arıza durumuna ilişkin faz akımlarının ortalama ve rms değerleri ölçülmüştür. Mevcut yöntemlerden farklı olarak veri kümesine ortalama ve rms akımları ile birlikte ortalama/rms değerlerinin oranları eklenmiştir. Bu teknik sayesinde ortalama akımdan kaynaklı yük bağımlılığı problemi giderilmiştir [4]. Böylelikle tekli ve çoklu anahtar arızalarını tanımlayan ve sınıflandıran yöntemler elde edilmiş, sonuçları değerlendirilmiş ve önerilen yöntemlerin performansları karşılaştırılmıştır.

Bölüm II'de iki-seviyeli evirici modeli ele alınmış ve arıza davranışları incelenmiştir. Benzetim modeli ile makine öğrenmesi ve derin öğrenme esaslı arıza tespit ve sınıflandırma teknikleri Bölüm III'de sunulmuştur. Benzetim sonuçları ve performans değerlendirilmeleri Bölüm IV'de tartışılmıştır.

2. İki-Seviyeli Evirici Modeli ve Arıza Davranışları

Üç-fazlı iki-seviyeli gerilim kaynaklı eviriciler; kesintisiz güç kaynakları, değişken-hızlı AA motor sürücüler, şebekeye bağlı fotovoltaik sistemler ve diğer yenilenebilir enerji üretimleri ile endüstriyel otomasyon gibi uygulamalarda yaygın olarak kullanılan güç elektroniği devreleridir [36-38]. Bu çalışmada, Şekil 1'de gösterilen IGBT anahtarlarından oluşan ve anahtarların denetimi için sinüzoidal darbe genişlik modülasyonu (SPWM) tekniğini kullanılan üç-fazlı iki-seviyeli eviricinin açık anahtar arıza durumları incelenmiştir. Sistemin parametreleri Tablo 1'de verilmiştir. Yapılan çalışmada yük olarak dengeli yıldız bağlı iki farklı yük kullanılmıştır.




Şekil 1. Üç-fazlı iki-seviyeli evirici.


Tablo 1. Devre parametreleri.

Parametre	Değeri
Doğru Akım Kaynağı	100V
Temel Frekans	50Hz
Taşıyıcı Frekans	10kHz
Yük-1	10Ω, 10mH
Yük-2	40Ω, 20mH
Modülasyon İndeksi	0,8
LC Filtre	L=10mH, C=25μF


Eviricilerde normal koşullar altında dengeli üç-faz sinüzoidal çıkış akımları elde edilmektedir (Şekil 2). Sistemdeki bir veya daha fazla IGBT anahtarlarında açık devre arızası meydana geldiğinde bu akım dalga formları sinüzoidal formdan uzaklaşır ve aralarındaki denge durumu ortadan kalkar. Üst kollarında oluşan bir açık anahtar devre arızasında, arızalı anahtardan akım akmayacaktır, bununla birlikte kolun alt anahtarında ise akım akmaya devam edecektir. Örneğin S_1 anahtarı için $t=0,04\text{sn}$ 'de açık devre arızası olduğunda; S_1 'den akım akmazken S_4 anahtarı üzerinden akım akmaya devam etmektedir. Böylece a-fazındaki akım negatif olduğundan b ile c-fazlarındaki akımlara pozitif bileşenler eklenir ve Şekil 3'te gösterildiği gibi üç-fazlı akım dalga formu bozulur. Benzer şekilde, alt kollarında oluşan bir açık anahtar devre arızasında (örneğin S_4), S_4 'den akım akmazken S_1 anahtarı üzerinden akım akmaya devam eder. Böylelikle durum tersine dönüşmüş olur ve a-fazındaki akım pozitif olduğundan b ile c-fazlarındaki akımlara negatif bileşenler eklenecek ve Şekil 4'te gösterildiği gibi üç-fazlı akım dalga formları oluşacaktır.



Şekil 2. Normal koşullar altında (arızasız durum) faz akımları




Şekil 3. S₁ anahtarının açık devre olduğu durumda faz akımları.




Şekil 4. S₄ anahtarının açık devre olduğu durumda faz akımları.


Üst kollardaki iki anahtar da açık devre arıza durumları oluştuğunda (örneğin S₃ ve S₅) her iki anahtardan da akım akmayacaktır, b ile c-fazlarındaki akımların ortalama değerleri Şekil 5'te gösterildiği gibi negatif bileşenlere sahip olacaktır. Arızalı anahtarlar alt kollarda ise (örneğin S₆ ve S₂) durum tersine döner, anahtarların bulunduğu b ile c-fazlarındaki akımların ortalama değeri Şekil 6'da gösterildiği gibi pozitif olmaktadır. Ayrıca, Şekil 7'de gösterildiği gibi arızalı anahtarların biri alt diğeri üst kolda ise (örneğin S₁ ve S₂) bu anahtarlardan akım akmayacak ve a ile c-fazlarında pozitif ve negatif akımlar oluşacaktır.



Şekil 5. S₃-S₅ anahtarlarının açık devre olduğu durumda faz akımları.




Şekil 6. S₆-S₂ anahtarlarının açık devre olduğu durumda faz akımları.



Şekil 7. S₁-S₂ anahtarlarının açık devre olduğu durumda faz akımları.

