

MESAFE KORUMA İÇİN BİR ÖRÜNTÜ TANIMA UYGULAMASI

Sami EKİCİ, Selçuk YILDIRIM ve Mustafa POYRAZ*

Elektrik Eğitimi Bölümü, Teknik Eğitim Fakültesi, Fırat Üniversitesi, 23119, Elazığ

*Elektrik-Elektronik Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, 23119, Elazığ

sekici@firat.edu.tr, svildirim@firat.edu.tr, mpoyraz@firat.edu.tr

(Geliş/Received: 08.02.2008 ; Kabul/Accepted: 21.11.2008)

ÖZET

Bu makalede, mesafe koruma işlevi için örüntü sınıflandırıcısı olarak Destek Vektör Makineler (DVM) yöntemini kullanan bir yöntem sunulmuştur. Önerilen yöntem enerji iletim hattının farklı noktalarında meydana gelen arızaları algılayarak röle işlevi için bir çıkış üretilmektedir. Yöntem, üç faz akım ve gerilim bilgilerinden faydalanmaktadır. DVM'nin eğitiminde ve test edilmesinde kullanılan akım ve gerilim bilgileri Alternative Transient Program (ATP) ile gerçekleştirilen bir iletim hattı benzetiminden elde edilmiştir. Gerçekleştirilen dijital röle uygulamasında, DVM'nin oldukça yüksek bir başarı oranı ile iletim hattında meydana gelen arızaları sınıflandırdığı görülmüştür.

Anahtar Kelimeler: Örüntü tanıma, iletim hattı arızaları, destek vektör makineleri.

A PATTERN RECOGNITION APPLICATION FOR DISTANCE PROTECTION

ABSTRACT

In this paper, a method based on Support Vector Machines (SVM) as pattern classifier is presented for distance protection operation. The proposed method generates an output by determining faults occurred at different location of power transmission line for relay operation. The approach utilizes three-phase current and voltage information. The current and voltage information which are used in training and testing of SVM are obtained from a transmission line simulation which is performed by Alternative Transient Program (ATP). In the implemented digital relay application, it is shown that SVM classifies faults occurred on transmission line with very high performance level.

Keywords: Pattern recognition, transmission line faults, support vector machines.

1. GİRİŞ (INTRODUCTION)

İletim hatları, özellikle fiziksel boyutları dikkate alındığında arızalara en fazla maruz kalan güç sistemi elemanlarıdır. Elektrik güç sistemlerinde iyi bir tasarım, uygun işletme şartları ve cihazların bakımlarının düzenli olarak yapılması, oluşabilecek arıza olasılığını azaltmakla birlikte tamamen ortadan kaldırmaz. Bu durumda güç sistemi elemanlarını, oluşabilecek arızalara karşı mümkün olduğu kadar iyi korumak gerekir. Enerji iletim hatlarının yüzlerce kilometre uzunluklarda olması, iklim şartları ve coğrafik etkenler arıza yerinin bulunmasını ve onarımını geciktirir. Arızanın hızlı bir biçimde tespit edilip yerinin belirlenmesi, zaman kazancı ve onarım

kolaylığı sağlamakla birlikte, ekonomik açıdan da büyük faydalar sağlar. Hızlı ve doğru bir arıza tahmini, yüksek akımların ve ısınmanın sebep olacağı mekanik etkileri gidererek cihazların ömrünün uzamasını sağlar. Ayrıca, enerjisiz kalan sanayi kuruluşlarının uğradığı zararlar da azaltılmış olunur.

Sayısal teknolojiye paralel olarak, bilim adamları mikroişlemci tabanlı röleler üzerinde çalışmaya başlamışlardır. Analog verilerin dijital ortama aktarılması ile birlikte arıza sinyalleri detaylı olarak analiz edilebilmiş ve yeni yöntemler geliştirilmeye başlanmıştır. Önerilen ilk dijital röle modelleri çoğunlukla hat empedansının hesaplanması ve yürüyen dalga yöntemlerine dayalıdır [1, 2]. Arıza

yerini hat empedansını hesaplayarak bulan yöntemler, arıza durumundaki reaktansı, hat başından ölçülen gerilim ve akım değerlerini kullanan diferansiyel denklemleri çözerek hesaplarlar [3, 4]. Bu yöntem oldukça basit ve kullanışlı olmasına rağmen, özellikle sistemde birden fazla generatör olması, sistem yapılandırmasının değişmesi gibi durumlarda yetersiz kalmaktadır [5].


Arıza yerini belirlemek için kullanılan diğer bir yöntem yürüyen dalga tekniğidir [6, 7]. Bu yöntemde, arıza anında meydana gelen yüksek frekanslı geçici durum sinyallerinin, hattın her iki ucuna doğru belli bir hızla hareket ettikleri öngörülür. Bu yüksek frekanslı sinyallerin ve yansımalarının, ölçüm noktalarına varış süreleri arasındaki zaman farkı ile sinyalin ilerleme hızının çarpımı arıza noktasının yerini verir. Yürüyen dalganın sönümlü olması ve giderek bozulması, dalganın varış süresinin ve hızının tam olarak belirlenememesine yol açar.

Son yıllarda, arıza tipi ve yerinin belirlenmesi için yapılan çalışmalarda yaygın olarak dalgacık dönüşümü (DD) yöntemi kullanılmaktadır [8]. Bu yöntem Fourier dönüşümünden farklı olarak, sinyali zaman-frekans bölgesinde inceler. DD'nin en önemli avantajı, bant aralığının daha iyi ayarlanabilmesidir. Yöntem, sinyalin yüksek frekanslı bileşenlerini küçük bir bant aralığıyla, düşük frekanslı bileşenlerini ise daha geniş bir bant aralığı ile analiz ederek, sinyale ait ayırt edici özelliklerin elde edilmesine olanak sağlar. DD, kısa devre arızaları gibi periyodik olmayan sinyaller için çok kullanışlı bir yöntemdir.

