

GÜÇ KALİTESİNDEKİ BOZULMA TÜRLERİNİN SINIFLANDIRILMASI İÇİN BİR ÖRÜNTÜ TANIMA YAKLAŞIMI

Murat UYAR, Selçuk YILDIRIM, Muhsin Tunay GENÇOĞLU*

Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Mimarlık Fak., Siirt Üniversitesi, 56100, Siirt

*Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fak., Fırat Üniversitesi, 23119, Elazığ

muvar@firat.edu.tr, svildirim@firat.edu.tr, mtgencoglu@firat.edu.tr

(Geliş/Received: 01.03.2010; Kabul/Accepted: 14.12.2010)

ÖZET

Bu çalışmada, güç kalitesindeki bozulma türlerinin sınıflandırılması için örüntü tanıma yaklaşımlarına dayalı bir algoritma önerilmiştir. Örüntü tanımının önemli bir kısmı olan özellik çıkarma için, dalgacık dönüşümünün ayrıştırma katsayılarını kullanan entropi temelli bir yöntem sunulmuştur. Yöntemin en önemli avantajı, işaretin ayırt edici özelliklerini kaybetmeksizin veri boyutunu indirgeyebilmesidir. Sınıflandırıcı olarak, istatistiksel öğrenme teoremine dayanan destek vektör makineler kullanılmıştır. Önerilen algoritmanın başarımı, gerçek ve yapay güç kalitesi bozulma verileri kullanılarak değerlendirilmiştir. Gerçek güç kalitesi bozulma verileri, ulusal enerji sistemimizden elde edilmiştir. Yapay veriler ise, ATP/ EMTP modelinden ve matematiksel modellerden elde edilmiştir. Çalışmadan elde edilen analiz ve sonuçlar, önerilen algoritmanın etkin, güvenilir ve uygulanabilir bir yapıya sahip olduğunu göstermektedir.

Anahtar Kelimeler: Örüntü tanıma, güç kalitesi bozulmaları, dalgacık dönüşümü, destek vektör makineleri.

A PATTERN RECOGNITION APPROACH FOR CLASSIFICATION OF POWER QUALITY DISTURBANCE TYPES

ABSTRACT

In this study, an algorithm based on pattern recognition approach is proposed for classification of power quality disturbance types. For feature extraction which is an important part of the pattern recognition, a method based on entropy which uses the decomposition coefficients of wavelet transform is presented. The most important advantage of the method is the reduction of data size without losing main distinguishing characteristics of signal. Support vector machines based on statistical learning theory is used as a classifier. The performance of the proposed algorithm is evaluated by using real and synthetic power quality disturbance data. Real power quality disturbance data are obtained from our national power system. Besides, the synthetic power quality disturbance data are obtained from ATP/EMTP and mathematical models. The analyses and results obtained in this study show that proposed algorithm has an efficient, feasible and practical structure.

Keywords: Pattern recognition, power quality disturbances, wavelet transform, support vector machines.

1. GİRİŞ (INTRODUCTION)

Elektrik enerjisini üreten, ileten ve dağıtan kuruluşlar; kesintisiz, ucuz ve kaliteli bir gücü tüketicilerine sunmayı amaçlamaktadır. Güç kalitesi kavramından maksat, sabit şebeke frekansında, sabit genlikli ve sinüs şeklinde bir yük geriliminin sağlanmasıdır. Ancak güç sistemi arızalara ve dinamik durumlara maruz kaldığında veya doğrusal olmayan yüklerin

etkisinde kaldığında gerilim dalga şekilleri genellikle saf sinüs şekline uzaklaşır. Gerilimin, akımın ve şebeke frekansının verilen sınırlar dışına çıkması, güç kalitesi problemleri veya güç kalitesi bozulmaları (GKB) olarak değerlendirilmektedir [1].