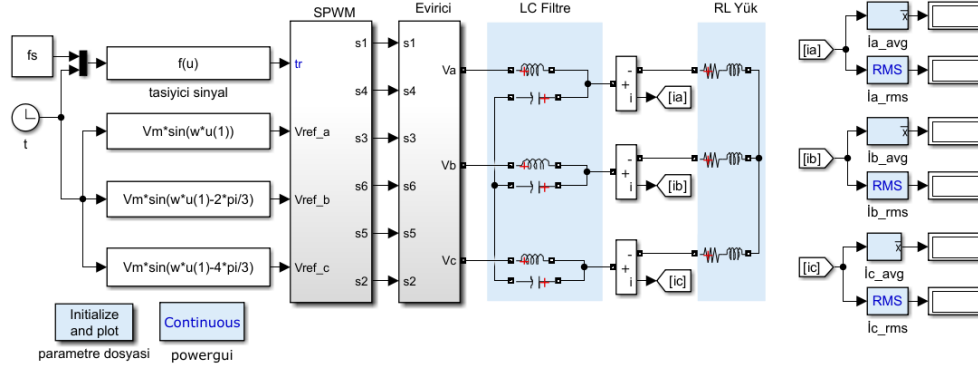
Evirici devresindeki üç adet anahtarda açık devre arızası olduğunda üç-fazlı akım dalga formları arızanın bulunduğu kola göre pozitif veya negatif yarı döngülere sahip olmaktadır. Örneğin S₁, S₂ ve S₃ anahtarlarında oluşan açık devre arızası durumunda, a ile b-faz akımı negatif, c-faz akımı ise pozitif değerlerde olacağı Şekil 8’de görülmektedir.




Şekil 8. S₁-S₂-S₃ anahtarlarının açık olduğu durumda faz akımları.

3. Benzetim Modeli ve Sınıflandırma Teknikleri

Bu çalışmada incelenen üç-fazlı iki-seviyeli eviricilerdeki IGBT anahtarları için açık devre arızalarının tanımlanması ve sınıflandırılması, faz akımlarının ortalama ve rms akım değerlerine göre gerçekleştirilmiştir. Arıza bilgilerini çıkarmak için gerekli rms ve ortalama akım değerleri sağlıklı ve arızalı durumlar için MATLAB/Simulink benzetim ortamında elde edilmiştir (Şekil 9). Bir periyot süresince her bir faz için ortalama ve rms akımlar Denklem 1 ve 2 kullanılarak hesaplanmıştır.



(a) SPWM tekniği ile denetlenen evirici sistemi



(b) Evirici devresindeki S₁ ve S₆ anahtarları için arıza durumu oluşturma

Şekil 9. MATLAB/Simulink benzetim ortamı.

$$i_{rms} = \sqrt{\frac{1}{T} \int_0^T i^2(t) dt} \quad (1)$$


$$i_{ort} = \frac{1}{T} \int_0^T i(t) dt \quad (2)$$

Faz akımlarının her bir arızalı durum için elde edilen rms değerleri ile arızasız durumdaki rms değerleri karşılaştırılarak arızanın bulunduğu kol tespit edilebilmektedir. Ancak belirlenen kol üzerindeki hangi anahtar arızanın olduğu rms değerleri kullanılarak belirlenememektedir. Bu soruna çözüm olarak arızalı faz akımının ortalama değeri kullanılarak kol üzerindeki arızalı anahtarın tespiti sağlanabilmektedir. Ortalama ve rms değerlerinin ayrı ayrı etkinliği bulunmasına rağmen tek başına yeterli değildir [4,39]. Araştırmacılar yük bağımlılığı problemini çözmek için ortalama akımın normalleştirildiği vektör yaklaşımını önermektedirler [24,27,40]. Bu normalleştirme tekniğinin sadece tekli ve ikili anahtar arızalarını tanımlayabilmesi ve düşük akım değerlerinde etkili olmaması gibi dezavantajları vardır. Bu çalışmada, literatür [12]'de detaylandırılan ortalama akım değerinin rms akıma oranını kullanan normalleştirme yöntemi ile yük bağımlılığı, üçlü arızalı anahtar

tanımlaması ve düşük akım değerlerindeki sınırlamalar giderilmiştir. Anahtarlarda arıza olmadığında veya bir başka deyişle sağlıklı durumda ortalama akım değeri sıfırdır. Tablo 2’de sağlıklı durum ve farklı açık anahtar devre arızalarında, iki farklı yük durumu için faz akımlarının ortalama ve rms değerleri değişirken, ortalama/rms oranının sabit kaldığı gösterilmiştir. Mevcut çalışmalardan farklı olarak bu çalışmada rms ve ortalama akım değerleri yanın da ortalama/rms oranının da arıza tanımlamaları için birer ayrı değişken olarak kullanılmıştır. Şekil 10’da ise arızalı fazın ve anahtarının tespit edilmesinde izlenen adımlar gösterilmiştir.

Tablo 2. Farklı yük durumları için faz akımlarının ortalama, rms değerleri ile ortalama/rms oranları.

Arıza Türü	Yük-1			Yük-2		
	ort. akım	rms akım	ort./rms oranı	ort. akım	rms akım	ort./rms oranı
Arızasız durum	a fazı	-0,000681	2,438	-0,000279	0,703	-0,000367
	b fazı	0,002431	2,438	0,000997	0,703	0,001037
	c fazı	-0,001750	2,437	-0,000718	0,7025	-0,000671
S ₁	a fazı	-0,107	0,228	-0,471	0,168	-0,472
	b fazı	0,056	2,153	0,026	0,610	0,066
	c fazı	0,052	2,075	0,025	0,619	0,063
S ₁ -S ₂	a fazı	-0,106	0,243	-0,434	0,166	-0,461
	b fazı	0,021	0,340	0,062	0,231	0,031
	c fazı	0,084	0,211	0,401	0,160	0,433
S ₁ -S ₂ -S ₃	a fazı	-0,043	0,119	-0,365	0,098	-0,370
	b fazı	-0,044	0,119	-0,366	0,098	-0,367
	c fazı	0,087	0,142	0,612	0,119	0,611




Şekil 10. Arıza tespiti için akış şeması.