Arıza tipi ve yerinin belirlenmesi için birçok yöntem geliştirilmiştir. Ancak bu konu üzerinde yapılan çalışmalar, yeni yöntemlerin geliştirilmesiyle birlikte devam etmektedir. Son yıllarda arıza tahmini için, insan beyninin çalışmasından esinlenerek geliştirilen yapay zekâ tekniklerini kullanan akıllı sistemler üzerinde çalışılmaktadır [9, 10]. Yapay zekâ tekniklerinin en belirgin özellikleri, hızlı öğrenme, hata toleransı ve bir sisteme ait kısmi verilerle doğru bir çıkış üretebilmeleridir. Bu özellikleri ile yapay zekâ teknikleri, güç sistemleri gibi büyük ve dinamik sistemlerin modellenmesi ve kontrolü için çok uygun yöntemlerdir. Güç sistemlerinde meydana gelen kısa devre arızalarının incelenmesinde uzman sistemler, genetik algoritmalar, bulanık mantık, karar ağaçları, k -en yakın komşuluklar algoritması (k-EYK), çok katmanlı algılayıcı ağları (ÇKA), olasılıksal sınır ağları (OSA), radyal tabanlı fonksiyon ağları (RTF) ve Elman ağları gibi yapay zekâ teknikleri kullanılmıştır [1, 5, 11, 12]. Bu yöntemler, arıza analizinde ayrı ayrı ya da birleşik olarak kullanılmışlardır.

Bu çalışmanın amacı, güç sistemlerinde meydana gelen kısa devre ve toprak arızalarının hızlı ve doğru


bir biçimde sınıflandırılmasıdır. Çalışmada kullanılacak veriler, ATP bilgisayar programında yapılan arıza benzetimlerinden elde edilmiştir. Enerji iletim hattının farklı noktalarında, farklı zamanlarda ve oluş açılarında arıza sinyalleri elde edildikten sonra normalizasyon işlemi gerçekleştirilmiştir. Hat başından alınan akım ve gerilim sinyallerine ait ayırt edici özelliklerin çıkarılması için ayırık dalgacık dönüşümü (ADD) yöntemi kullanılmıştır. Sınıflandırıcı olarak da oldukça yeni bir yöntem olan ve özellikle sınıflandırma problemleri için etkili olan DVM yöntemi kullanılmıştır. Şekil 1'de önerilen yöntemin akış diyagramı görülmektedir.



Şekil 1. Arıza belirleme akış diyagramı (Fault determination flow diagram)

2. İLETİM HATTI BENZETİMİ (TRANSMISSION LINE SIMULATION)

Son yıllarda, bilgisayar teknolojisindeki gelişmelere paralel olarak sayısal analiz yöntemlerinde de hızlı gelişmeler olmuştur. ATP, Electro Magnetic Transient Program'ın (EMTP) ücretsiz ve eğitim amaçlı olan bir sürümüdür [13]. Kullanış kolaylığı ve benzetimdeki başarısı ATP'yi güç sistemleri analizinde dünyada en çok kullanılan program haline getirmiştir [14]. Şekil 2'de ATP ile benzetimi yapılan 380 kV'luk güç sistemi modeli gösterilmiştir. Benzetimi yapılan iletim hattı 360 km uzunluğunda olup üç fazlı dengeli bir yükü beslemektedir. Arıza



Şekil 2. İletim hattının ATP benzetimi (ATP simulation of Transmission line)

benzetimleri Şekil 2’de gösterilen anahtarlar ile gerçekleştirilmiştir. Toprak yolu üzerinde 11Ω ’luk bir direnç ve 250 mH ’lik bir endüktans bulunmaktadır. ATP benzetiminde kullanılan parametreler Tablo 1’de görülmektedir. Benzetim süresi $0,5$ saniye olup, örnekleme periyodu $20 \mu\text{s}$ ’dir.

Tablo 1. İletim hattı modeli için hat parametreleri (Line parameters for transmission line)

20 °C’ deki dc direnci	0.036 Ω/km
Hat endüktansı	0.805 mH/km
İletkenler arası kapasitans	2.78 nF/km
İletkenler ile toprak arasındaki kapasitans	5.556 nF/km
Toprak direnci	0.031 Ω/km
Toprak endüktansı	0.694 mH/km

İletim hatlarında meydana gelen kısa devre arızaları simetrik ve asimetrik olmak üzere iki ana grupta incelenebilir. Simetrik arızalar, üç fazın birbirleriyle veya toprakla temas etmesiyle oluşan üç fazlı arızalar (3F)’dir. Asimetrik arızalar ise tek faz toprak (TFT), iki faz (2F) ve iki faz toprak arızaları (2FT)’dir. ATP benzetiminden elde edilen üç faz akım ve gerilim sinyallerinin yarım periyodu arıza öncesi, yarım periyodu da arıza sonrası olmak üzere toplam bir periyotluk kısmı ele alınmıştır. Arıza anında, arıza yerine bağlı olarak sinyallerde bozulmalar meydana gelmektedir. Sinyal analizi ile elde edilecek verilerin sınıflandırıcıya giriş olarak uygulanması için her bir sinyal $[-1, 1]$ aralığında normalize edilmiştir. Bu işlemler 360 km ’lik iletim hattının 50 farklı noktasında farklı oluş açılarında meydana getirilen tüm akım ve gerilim sinyallerine uygulanmıştır. Bu ön işlemden sonra sinyallere ait ayırt edici özelliklerin elde edilebilmesi için ADD yöntemi kullanılmıştır.

3. ADD İLE ÖZELLİK ÇIKARMA (FEATURE EXTRACTION WITH DWT)

Sürekli Dalgacık Dönüşümü (SDD), Fourier dönüşümüne (FD) benzer bir yapıya sahiptir. SDD’yi FD’den ayıran fark, FD incelenen sinyalin farklı frekanslardaki sinüs ve kosinüs bileşenlerini toplarken, SDD sinyalin farklı ölçeklemelere (sıkıştırma ya da uzatma) sahip ötelenmiş dalgacıklardan oluştuğunu kabul eder [15]. SDD matematiksel olarak,

$$SDD(s, \tau) = \int f(t) \psi_{s, \tau}(t) dt \quad (1)$$

ile ifade edilir. Buradaki $\psi_{s, \tau}(t)$ ana dalgacık (AD) olarak adlandırılır [15, 16]. Ana dalgacığın alt indisi olarak gösterilen τ ifadesi ise öteleme parametresidir. Dolayısıyla SDD, s ve τ ’nin bir fonksiyonudur. AD formülasyonu,

$$\psi_{s, \tau}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t - \tau}{s}\right) \quad (2)$$

gibi yazılır. Ayırık dalgacıklar ise, sadece ayırık adımlarda ölçeklenir ve dönüştürülür [17]. Ayırık dönüşüm denk. (2)’yi aşağıdaki gibi ayrıklaştırarak sağlanır:


$$\psi_{j, k}(t) = \frac{1}{\sqrt{s_0^j}} \psi\left(\frac{t - k\tau_0 s_0^j}{s_0^j}\right) \quad (3)$$

Buradaki j ve k birer tamsayı, $s_0 > 0$ genleşme katsayısı ve τ_0 genleşme katsayısına bağlı öteleme faktörüdür [18]. Şekil 3 ve 4’te sırasıyla iletim hattında meydana gelen 2FT ve 3F arızalarına ait üç faz gerilim ve akım sinyalleri görülmektedir. Kısa devre arıza sinyallerinin ADD ile analizi yapılırken, yarım


periyodu arıza anından önce ve yarım periyodu da arıza anından sonra olmak üzere toplam bir periyotluk (1000 adet) sinyal verileri kullanılmıştır. Ayırışım için farklı dalgacık aileleri denenmiş ve en iyi sonuçlar Daubechies dalgacık ailesi (dB4) ile elde edilmiştir [19]. Şekil 5'te arızalı bir faza ait gerilim ve akım sinyalleri için 6 seviyeli ADD ayırışımından elde

edilen yaklaşık (A_i) ve detay (D_i) katsayıları görülmektedir. Şekildeki S orijinal sinyali göstermektedir.


Şekil 5 incelendiğinde, ilk 3 detay katsayısının (cD1, cD2, cD3) arıza durumuna ait ayırt edici özellikler taşıdığı görülmektedir. Bu yüzden diğer sinyaller için 3



Şekil 3. İki faz toprak arızası için gerilim ve akım sinyalleri (Voltage and current signals for two-phase to ground fault)



Şekil 4. Üç faz simetrik arızası için gerilim ve akım sinyalleri (Voltage and current signal for three-phase symmetrical fault)



Şekil 5. Arızalı bir faz sinyalinin ADD ile analizi, a) gerilim, b) akım (DWT analysis of a faulty phase signal, a) voltage, b) current)

seviyeli bir ayrışım yapmak yeterli görülmüştür. Arıza tiplerini belirlemek için sadece ADD analizi ile elde edilen detay katsayıları kullanılmıştır. ADD ayrışımından elde edilen yaklaşık katsayıları alçak frekans bileşenlerini içerdikleri için, arıza durumlarına ait ayırt edici geçici durum bilgilerini içermezler. Bu yüzden yaklaşık katsayıları, sınıflandırma ve tahmin uygulamalarında kullanılmamıştır. Yapılan 3 seviyeli ADD ayrışımı sonucu elde edilen yaklaşık katsayıları sınıflandırıcının eğitimi için oldukça fazladır. Veri sayısını indirmek için bir dalgacığın düzensizlik derecesini veren *Entropy* yöntemi kullanılmıştır [20]. ADD detay katsayılarına entropy yöntemi uygulandıktan sonra üç faz gerilimi için 9, üç faz akımı için 9 özellik olmak üzere bir arıza durumu için 18 özellik elde edilmiştir. Bu işlem iletim hattının 50 farklı noktasında meydana getirilen arızaların tüm sağlam ve arızalı fazlarına uygulanmış ve toplamda 200x18'lik bir özellik matrisi elde edilmiştir. Bu veri matrisinin bir kısmı sınıflandırıcının eğitiminde, geriye kalanlar ise sınıflandırıcının test edilmesinde kullanılmıştır.

4. DVM İLE SINIFLANDIRMA (CLASSIFICATION WITH SVM)

Birçok yapay sinir ağı (YSA) arasında geri yayımlı ağ olarak da bilinen çok katmanlı ileri beslemeli ağlar en çok tercih edilenlerdir. Bu tip ağ yapısının en büyük dezavantajı, GYA'nın hata uzayında en düşük hataya sahip noktayı bulmaya çalışan bir rasgele arama algoritması olmasıdır [21]. Eğitim süreci arama uzayının geniş olması durumunda minimum hatayı

yakalayamama riski ile birlikte çok uzun olabilir. ÇKA ağlarının diğer bir dezavantajı, kaç tane katman kullanılacağı ve bu katmanlardaki nöron sayısının bilinmemesidir. Kullanılacak gizli katman sayısı ve bu katmanlardaki nöron sayıları genellikle deneme yanılma yoluyla belirlenir ve bu işlem büyük zaman kaybına neden olur. Ayrıca ağ mimarisinin değiştirilmesi durumunda YSA'nın kendini bu yeni ağ yapısına adapte etmesi zordur. Bu durumda ağ mimarisi değiştirildiğinde, ağı yeni verilerle yeniden eğitilmesi gerekir ki bu da yine zaman kaybına neden olur. Güç sistemleri gibi yapısı sürekli değişebilen büyük ve karmaşık sistemlerde kullanılan ağ mimarisinin değişmesi olağan bir durumdur. Bu yüzden, kullanılacak YSA modelinin değişik ağ yapılandırmalarına kolay adapte olması gerekir.

Destek vektör makineleri (DVM), Vapnik tarafından geliştirilen ve istatistiksel öğrenme teorisine dayanan oldukça yeni bir yöntemdir [22]. İlk olarak optik karakter tanıma alanına uygulanan DVM, son otuz yılda Vapnik ve çalışma arkadaşları (Chervonenkis, Boser, Guyon, Cortes, Schölkopf) tarafından bugünkü haline getirilmiştir [23]. DVM yönteminde orijinal giriş uzayı, özellik uzayı olarak adlandırılan ve içerisinde sınıflandırıcının genelleme kabiliyetini arttırmak için en uygun aşırı düzlemlerin belirlendiği yüksek boyutlu bir iç çarpım uzayı üzerinde haritalandırılır. En uygun ayırıcı düzlemler, matematiğin bir dalı olan optimizasyon teorisi ve bununla ilişkili olan istatistiksel öğrenme teorisini kullanarak bulunur [22]. DVM yöntemi son yıllarda

birçok alanda kullanılmaya başlanmıştır. El yazını rakamların tanınması, resim ve nesne tanıma, ses tanımlama ve zaman serilerinin tahmin edilmesi DVM'nin kullanıldığı bazı alanlardır [24]. Bu uygulama alanlarının yanı sıra özellikle son yıllarda arıza tipi ve yerinin bulunması için de kullanılmışlardır [25, 26]. Aşağıda DVM yönteminin YSA'ya göre bazı üstün yönleri belirtilmiştir.