Arızalı anahtarın tespit edilmesi ve konumlandırılması amaçlanan bu çalışmada dört farklı sınıflandırma algoritması kullanılmıştır. Sınıflandırıcıların başarıları değerlendirilirken doğruluk ve verimlilik göz önünde

bulundurulmaktadır. Sınıflandırıcının doğruluğunu veri kümesinin parametreleri ve verilerin dengeli dağılımı belirlemektedir. Aşırı uyumdan korunmak ve başarılı bir sınıflandırma için veri setine çapraz doğrulanma uygulanmıştır. Çapraz doğrulama tekniği ile veri seti eğitim ve test verilerine bölünerek, model eğitilmediği veriler üzerinde test edilmiştir. Böylelikle modelin performansının daha sağlıklı değerlendirilmesi sağlanmıştır.

3.1. Destek vektör makineleri (SVM)


Destek vektör makineleri, Vapnik ve ekibi tarafından geliştirilen sınıflandırma ve regresyon problemlerinde kullanılan denetimli bir makine öğrenmesi algoritmasıdır [41]. Bu algoritmanın temel amacı, veri noktalarını çok boyutlu uzaya yansıtarak optimal bir hiperdüzlem bularak sınıflandırmaktır. Şekil 11’de gösterildiği üzere SVM, veri sınıfları arasında maksimum mesafeye sahip hiperdüzlemi belirlemeye dayanmaktadır. Karar düzlemi olarak da adlandırılan hiperdüzlem, bir sınıftaki verileri diğer sınıflardaki verilerden ayıran düzlemdir. Hem doğrusal hem de doğrusal olmayan veri kümelerini sınıflandırabilen matematiksel öğrenme şemasıdır [42]. Küçük ve orta boyutlu veri kümeleri için basit ve başarılı bir sınıflandırma tekniğidir.



Şekil 11. SVM modeli [43].

3.2. K-en yakın komşular (KNN)


K-en yakın komşular, eğitim veri sınıflarının yakınlıklarını analiz ederek minimum mesafelere göre k değeri (benzerliği) ile gruplandırılan parametrik olmayan bir sınıflandırma modelidir [44]. Sınıflandırma algoritması tasarlanırken yalnızca bir mesafe fonksiyonu ve sınıflandırma kuralı oluşturulması gereklidir [45]. Model eğitimi ve test verisi tahmini olmak üzere iki aşamadan oluşmaktadır. Eğitim aşamasında, genellikle çapraz uygulama kullanılarak en uygun k değerini bulmaya çalışılır. Tahmin aşamasında, k komşu arasında en sık bulunan test verisi sınıfına dayanarak tahminde bulunulur [46]. Şekil 12’de KNN modeli gösterilmiştir. KNN sınıflandırıcının, bir test örneğinin sınıfını tahmin ederken k komşu parametresini bulmak için tüm eğitim veri kümesini hafızada tutması gerekmektedir [47].



Şekil 12. KNN modeli [48].

3.3. Yapay sinir ağı (ANN)

Yapay sinir ağları kendi kendine öğrenme, bilgiler arasında ilişki kurma, analiz etme ve karar verme gibi işlevleri gerçekleştiren nöronlardan oluşan derin öğrenme algoritmalarıdır [49]. Herhangi bir ön bilgi olmadan girişler ile çıkışlar arasındaki doğrusal olmayan karmaşık ilişkileri tanımlayabilen, eksik bilgilerle de tahminde bulunabilen modellerdir [50]. Temel olarak bir dizi giriş katmanı, gizli katman ve çıkış katmanından oluşan yapay sinir ağı modeli Şekil 13'te gösterilmiştir.




Şekil 13. ANN modeli [51].

Her katman bir önceki katmana bağlıdır ve önceki katmandan aldığı bilgileri alarak analiz etmektedir [52]. Gizli katman sayısı ve katmandaki nöron sayısı probleme göre belirlenmektedir. Tek bir gizli katmana sahip olanlar sığ ANN, birden fazla gizli katmana sahip olanlar ise derin öğrenme ANN'leri olarak adlandırılır. Daha fazla nöron ve katman eklenerek, ANN'lerin öğrenme yetenekleri genişletilebilmektedir [53]. Topolojisi iyi ayarlanan bir sinir ağı karmaşık ve yüksek boyutlu veri kümeleri için başarılı bir sınıflandırma sağlayabilmektedir.