- ✓ DVM çok az giriş ile öğrenebilir [27]. YSA'da ise giriş boyutunun fazla olması öğrenmeyi olanaksız kılar ya da yavaşlatır. Çoğu DVM uygulamasında veri sayısını azaltmak için özellik çıkarma işlemine gerek duyulmaz [22].
- ✓ DVM' de YSA'da görülen yerel minimum noktaları bulunmaz [28].
- ✓ DVM yapısal hatalı sınıflandırma riski olarak adlandırılan hatayı en aza indirmeye çalıştığı için YSA'ya göre daha iyi bir genelleme özelliğine sahiptir [28].

DVM temelde ikili sınıflandırma için (Binary SVM) geliştirilen bir yöntem olmasına rağmen, arıza tipi belirlemede olduğu gibi çoğu uygulamada birden fazla sınıf mevcuttur. İki'den fazla farklı kümeyi sınıflandırmak için, birden fazla ikili DVM kullanan çok sınıflı DVM yöntemi (Multiclass SVM) geliştirilmiştir [23, 28].

4.1. Destek Vektör Makineler (DVM) (Support Vector Machines (SVM))

N adet gözlemden oluşan ve her biri bir veri çiftinden oluşan veri vektörü n -boyutlu uzayda $x_i \in R^n$ ve $i = 1, 2, \dots, N$ olmak üzere, veri vektörlerine karşılık gelen sınıf etiketi $y_i \in \{+1, -1\}$ olsun. Bu durumda $y_i = +1$ ise x_i I. sınıfa, $y_i = -1$ ise x_i II. sınıfa dahil edilir. Bu veri çiftleri eğitim setini oluşturmaktadır

[28]. Doğrusal olarak birbirlerinden ayrılabilen veriler için, bu verileri birbirinden ayıran bir $f(x)$ aşırı düzlemi tanımlanabilir. Bu aşırı düzlemi tanımlamak için, x_i pozitif sınıfa ait ise $f(x) \geq 0$ ve x_i negatif sınıfa ait ise $f(x) < 0$ şartı uygulanır [28],

$$f(x) = w^T \cdot x + b = \sum_{j=1}^n w_j \cdot x_j + b \quad (4)$$

$$y_i f(x_i) = y_i (w^T \cdot x_i + b) \geq 0 \quad i = 1, 2, \dots, N \quad (5)$$

Buradaki w n -boyutlu bir vektör, b ise eşik değeridir. Buna ilave olarak w ve x 'in $1/|w|$ uzaklığındaki aşırı düzleme en yakın nokta olma koşulu getirilirse denk.(5) aşağıdaki gibi yeniden düzenlenebilir;


$$y_i (w^T \cdot x + b) \geq 1, \quad i = 1, 2, \dots, N \quad (6)$$

Aşırı düzlem ile en yakın noktaya uzaklığı en fazla olan düzlem (maksimum aralıktaki), en uygun ayrıştırıcı aşırı düzlem olarak adlandırılır. DVM'nin genelleme kabiliyeti bu ayrıştırıcı düzlemi maksimize etmekle sağlanır [28]. Şekil 6'da en uygun aşırı düzlem görülmektedir. Buradaki m maksimum aralık, H ise en uygun ayrıştırıcı düzlemdir.

En uygun ayrıştırıcı düzlem, arttırıcı yapay değişken (ξ_i) ve düzenleme katsayısı (C) ile gürültü ilave edilerek,

$$\text{minimize } \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N \xi_i \quad (7)$$

$$y_i (w^T \cdot x_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N \text{ ve } \xi_i \geq 0 \quad (8)$$



Şekil 6. En uygun ayrıştırıcı düzlem (Optimal separating hyper plane)

elde edilir [22]. Bu problem aşağıdaki gibi Lagrange ikilik problemine dönüştürülebilir;

$$\text{maksimize } Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,k=1}^N \alpha_i \alpha_k y_i y_k x_i \cdot x_k \quad (9)$$

$$\sum_{i=1}^N y_i \alpha_i = 0, \quad \alpha_i \geq 0, \quad i = 1, 2, \dots, N \quad (10)$$

Buradaki $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_i)$ Lagrange çarpanlarıdır [22, 25, 28]. Her bir örnek α_i 'ye karşılık gelmektedir. Karush–Kuhn–Tucker teoremine göre denk.(7)'deki eşitlik, giriş-çıkış çifti (x_i, y_i) için sadece $\alpha_i \geq 0$ olmak koşuluyla devam ettirilir. Bu koşula uyan giriş verileri (x_i) destek vektör olarak adlandırılır [25]. Diğer tüm eğitim verileri $(\alpha_i = 0)$ en uygun aşırı düzlemi etkilemeksizin eğitim setinden çıkarılır. α 'nın ikili problem için en uygun çözümünün α^* olduğu varsayılırsa w ve b 'nin en uygun çözümleri,

$$w^* = \sum_{i=1}^N \alpha_i^* y_i x_i = \sum_{\text{destek vektörler}} \alpha_i^* y_i x_i \quad (11)$$

$$b^* = 1 - w^* x_i, \quad x_i \text{ ve } y_i = 1 \text{ için} \quad (12)$$

olur [22]. Sınıflandırıcı, eğitimden sonra herhangi bir bilinmeyen x örneğini aşağıdaki karar fonksiyonu ile;

$$f(x) = \text{sign} \left(\sum_{j=1}^N \alpha_j^* y_j x_j \cdot x + b^* \right) \quad (13)$$

$$x \in \begin{cases} I.\text{sum} \Rightarrow f(x) = +1 \\ II.\text{sum} \Rightarrow f(x) = -1 \end{cases} \quad (14)$$

elde edilir. DVM, doğrusal olmayan, çekirdek fonksiyon tabanlı bir sınıflandırıcıdır. DVM yöntemi, daha önce de belirtildiği gibi orijinal R^n uzayındaki verileri, özellik uzayı olarak adlandırılan ve verilerin doğrusal olarak sınıflandırılabilirdiği yeni bir uzaya taşır. Şekil 7'de orijinal uzayın, özellik uzayına dönüştürülmesi gösterilmiştir. Doğrusal olmayan bir vektör fonksiyonu $(\phi(x) = \phi_1(x), \dots, \phi_L(x))$ kullanarak n -boyutlu giriş vektörü x 'i L -boyutlu F özellik uzayına taşıyan ikili formdaki doğrusal karar fonksiyonu,

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i^* y_i \phi^T(x_i) \cdot \phi(x) + b^* \right) \quad (15)$$


yazılır. Denk.(8) ve (14)'deki optimizasyon problemleri iç çarpım kullanmaktadır. F özellik uzayında ise $\phi^T(x) \cdot \phi(z)$ iç çarpımıyla ilgilenilir. Bu iç çarpımlar, özellik uzayındaki veri sayısının çok fazla olması durumunda hesaplama işlemini zorlaştırır. Bu problemin çözümü için $\phi^T(x) \cdot \phi(z)$ iç çarpımının yerine, $K(x, z) = \phi^T(x) \cdot \phi(z)$ gibi bir çekirdek fonksiyonu kullanılır [28].

Bazı önemli çekirdek fonksiyonları Tablo 2'de verilmiştir [22]. Çekirdek fonksiyonunu kullanarak denk.(15)'deki karar fonksiyonu,

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i^* y_i K(x_i, x) + b^* \right) \quad (16)$$

Tablo 2. Yaygın olarak kullanılan çekirdek fonksiyonları (Commonly used kernel functions)

Polinomal	$K(x, z) = (x^T \cdot z + 1)^m$
Radyal tabanlı	$K(x, z) = \exp \left(-\frac{\ x - z\ ^2}{2\sigma^2} \right)$
Sigmoid	$K(x, z) = \tanh[b(x, z) - c]$



Şekil 7. Giriş uzayının özellik uzayına taşınması (Transforming of input space to feature space)

olarak yazılır. Doğrusal olmayan bir çekirdek fonksiyonu kullanılarak çözülen denk.(16) eşitliği sonucunda, x eğitim örneğinin hangi sınıfa ait olduğunu belirlemek için sınır şartları;

$$x \in \begin{cases} I.sum \Rightarrow f(x) = +1 \\ II.sum \Rightarrow f(x) = -1 \end{cases} \quad (17)$$

olarak yazılır.

Tablo (2)'deki m , polinomsal çekirdek fonksiyonunun derecesi, σ radyal tabanlı fonksiyonun genişliği ve C kullanıcı tarafından belirlenen bir sabittir.

4.2. Çok Sınıflı DVM Algoritması (Multi-Class SVM Algorithm)

DVM yöntemi ilk olarak ikili sınıflandırma için geliştirilmiştir. Uygulamalardaki sınıflandırma problemlerinin büyük çoğunluğu ikiden fazla sınıftan oluştuğu için, çok sınıflı bir DVM sınıflandırıcısına ihtiyaç duyulmaktadır. Çok sınıflı sınıflandırma, ikili sınıflandırıcıların birleştirilmesiyle elde edilebilir [22]. Sınıflandırılabilir k -sınıflı bir problem ikili sınıflandırıcılar kullanılarak çözülebilir. Çok sınıflı sınıflandırma için önerilen pek çok DVM ayrıştırma yöntemi vardır. Bunlardan en önemlileri, bire-karşı-diğer (BKD) ve bire-karşı-bir (BKB) yöntemleridir [27].

BKD yönteminde, eğitim verisini ikili DVM ile ayırabilen k adet sınıflandırıcı oluşturulur. Bu sınıflandırıcılardan her biri, bir sınıfa geriye kalan diğer sınıflardan ayırır [27]. Bu işleme, tüm sınıflandırıcılar kullanılabildiği kadar devam edilir ve tüm sınıflandırıcıların ikili sınıflandırma sonuçları birleştirilerek karar işlevi yerine getirilir.


BKB yönteminde ise, k -sınıflı bir sınıflandırma problemi için $M = k(k-1)/2$ adet sınıflandırıcı oluşturulur. Bu sınıflandırıcılar i . ve j . sınıflara ait veriler ile eğitilir. BKB yönteminde ikili sınıflandırma problemi,

$$\min_{w^{ij}, b^{ij}, \xi^{ij}} \frac{1}{2} (w^{ij})^T w^{ij} + C \sum_t \xi_n^{ij} (w^{ij})^T K(x, z) + b^{ij} \geq 1 - \xi_n^{ij}, \quad y_n = i \text{ ise}, \quad (18)$$

$$(w^{ij})^T K(x, z) + b^{ij} \leq 1 - \xi_n^{ij}, \quad y_n = j \text{ ise},$$

çözülerek elde edilir [22]. Buradaki $K(x, z)$ çekirdek fonksiyonu, (x_n, y_n) i . ya da j . eğitim örneği, b eşik değeri ve C ise düzenleme faktörüdür. Eğitim örneklerinin hangi sınıfa ait olduğunu belirlemek için bir yarışma stratejisi uygulanır. Eğer bir x eğitim örneğinin i . sınıfa ait olduğuna karar verilirse, i . sınıfın puanı 1 artırılır. Aksi durumda j . sınıfın puanı hanesine 1 eklenir. Bu yarışma stratejisi sonucunda, hangi sınıfın puanı daha fazla ise x örneğinin kesin olarak o sınıfa ait olduğuna karar verilir [22]. Şekil 8'de 5 farklı sınıfın BKB yöntemi ile sınıflandırılması gösterilmiştir [29].