3.4. Uzun kısa süreli bellek (LSTM)

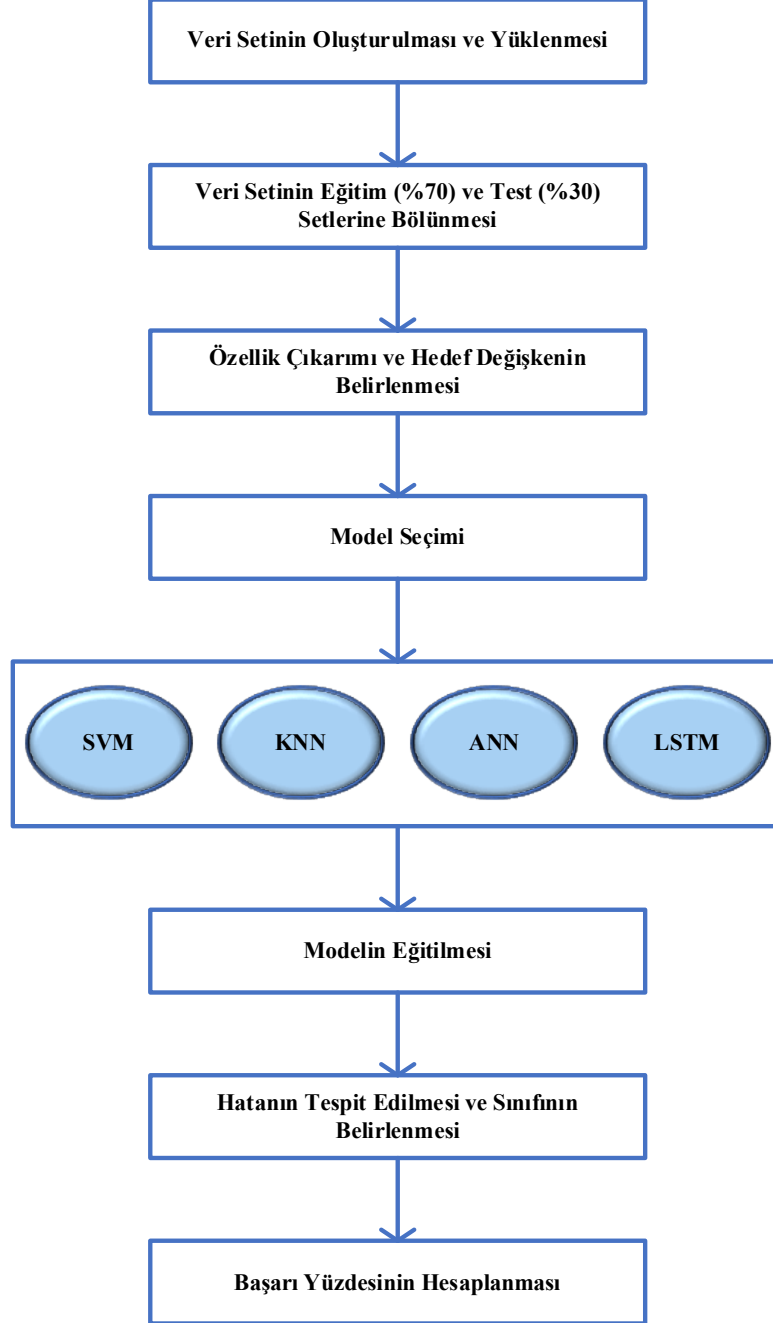
LSTM sınıflandırıcısı uzun süre bilgileri tutma ve kısa zamanlı girdileri atlama sorunlarını çözmeye çalışan geliştirilmiş yinelemeli sinir ağı (RNN-Recurrent Neural Network) mimarisidir [54-55]. LSTM ağı, diğer ağ birimlerinin yerine veya bunlarla birlikte ana yapı taşları olarak LSTM birimlerini kullanmaktadır. LSTM ağlarının en önemli özelliği, herhangi bir aktivasyon işlevi içermeyen tekrarlayan bileşenleri kullanmasıdır [56]. Şekil 14'te gösterildiği üzere LSTM modeli; önemsiz bilgileri tutmayan, önemli olanları bir sonraki katmana aktarmayı sağlayan giriş, unutmaya ve çıkış olmak üzere üç kapıdan, gizli durumu ve bellek hücrelerini içeren gizli katmandan oluşmaktadır.



Şekil 14. LSTM modeli [57]

Çalışmada kullanılan tüm sınıflandırma algoritmaları için aynı arıza etiketleri kullanılmıştır (Tablo 3). Her bir arıza türü için faz akımlarının rms, ortalama ve ortalama/rms oranları kaydedilmiştir. Böylelikle her bir faz için

üç ayrı özellik kullanılmıştır. Her bir etiket için 100 periyotluk değerler alınarak sınıflandırıcı modelleri için veri kümesi oluşturulmuştur. Çapraz doğrulama uygulanmış, [44,58] referanslar doğrultusunda veri kümesinin %70'i eğitim, %30'u ise test için ayrılmıştır. Toplam 2500 periyot için elde edilen veri setinin 1750'si modelleri eğitmek ve 750'si test etmek için kullanılmıştır. Denetimli eğitim veri seti kullanılarak SVM ve KNN makine öğrenmesi modelleri ile ANN ve LSTM derin öğrenme sınıflandırıcıları eğitilerek analizler yapılmıştır. Şekil 15'te seçilen modellerin eğitim adımları gösterilmiştir.

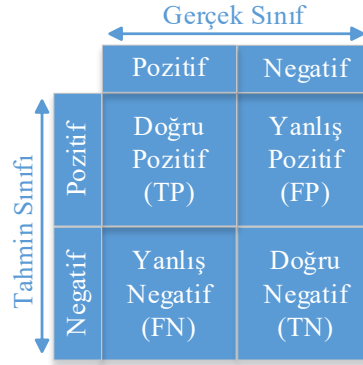


Şekil 15. Sınıflandırıcı modellerinin akış şeması.

Sınıflandırıcıların performanslarını karşılaştırmak için doğruluk metriği ve karışıklık matrisi kullanılmıştır. Doğruluk, doğru sınıflandırılmış verilerin tüm verilere oranını ifade etmektedir. Karışıklık matrisi Şekil 16'da gösterildiği gibi tahmin edilen ve gerçek değerlerden oluşturulan 4 farklı kombinasyondan oluşan bir tablodur.

Tablo 3. Arıza türlerinin etiketleri.


Arıza türü	Arıza etiketi	Arıza türü	Arıza etiketi
Arızasız durum	0	S ₃ -S ₂	13
S ₁	1	S ₅ -S ₄	14
S ₃	2	S ₅ -S ₆	15
S ₅	3	S ₄ -S ₆	16
S ₄	4	S ₄ -S ₂	17
S ₆	5	S ₂ -S ₆	18
S ₂	6	S ₁ -S ₂ -S ₃	19
S ₁ -S ₃	7	S ₁ -S ₆ -S ₅	20
S ₁ -S ₅	8	S ₁ -S ₆ -S ₂	21
S ₁ -S ₆	9	S ₃ -S ₄ -S ₂	22
S ₁ -S ₂	10	S ₅ -S ₄ -S ₆	23
S ₃ -S ₅	11	S ₄ -S ₃ -S ₅	24
S ₃ -S ₄	12		