Şekil 8'deki 5 farklı sınıftan oluşan sınıflandırma problemini çözmek için BKB yöntemi $M = k(k-1)/2 = 10$ adet sınıflandırıcı kullanmıştır. BKB yönteminde kullanılan sınıflandırıcı sayısı $k \geq 3$ olması durumunda BKD yöntemine göre daha fazla olmasına rağmen ($M = k(k-1)/2 \geq k$), BKD



Şekil 8. Farklı 5 sınıfın ÇDVM ile sınıflandırılması (MSVM classification of 5 different classes)

yöntemi her örnek için geriye kalan tüm veri setini eğittiğinden eğitimi daha yavaştır [22].

5. ÇDVM İLE ARIZA TİPLERİNİN BELİRLENMESİ (FAULT TYPE IDENTIFICATION WITH MSVM)

Şekil 2’de gösterilen prototip güç sisteminde, 50 noktada farklı zamanlarda meydana getirilen TFT, 2F, 2FT ve 3F arıza durumlarına ait ADD detay katsayıları ÇDVM ile eğitilmiş ve bu arızaların % 99’u doğru olarak sınıflandırılmıştır. Sınıflandırma yapılırken TFT: 1, 2F: 2, 2FT: 3 ve 3F arızası ise 4 rakamı ile temsil edilmiştir. ÇDVM sınıflandırıcısının eğitimi için yapılan çapraz-geçerlilik testi sonucunda en uygun parametre değerleri $C=1000$ ve $\sigma=1$ olarak bulunmuştur. Bu parametrelerin seçilmesiyle elde edilen çapraz-geçerlilik testi hatası yaklaşık olarak 0.02’dir.


Tablo 3’te ÇDVM sınıflandırıcısının eğitim ve testi için kullanılan ve doğru olarak sınıflandırılan arıza sayıları verilmiştir. Şekil 9’da ise sınıflandırıcıdan beklenen gerçek çıkışlar ve ÇDVM’nin test edilmesinden elde edilen çıkışlar gösterilmiştir. Şekil 9’dan da görüldüğü gibi, test edilen 100 arıza durumundan 99’u doğru sınıflandırılmıştır. Sadece 1 arıza durumu için beklenen gerçek çıkış 2FT iken ÇDVM sınıflandırıcısı bu arızayı 2F arızası olarak algılamıştır.

Tablo 3. DVM sınıflandırıcısı ile eğitilen ve test edilen arıza sayıları (Trained and tested fault numbers by using SVM classifier)

Arıza Tipi:	TFT	2F	2FT	3F	Toplam
Eğitim:	25	25	25	25	100
Test:	25	25	25	25	100
Doğru:	25	25	24	25	99
Yanlış:	-	-	1	-	1

6. ÇAPRAZ GEÇERLİLİK TESTİ (CROSS VALIDATION TEST)

ÇDVM sınıflandırıcısının eğitim ve test başarısı oldukça yüksek olmasına rağmen, sonuçların rastlantısal olma olasılığı vardır. Ayrıca sınıflandırıcının eğitimi için ayrılan veri sayısının az olması, test başarımını olumsuz yönde etkileyebilmektedir. ÇDVM’nin sınıflandırmadaki güvenilirliğini ve geçerliliğini sağlamlaştırmak için ikinci bir geçerlilik testi uygulanmıştır. K -katlı çapraz geçerlilik testinde (K -fold cross-validation) ilk olarak, veri seti K sayısı kadar alt sete bölünür [30]. $K-1$ adet alt veri seti



Şekil 9. ÇDVM sınıflandırıcısından beklenen ve tahmin edilen çıkışlar (Predicted and expected outputs of MSVM classifier)

eğitim için kullanılırken, 1 adet alt veri seti eğitilen ağın testi için kullanılır. Bu işleme, bütün alt veri setleri eğitim dışında bırakılıp test edilinceye kadar devam edilir. Test edilen veri setlerinin başarılı sonuç vermesi, kullanılan ağın güvenilirliğinin ve geçerliliğinin derecesini verir. K adet veri setinin test başarısının ortalaması alınarak tek bir geçerlilik değeri elde edilebilir.

Bu çalışmada kullanılan ÇDVM sınıflandırıcısının geçerliliğinin test edilmesi için 5-katlı çapraz-geçerlilik testi uygulanmıştır. Toplam 200 adet arıza durumu olduğu için, 5-katlı çapraz-geçerlilik testinde kullanılan her bir alt veri seti 40 arıza durumuna ait verileri içermektedir. 5 aşamadan oluşan testin her aşamasında 18×160 adet veri ağın eğitimi için, 18×40 adet veri ise ağın test edilmesi için kullanılmıştır. Tablo 4’te 5 ayrı ÇDVM sınıflandırıcısından oluşan çapraz geçerlilik testinin sonuçları verilmiştir.

Tablo 4’te görüldüğü gibi, ÇDVM sınıflandırıcısı çapraz geçerlilik testi uygulanan arıza tiplerinin tamamını doğru olarak sınıflandırmıştır. Çapraz geçerlilik testi sonuçları, kullanılan ÇDVM sınıflandırıcısının arıza tiplerini belirlemedeki başarısının rastlantısal olmadığını göstermektedir. Çapraz geçerlilik testi ile 18×200 boyutundaki özellik veri setinin tamamı eğitilmiş ve test edilmiştir. Burada dikkat edilmesi gereken en önemli nokta, ÇDVM’nin eğitiminde giriş olarak 100 yerine 160 arıza verisinin kullanılması test başarımını arttırmıştır.

ÇDVM sınıflandırıcılarının arıza tipi belirlemedeki başarısını değerlendirmek için Bayes, k-EYK, RTF ağları, Elman ağları, ÇKA ağları ve OSA gibi sınıfl-

Tablo 4. Beş katlı çapraz-geçerlilik testi sonuçları (Results of the five-fold cross validation test)

	ÇDVM-1	ÇDVM-2	ÇDVM-3	ÇDVM-4	ÇDVM-5
Eğitim	18×160	18×160	18×160	18×160	18×160
Test	18×40	18×40	18×40	18×40	18×40
% Başarı	100	100	100	100	100

landırıcılar kullanılmış ve sonuçları karşılaştırılmıştır. Tablo 5'te bu sınıflandırıcıların eğitimi için geçen süreler ve yüzdelik başarı oranları gösterilmiştir.

Tablo 5. ÇDVM'nin diğer sınıflandırıcılar ile karşılaştırılması (Comparison of MSVM with the other classifiers)

Sınıflandırıcı	Eğitim Süresi (s)	Başarı %
OSA	0.24	99
Bayes	0.14	45
k-EYK	-	96
RTF	0.25	97
Elman	327.77	85
ÇKA	105.13	99
ÇDVM	0.04	99

Tablo 5'te görüldüğü gibi farklı arıza tiplerini belirlemede başarısı en yüksek olan sınıflandırıcılar OSA, ÇKA ve DVM'dir. Sınıflandırma başarısı en düşük olan yöntem ise % 45 doğruluk oranına sahip olan Bayes sınıflandırıcısıdır. Tablo 5'e bakıldığında, Bayes sınıflandırıcısı dışındaki tüm sınıflandırıcıların başarı performansı oldukça iyidir. Başarı performansı yanında sınıflandırıcı seçiminde dikkat edilmesi gereken diğer önemli bir husus, ağırlı oluşturulması, eğitim ve testi için harcanan zamandır. Başarı oranı en yüksek ve eğitimi için harcanan zamanı en az olan sınıflandırıcı, doğal olarak uygulamada kullanılacak sınıflandırıcının seçimi için en önemli ölçüttür. Tablo 5'ten de görüldüğü gibi ÇDVM sınıflandırıcısının %99'luk başarı oranı ile arıza tiplerini belirlemek için harcadığı zaman sadece 40 milisaniedir.

7. SONUÇLAR (RESULTS)

Bu çalışmada, güç sistemlerinde meydana gelen kısa devre arıza tiplerini hızlı ve doğru bir biçimde tespit eden bir yöntem sunulmuştur. Önerilen yöntem başlıca üç temel aşamadan oluşmaktadır. İlk aşama, kullanılacak verilerin elde edilmesi ve ön işlemdir. Bu amaçla, ATP programı ile 380 kV–360 km'lik bir iletim hattı benzetimi yapılarak dört arıza tipi (TFT, 2F, 2FT ve 3F) için 50 farklı noktada ve oluş açılarında kısa devre arızaları meydana getirilmiştir. Bu arıza durumlarına ait faz gerilimleri ve akımları bilgisayar ortamında kaydedilmiştir. Gerilim ve akım sinyallerine ait veriler [-1, 1] aralığında normalize edilmiştir. Arızalı ve sağlam fazlar için, yarım periyodu arıza öncesi ve diğer yarım periyodu arıza sonrası olmak üzere toplam bir periyotluk sinyaller ele alınmıştır. Bu işlem sayesinde hem arıza anından önceki hem de arıza anından sonraki bilgileri içeren veriler elde edilmiştir.

İkinci aşamada ise, literatürde diğer sinyal analiz yöntemlerine göre üstünlükleri ispatlanmış olan, ADD yöntemiyle sinyallere ait ayırt edici özellikler çıkarılmıştır. Daubechies-4 ana dalgacığı kullanılarak, üç seviyede ayrıştırılan akım ve gerilim sinyallerinin

sadece detay katsayıları kullanılmıştır. Bunun nedeni, yaklaşık katsayılarının düşük frekans bileşenlerini içermesidir. ADD ile elde edilen detay katsayılarının fazla olması nedeniyle dalgacıkların düzensizlik derecelerini hesaplayan entropi yöntemi kullanılarak veri sayısı düşürülmüştür. Bu sayede, her bir detay katsayı matrisi için bir entropi değeri hesaplanmış ve böylece her bir arıza durumu için 18 ayırt edici gerilim ve akım (9 gerilim, 9 akım) özelliğinden oluşan 200x18'lik bir veri matrisi elde edilmiştir.

Üçüncü aşamada, bir önceki aşamada elde edilen indirgenmiş akım ve gerilim verileri kullanılarak meydana gelen arızaların tipi belirlenmiştir. Arıza tipini belirlemek için oldukça yeni bir istatistiksel öğrenme algoritması olan destek vektör makineler yöntemi kullanılmıştır. Destek vektör makineler yöntemi, temelde iki sınıflı problemlerin çözümü için geliştirildiğinden, bu yöntemin birden fazla sınıftan oluşan problemlerin çözümünde kullanılan güncellenmiş bir sürümü olan çok sınıflı destek vektör makineler yöntemi kullanılmıştır. ADD katsayılarına entropi ölçütü uygulanarak elde edilen verilerin yarısı sınıflandırıcının eğitimi için, diğer yarısı ise test işlemi için kullanılmıştır. Destek vektör makineler sınıflandırıcısından en yüksek başarı oranını elde etmek için, kullanıcı tarafından belirlenen düzenleme katsayısı C ve çekirdek fonksiyonu sabiti σ 'nın en uygun değerleri araştırılmıştır. Çapraz geçerlik testi kullanılarak en uygun C parametresi 1000 ve σ değeri 1 olarak bulunmuştur. Çekirdek fonksiyonu olarak ise daha iyi sonuçlar veren ve daha yaygın olarak kullanılan radyal tabanlı fonksiyon tercih edilmiştir. Farklı arıza tipleri için eğitilen ÇDVM sınıflandırıcısı, daha önce kullanılmamış verilerle test edilmiş ve 100 arızadan 99'u doğru olarak sınıflandırılmıştır. Sınıflandırıcının başarı geçerliliğini değerlendirmek için ikinci bir çapraz geçerlik testi uygulanmış ve bu kez her seferinde 160x18 veri eğitim için, 40x18 veri test işlemi için kullanılmıştır. 5-katlı çapraz geçerlilik testi sonucunda bütün arızaların doğru olarak sınıflandırıldığı görülmüştür.

ÇDVM'nin arıza tiplerini sınıflandırmadaki başarısını değerlendirmek için Bayes sınıflandırıcıları k-EYK, OSA, ÇKA, RTF ve Elman ağırları gibi sınıflandırıcılar kullanılmış ve sonuçları karşılaştırılmıştır. Kullanılan sınıflandırıcılarının test başarımları incelendiğinde ÇKA ve OSA ağırlarının da, destek vektör makineler sınıflandırıcısı gibi %99 başarı oranı sağladığı görülmüştür. Genelleme özelliğinin yüksek olması, az sayıda veri kullanarak da doğru sonuçlar verebilmesi ve özellikle eğitimi için harcanan sürenin az olması DVM yöntemini üstün kılmıştır.