**Şekil 16.** Karışıklık matrisi.

Doğru Pozitif (TP-True Positive) gerçekte doğru olan veriyi doğru tahmin etmeyi, Doğru Negatif (TN-True Negative) gerçekte doğru olmayan veriyi doğru tahmin etmemeyi, Yanlış Pozitif (FP-False Positive) gerçekte doğru olmayan veriyi doğru tahmin etmeyi, Yanlış Negatif (FN-False Negative) ise gerçekte doğru olan veriyi doğru tahmin etmemeyi ifade etmektedir [59]. Sınıflandırıcıların başarıları Doğru Pozitif Oranı (TPR-True Positive Rate) ve Yanlış Negatif Oranı (FNR-False Negative Rate) kullanılarak değerlendirilmiştir. Karışıklık matrislerinde en yüksek FNR kırmızı renkle ile gösterilirken en yüksek TPR mavi renk ile gösterilmiştir. FNR'lerin varlığı TPR'nin en yüksek seviyeye ulaşmadığını ve yoğunluğunun azaldığını göstermektedir.


4. Sonuç

Bu çalışmada üç-fazlı iki-seviyeli eviricilerde açık anahtar devre arızalarının tespit ve tanısı incelenmiştir. Bunun için eviricideki tekli ve çoklu anahtar arızalarının sınıflandırılmasında dört farklı model kullanılıp sonuçları değerlendirilmiştir. Her bir model evirici faz akımlarının ortalama, rms değerleri ile birlikte ortalama/rms oranları kullanılarak eğitilmiştir. Modellerin başarı oranlarının karşılaştırıldığı matris grafiklerinde bulunan sayılar hata türlerinden rastgele kaç tane örnek kullanıldığını ifade etmektedir. Grafiklerde bulunan renkler ise hata örneklerinin doğru tahmin edilip edilmediğini belirtmektedir. Örneğin Şekil 17'de çok sınıflı SVM kullanılan modelin karışıklık matrisi gösterilmiştir. 0'a 0 sütununda bulunan 29 sayısı, "0" etiketi için seçilen rastgele 29 örneğin 29'unu doğru sınıflandırıldığını belirtmektedir. 24'e 13 sütununda bulunan açık kırmızı renkle gösterilen 1 sayısı ise, gerçek sınıfı "24" olan bir örneği "13" olarak sınıflandırıldığını ve yanlış olduğunu ifade etmektedir. Yanlış örneklerin sayısı arttıkça açık kırmızı olan renk koyulaşmaktadır ve başarı oranını düşürmektedir. Matriste görüldüğü üzere SVM modeli test setinden sadece 1 verinin sınıfını yanlış tahmin ederek (gerçek sınıf etiketi 24 iken sınıfını 13 olarak tahmin etmiştir) %99,87 başarı göstermiştir.



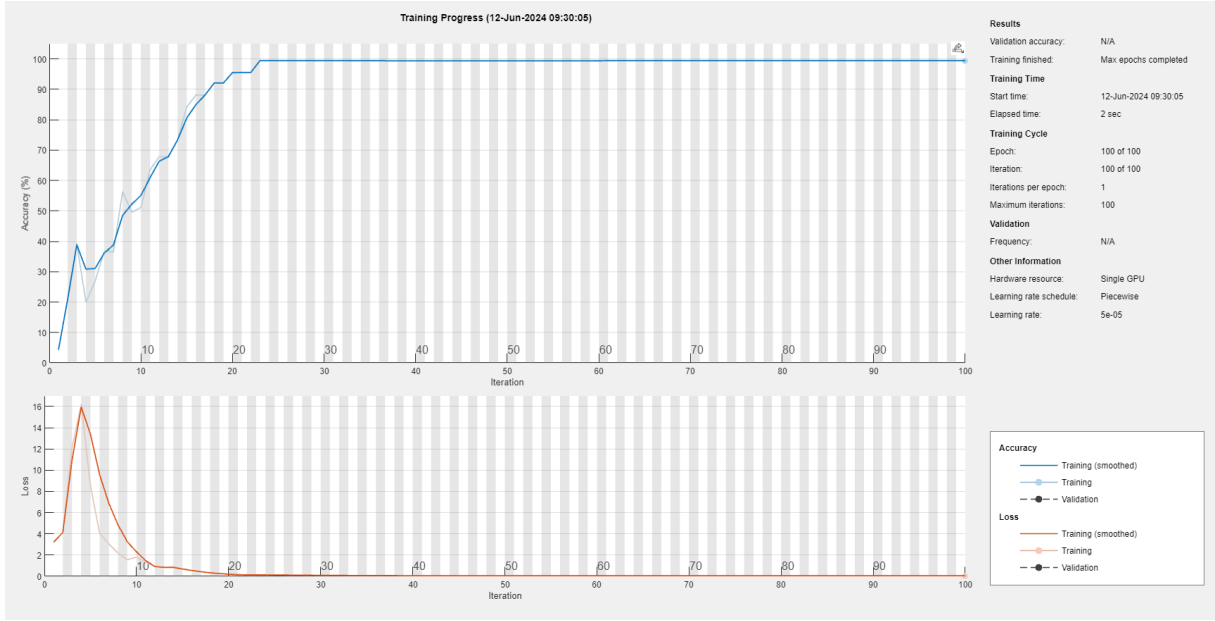
Şekil 17. SVM karışıklık matrisi.

Çok sınıflı KNN modeli kullanılan sınıflandırıcının karmaşıklık matrisi Şekil 18’de gösterilmiştir. Görüldüğü üzere eğitilen model tüm test verilerinde %100 başarı elde ederek tüm arızaları doğru sınıflandırmıştır.

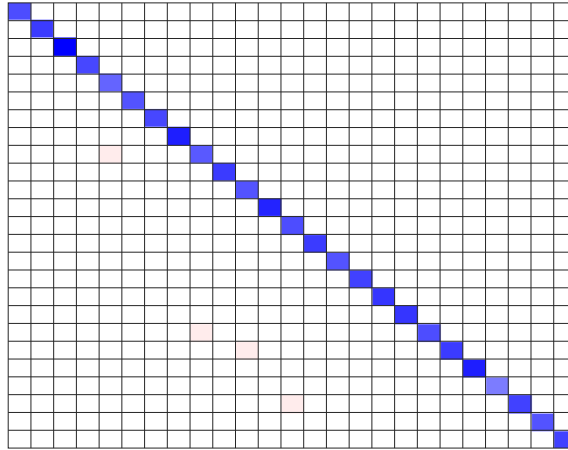


Şekil 18. KNN karışıklık matrisi.

Eğitim setinin ANN modeli ile eğitimi ve doğruluğu Şekil 19’da verilmiştir. Yaklaşık 750 test verisinin sadece 4 tanesinin etiketini yanlış tahmin ederek %99,47 başarı gösteren ANN modelinin karışıklık matrisi Şekil 20’de gösterilmiştir.



Şekil 19. ANN modelinin eğitimi.




Şekil 20. ANN karışıklık matrisi.


LSTM modeli kullanılan sınıflandırılmanın eğitim süreci ve doğruluğu Şekil 21’de verilmiştir. %99,87 başarı gösteren sınıflandırıcının karışıklık matrisi Şekil 22’de gösterilmiştir.

Kullanılan makine öğrenmesi ve derin öğrenme modelleri ile üç-fazlı iki-seviyeli gerilim eviricilerde oluşturulan açık anahtar arızaları başarılı bir şekilde tespit edilip, etiketlerine göre sınıflandırılmıştır. Mevcut çalışmalara kıyasla, tekli açık anahtar arıza tespitlerinin yanı sıra çoklu açık anahtar arızaları da tespit edilebilmiştir. Tablo 4’te kullanılan dört sınıflandırma modelinin eğitim süreleri ile başarı oranları karşılaştırılmıştır. Derin öğrenme ile eğitilen modellerde LSTM sınıflandırıcının başarı oranı ANN sınıflandırıcıya göre daha yüksek ancak eğitim süresi daha uzundur. ANN sınıflandırıcının eğitimi 2 saniye sürerken, LSTM sınıflandırıcının 17 saniye sürmektedir. Makine öğrenmesi tekniklerinde ise rastgele eğitim ve test setine bölünen veri seti kullanılarak modeller eğitilmiş, KNN sınıflandırıcı ile SVM sınıflandırıcısına göre hem daha yüksek başarı hem de daha kısa eğitim süresi elde edilmiştir. Her bir model ile arızalı anahtarın tespiti ve lokalizasyonu başarılı bir şekilde sağlanmıştır. İki-seviyeli eviriciler için yapılmış bu çalışmanın çok seviyeli eviriciler için de geliştirilmesi, çok seviyeli eviricilerde anahtar sayısının çokluğundan kaynaklanan arıza tespitinin zorluğunun iyileştirilmesi amaçlanmaktadır.

Gerilim Kaynaklı Eviricinin Faz Akımlarının İzlenmesiyle Açık Devre Arızalarının Teşhisi



Şekil 21. LSTM modelinin eğitimi.



Şekil 22. LSTM karışıklık matrisi.

Tablo 4. Sınıflandırma modellerinin performansları.

Sınıflandırma tekniği	Eğitim süresi (sn)	Başarı oranı (%)
SVM Sınıflandırıcı	1,42sn	%99,87
KNN Sınıflandırıcı	0,67sn	%100
ANN Sınıflandırıcı	2sn	%99,47
LSTM Sınıflandırıcı	17sn	%99,87