Sonuç olarak, DVM yönteminin iletim hatlarında meydana gelen kısa devre arızalarının tespiti için etkili ve kullanılabilir bir yöntem olduğu görülmüştür.

KAYNAKLAR (REFERENCES)

- Hanninen, S., Single Phase Earth Faults In High Impedance Grounded Networks, Characteristics, Indication and Location, **Espoo 2001**, Technical Research Centre of Finland, VTT Publications 453, 78s, 2001.
- Kezunovic, M., Digital protective relaying algorithms and systems-an overview, **Electric Power Systems Research**, 4, 3, 167-80, 1981.
- Davall, P.W., Yeung, G.A., A software design for a computer based impedance relay for transmission line protection, **IEEE Trans. on Power App. and Systems**, PAS-99, 1, 235-45, 1980.
- Youssef, O.A.S., Fundamental approach to impedance relaying, **IEEE Trans. on Power Delivery**, 7, 4, 1861-70, 1992.
- Sachdev, M.S., Sidhu, T.S., A technique for estimating the location of a transmission line shunt fault, **Electrical and Computer Engineering, Canadian Conference on**, 1, 562-565, 1993.
- Crossley, P.A., McLaren, P.G., Distance protection based on travelling waves, **IEEE Trans. on Power Apparatus and Systems**, PAS-102, 9, 2971-2983, 1983.
- Bollen, M.H.J., Travelling-wave based protection of double-circuit lines, **IEE Proceedings-C**, 140, 1, 37-47, 1993.
- Morlet, J., Wave propagation and sampling theory and complex waves, Technical Report, **Geophysics**, 47, 2, 222-236, 1982.
- Cichocki, A., Lobos, T., Artificial neural networks for real-time estimation of basic waveforms of voltages and currents, **IEEE Trans. on Power Systems**, 9, 2, 612-8, 1994.
- Perez, L.G., Flechsiz, A.J., Meador, J.L., Obradovic, A., Training an artificial neural network to discriminate between magnetizing inrush and internal faults, **IEEE Trans. on Power Delivery**, 9, 1, 434-41, 1994.
- Igel, M., Koglin, H.J., Schegner, P., New algorithms for earth fault distance protection in insulated and compensated networks, **European Transaction in Electrical Power**, 1, 5, 253-259, 1991.
- Kim, C.H., Kim, H., Ko, Y., Byun, S.H., Aggarwal, R.K., Johns, A.T., A novel fault-detection technique of high-impedance arcing faults in transmission lines using the wavelet transform, **IEEE Trans. on Power Delivery**, 17, 4, 921-929, 2002.
- Prikler, L., Hoidalén, H.K., **ATPDraw Version 3.5 User's Manual, Preliminary Release 1.0**, 198-200, 2002.
- CanAm EMTP User Group, **Alternative Transients Program (ATP) - Rule Book**, 1992.
- Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J.M., **Wavelet Toolbox, For Use with MATLAB, The MathWorks**, User's Guide, Ver:3, 2005.
- Özgönenel, O., Önbilgin, G., Kocaman, Ç., Wavelets and its applications of power system protection, **Gazi University Journal of Science** 17, 2, 77-90, 2004.
- Daubechies, I., Ten Lectures On Wavelets, 2nd ed., Philadelphia: **SIAM, CBMS-NSF regional conference series in applied mathematics**, 61p, 1992.
- Kaiser, G., **A Friendly Guide To Wavelets**, Birkhauser Boston, 324p, 1994.
- Ekici, S., Yildirm, S., Fault Location Estimation on Transmission Lines Using Wavelet Transform and Artificial Neural Network. Proceedings of the 2006 **International Conference on Artificial Intelligence**, ICAI 2006, Las Vegas, USA, 1: 181-184, 2006.
- Ekici, S., Yildirim, S., Poyraz, M., Energy and Entropy-Based Feature Extraction for Locating Fault on Transmission Lines by Using Neural Network and Wavelet Packet Decomposition, **Expert Systems with Applications**, doi:10.1016/j.eswa.2007.05.011, 2007.
- Mo, F., Kinsner, W., Probabilistic neural networks for power line fault classification, **IEEE Canadian Conference on Electrical and Computer Eng.**, 585-588, 1998.
- Jiang, Z.G., Fu, H.G., Li, L.J., Support vector machine for mechanical faults classification, **Journal of Zhejiang University Science**, 6A, 5, 433-439, 2005.
- Smola, A.J. and Schölkopf, B., A tutorial on support vector regression, **Technical Report NC2-TR-1998-030**, 200-222, 1998.
- Burges, C.J.C., A tutorial on support vector machines for pattern recognition, **Data Mining and Knowledge Discovery**, 2, 121-167, 1998.
- Dash, P.K., Samantary, S.R., Ganapati, P., Fault classification and section identification of an advanced series-compensated transmission line using support vector machine, **Power Delivery, IEEE Transactions on**, 22, 67-73, 2007.
- Marwala, T., Mahola, U., Chakraverty, S., Fault classification in cylinders using multi-layer perceptrons, support vector machines and gaussian mixture models, **The Intl. Symposium on Neural Networks and Soft Computing**, NNSC-2005, 14, 2, 307-316, 2007.
- Pöyhönen, S., **Support Vector Machine Based Classification In Condition Monitoring of Induction Motors**, Doktora Tezi, Helsinki University of Technology, 63p, 2004.
- Vapnik, V., **The Nature of Statistical Learning Theory**, New York: Springer Verlag, New York, 187p, 1995.
- Vojtech, F., Hlavac, V., **Statistical Pattern Recognition Toolbox for MATLAB (SPRTOOL)**, User's Guide, 2007.
- Kohavi, R., A study of cross-validation and bootstrap for accuracy estimation and model selection, **Proceedings of the Fourteenth International Joint Conference on Artificial Intelligence**, 2, 12, 1137-1143, 1995.