Kaynaklar

- [1] Kharjule S. Voltage source inverter. In: 2015 International Conference on Energy Systems and Applications; 2015; Pune, India. pp. 537-542.
- [2] Xia Y, Xu Y. A transferrable data-driven method for IGBT open-circuit fault diagnosis in three-phase inverters. *IEEE Trans Power Electron* 2021; 36(12): 13478-13488.
- [3] Hang C, Ying L, Shu N. Transistor open-circuit fault diagnosis in two-level three-phase inverter based on similarity measurement. *Microelectron Reliab* 2018; 91: 291-297.
- [4] Ibem CN, Farrag ME, Aboushady AA, Dabour SM. Multiple open switch fault diagnosis of three phase voltage source inverter using ensemble bagged tree machine learning technique. *IEEE Access* 2023; 11: 85865-85877.
- [5] Deng X, Wan C, Jiang L, Gao G, Huang Y. Open-switch fault diagnosis of three-phase PWM converter systems for magnet power supply on EAST. *IEEE Trans Power Electron* 2023; 38(1): 1064-1078.
- [6] Prejbeanu RG. A sensor-based system for fault detection and prediction for EV multi-level converters. *Sensors* 2023; 23(9): 4205.
- [7] Achintya P, Kumar Sahu L. Open circuit switch fault detection in multilevel inverter topology using machine learning techniques. In: 2020 IEEE 9th Power India International Conference (PIICON); 2020; Sonepat, India. pp. 1-6.
- [8] Dabour SM, Masoud MI. Open-circuit fault detection of five-phase voltage source inverters. In: 2015 IEEE 8th GCC Conference & Exhibition; 2015; Muscat, Oman. pp. 1-6.
- [9] Kumar MD, Kodad SF, Sarvesh B. Simplified fault detection algorithm for voltage source fed induction motor. *Mater Today Proc* 2018; 5(1): 1401-1410.
- [10] Ibem CN, Farrag ME, Aboushady AA. Open circuit fault diagnosis technique for inverter switches and gate drive malfunction. In: 2023 58th International Universities Power Engineering Conference (UPEC); 2023; Dublin, Ireland. pp. 1-6.
- [11] Zdiri MA, Bouzidi B, Abdallah HH. Improved diagnosis method for VSI fed IM drives under open IGBT faults. In: 2018 15th International Multi-Conference on Systems, Signals & Devices (SSD); 2018; Yasmine Hammamet, Tunisia. pp. 905-910.
- [12] Gao Z, Cecati C, Ding SX. A survey of fault diagnosis and fault-tolerant techniques-Part I: Fault diagnosis with model-based and signal-based approaches. *IEEE Trans Ind Electron* 2015; 62(6): 3757-3767.
- [13] Malik A, Haque A, Kurukuru VSB, Khan MA, Blaabjerg F. Overview of fault detection approaches for grid connected photovoltaic inverters. *e-Prime-Advances in Electrical Engineering, Electronics and Energy* 2022; 2:100035.
- [14] Zhuo S, Gaillard A, Xu L, Liu C, Paire D, Gao F. An observer-based switch open-circuit fault diagnosis of DC-DC converter for fuel cell application. *IEEE Trans Ind Appl* 2020; 56(3): 3159-3167.
- [15] Wassinger N, Penovi E, Retegui RG, Maestri S. Open-circuit fault identification method for interleaved converters based on time-domain analysis of the state observer residual. *IEEE Trans Power Electron* 2019; 34(4): 3740-3749.
- [16] Berriri H, Naouar MW, Slama-Belkhdja I. Easy and fast sensor fault detection and isolation algorithm for electrical drives. *IEEE Trans Power Electron* 2012; 27(2): 490-499.
- [17] Zhou D, Yang S, Tang Y. A voltage-based open-circuit fault detection and isolation approach for modular multilevel converters with model-predictive control. *IEEE Trans Power Electron* 2018; 33(11): 9866-9874.
- [18] Xie D, Ge X. A state estimator-based approach for open-circuit fault diagnosis in single-phase cascaded H-bridge rectifiers. *IEEE Trans Ind Appl* 2019; 55(2): pp. 1608-1618.
- [19] Poon J, Jain P, Konstantakopoulos IC, Spanos C, Panda SK, Sanders SR. Model-based fault detection and identification for switching power converters. *IEEE Trans Power Electron* 2017; 32(2): 1419-1430.
- [20] Poon J, Jain P, Spanos C, Panda SK, Sanders SR. Fault prognosis for power electronics systems using adaptive parameter identification. *IEEE Trans Ind Appl* 2017; 53(3): 2862-2870.
- [21] Yan H, Peng Y, Shang W, Kong D. Open-circuit fault diagnosis in voltage source inverter for motor drive by using deep neural network. *Eng Appl Artif Intell* 2023; 120: 105866.
- [22] Shahbazi M, Poure P, Saadate S, Zolghadri MR. FPGA-based fast detection with reduced sensor count for a fault-tolerant three-phase converter. *IEEE Trans Industr Inform* 2013; 9(3): 1343-1350.
- [23] Freire NMA, Estima JO, Cardoso AJM. A voltage-based approach without extra hardware for open-circuit fault diagnosis in closed-loop PWM AC regenerative drives. *IEEE Trans Ind Electron* 2014; 61(9): 4960-4970.
- [24] Mendes AMS, Cardoso AJM. Voltage source inverter fault diagnosis in variable speed AC drives, by the average current Park's vector approach. *IEEE International Electric Machines and Drives Conference*; 1999; Seattle, WA, USA. pp.704-706.
- [25] Im WS, Kim JS, Kim JM, Lee DC, Lee KB. Diagnosis methods for IGBT open switch fault applied to 3-phase AC/DC PWM converter. *Journal of Power Electronics* 2012; 12(1):120-127.
- [26] Im WS, Kim JM, Lee DC, Lee KB. Diagnosis and fault-tolerant control of three-phase AC-DC PWM converter systems. *IEEE Trans Ind Appl* 2013; 49(4): 1539-1547.
- [27] Freire NMA, Estima JO, Cardoso AJM. Open-circuit fault diagnosis in PMSG drives for wind turbine applications. *IEEE Trans Ind Electron* 2013; 60(9): 3957-3967.
- [28] Peugeot R, Courtine S, Rognon JP. Fault detection and isolation on a PWM inverter by knowledge-based model. *IEEE Trans Ind Appl* 1998; 34(6): 1318-1326.
- [29] Trabelsi M, Boussak M, Gossa M. Multiple IGBTs open circuit faults diagnosis in voltage source inverter fed induction motor using modified slope method. *The XIX International Conference on Electrical Machines - ICEM 2010*; 2010; Rome, Italy. pp. 1-6.

- [30] Shi T, He Y, Wang T, Tong J, Li B, Deng F. An improved open-switch fault diagnosis technique of a PWM voltage source rectifier based on current distortion. *IEEE Trans Power Electron* 2019; 3(12): 12212-12225.
- [31] Cai B, Zhao Y, Liu H, Xie M. A data-driven fault diagnosis methodology in three-phase inverters for PMSM drive systems. *IEEE Trans Power Electron* 2017; 32(7): 5590-5600.
- [32] Li Z, Gao Y, Zhang X, Wang B, Ma H. A model-data-hybrid-driven diagnosis method for open-switch faults in power converters. *IEEE Trans Power Electron* 2020; 36(5): 4965-4970.
- [33] Xia Y, Xu Y, Gou B. A data-driven method for IGBT open-circuit fault diagnosis based on hybrid ensemble learning and sliding-window classification. *IEEE Trans Industr Inform* 2020; 16(8): 5223-5233.
- [34] Moosavi SS, Djerdir A, Ait-Amirat Y, Khaburi DA, N'Diaye A. Artificial neural network-based fault diagnosis in the AC-DC converter of the power supply of series hybrid electric vehicle. *IET Electrical Systems in Transportation* 2016; 6(2): 96-106.
- [35] Gou B, Xu Y, Xia Y, Deng Q, Ge X. An online data-driven method for simultaneous diagnosis of IGBT and current sensor fault of three-phase PWM inverter in induction motor drives. *IEEE Trans on Power Electron* 2020; 35(12): 13281-13294.
- [36] Wang B, Cai J, Du X, Zhou L. Review of power semiconductor device reliability for power converters. *CPSS Transactions on Power Electronics and Applications* 2017; 2(2): 101-117.
- [37] Liang W, Wang J, Luk PCK, Fang W, Fei W. Analytical modeling of current harmonic components in PMSM drive with voltage-source inverter by SVPWM technique. *IEEE Transactions on Energy Conversion* 201; 29(3): 673-680.
- [38] Rocabert J, Luna A, Blaabjerg F, Rodríguez P. Control of power converters in AC microgrids. *IEEE Trans Power Electron* 2012; 27(11): 4734-4749.
- [39] Khelif AM, Bendiabdellah A, Cherif BDE. A combined RMS-mean value approach for an inverter open-circuit fault detection. *Periodica Polytechnica Electrical Engineering and Computer Science* 2019; 63(3): 169-177.
- [40] Caseiro JAA, Mendes AMS, Marques Cardoso AJ. Fault diagnosis on a PWM rectifier AC drive system with fault tolerance using the average current Park's vector approach. In: 2009 IEEE International Electric Machines and Drives Conference; 2009; Maimi, FL, USA. pp. 695-701.
- [41] Harman G. Destek vektör makineleri ve naive bayes sınıflandırma algoritmalarını kullanarak diabetes mellitus tahmini. *Avrupa Bilim ve Teknoloji Dergisi* 2021; 32: 7-13.
- [42] Chandra MA, Bedi SS. Survey on SVM and their application in image classification. *Int J Inf Technol* 2021; 13(59): 1-11.
- [43] Metlek S, Kayaalp K. Derin öğrenme ve destek vektör makineleri ile görüntüden cinsiyet tahmini. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi* 2020; 8(3): 2208-2228.
- [44] Gong W, Chen H, Zhang Z, Zhang M, Gao H. A data-driven-based fault diagnosis approach for electrical power DC-DC inverter by using modified convolutional neural network with global average pooling and 2-D feature image. *IEEE Access* 2020; 8: 73677-73697.
- [45] Zhang S, Li J. KNN classification with one-step computation. *IEEE Trans Knowl Data Eng* 2021; 35(3): 2711-2723.
- [46] Zhang S. Challenges in KNN classification. *IEEE Trans Knowl Data Eng* 2022; 34(10): 4663-4675.
- [47] Zhang S. Cost-sensitive KNN classification. *Neurocomputing* 2020; 391: 234-242.
- [48] Coşar M, Deniz E. Makine öğrenimi algoritmaları kullanarak kalp hastalıklarının tespit edilmesi. *Avrupa Bilim ve Teknoloji Dergisi* 2021; 28: 1112-1116.
- [49] Pham BT, Nguyen MD, Nguyen-Thoi T, Ho LS, Koopialipoor M, Quoc NK, Armaghani DJ, Van Le H. A novel approach for classification of soils based on laboratory tests using adaboost, tree and ANN modeling. *Transportation Geotechnics* 2021; 27: 100508.
- [50] Bhagya Raj GVS, Dash KK. Comprehensive study on applications of artificial neural network in food process modeling. *Crit Rev Food Sci Nutr* 2022; 62(10): 2756-2783.
- [51] Konakoğlu B. Çok katmanlı algılayıcı yapay sinir ağı ile jeodezik elipsoidal koordinatların (ϕ , λ , h) 3 boyutlu global kartezyen koordinatlara (x , y , z) dönüşümü. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi* 2020; 10(3): 702-710.
- [52] Kuşkan E, Çodur MK, Çodur MY. Türkiye'deki demiryolu enerji tüketiminin yapay sinir ağı ile tahmin edilmesi. *Konya Mühendislik Bilimleri Dergisi* 2022; 10(1): 72-84.
- [53] Guillod T, Papamanolis P, Kolar JW. Artificial neural network (ANN) based fast and accurate inductor modeling and design. *IEEE Open J Power Electron* 2020; 1: 284-299.
- [54] Rajendran GB, Kumarasamy UM, Zarro C, Divakarachari PB, Ullo SL. Land-use and land-cover classification using a human group-based particle swarm optimization algorithm with an LSTM classifier on hybrid pre-processing remote-sensing images. *Remote Sens* 2020; 12(24): 4135.
- [55] Kłosowski G, Rymarczyk T, Niderla K, Rzemieniak M, Dmowski A, Maj M. Comparison of machine learning methods for image reconstruction using the LSTM classifier in industrial electrical tomography. *Energies* 2021; 14(21): 7269.
- [56] Gür YE. Stock price forecasting using machine learning and deep learning algorithms: A case study for the aviation industry. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 2024; 36(1): 25-34.
- [57] Aslan E. LSTM-ESA hibrit modeli ile MR görüntülerinden beyin tümörünün sınıflandırılması. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi* 2024; 11(22): 63-81.
- [58] Bouchiba N, Kaddouri A. Application of machine learning algorithms for power systems fault detection. In: 2021 9th International Conference on Systems and Control (ICSC); 2021; Caen, France. pp. 127-132.
- [59] Sağıroğlu S, Arslan Tuncer S, Karahan B, Özercan İH. Evrimsel sinir ağı kullanarak ÇKA sınıflandırıcısı ile mide displazisinin tespiti. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi* 2024; 36(1): 291-300.