Üretici ya da tüketiciden kaynaklanan ve güç kalitesini olumsuz yönde etkileyen faktörler ortadan kaldırılmaya çalışılmadan önce, standartlarda

belirtilen ölçütler doğrultusunda sistemdeki bozulmalar hızlı ve verimli bir şekilde tespit edilmelidir. Daha sonra bu bozulmaların temel karakteristikleri belirlenerek hangi bozulmaların meydana geldiğine karar verilmelidir [2]. Böyle bir çalışma yapıldığı takdirde, sistem hakkında durum tespiti ve değerlendirme yapılarak bozulmaların kaynağı ve sebepleri araştırılabilir. Belirli bir baradan beslenen mevcut tesisler veya belirli bir baradan beslenilmesi planlanan yapım veya tasarım halindeki tesisler, ölçümler sonucu elde edilen güç kalitesi verileri doğrultusunda bilinçli yer seçimi ve doğru ekipman seçimi yapma imkanına kavuşturulabilir. Son olarak, bu veriler doğrultusunda hangi bölgelere hangi özellikte bir güç kalitesi iyileştirme cihazının (aktif güç filtreleri, gerilim düzenleyiciler, kesintisiz güç kaynakları vb.) konulması gerektiğine karar verilebilir [3]. Bu bilgiler ışığında önerilen çözümler sistemin sürekliliğini ve güvenilirliğini artırmanın yanında sistemin kontrolünü de kolaylaştırır. Bu amaç için, güç kalitesi izleme cihazları yaygın bir şekilde kullanılmaktadır.

Geleneksel izleme cihazlarıyla yapılan ölçümlerde veriler, önce cihaz hafızasına kaydedilir ve bu bilgiler daha sonra istenildiğinde bilgisayar ortamına aktarılır. Hem cihaz içerisinde hem de bilgisayar ortamında analiz işlemleri gerçekleştirilerek, bozulmalara ait bilgiler çıkarılabilir. Bu şekilde veri analiz işlemi; oldukça zahmetli, zaman alıcı ve zordur. Ayrıca, bilgi çıkarımında genellikle Fourier Dönüşümü (FD) temelli işaret işleme yöntemlerinin sınırlı kapasiteye sahip olması, geleneksel izleme cihazlarının diğer bir dezavantajıdır [4,5].

2000'li yılların başından itibaren bilgisayar teknolojisindeki gelişmelere paralel olarak, önerilen yeni işaret işleme yöntemleriyle akıllı sistemlerin birlikte kullanıldığı izleme sistemleri tasarlanmaya başlanmıştır [6]. Bu yeni eğilimlerin temel amacı, bir işaret işleme yöntemiyle farklı türden işaretleri işlemek ve akıllı sistemlerin genelleme yeteneği yardımıyla, işaretlerden sistemle ilgili önemli bilgileri çıkarmaktır.

Bir işaret işleme yöntemi olarak dalgacık dönüşümüne (DD) dayalı algoritmaların kullanıldığı yaklaşımlar son yıllarda GKB işaretlerini sınıflandırmak için kullanılmaya başlanmıştır. DD yöntemini cazip hale getiren en önemli özelliği, bant aralığının daha iyi ayarlanabilmesidir. Yöntem, işaretin yüksek frekanslı bileşenlerini küçük bir bant aralığıyla, düşük frekanslı bileşenlerini ise daha geniş bir bant aralığı ile analiz ederek, işarete ait ayırt edici özelliklerin elde edilmesine olanak sağlar.

Literatürde, DD ile beraber yapay zekaya dayalı akıllı sistemlerden yararlanılarak, bozulmaların sınıflandırılması için farklı yöntemler önerilmiştir. Perunicic ve diğ. (1998), DD'den elde edilen katsayıları doğrudan kendinden organize ağ yapısına giriş olarak uygulayarak geçici durum GKB

işaretlerinin otomatik olarak sınıflandırılması için önemli bir adım atmıştır [7]. Bu yöntemin en önemli dezavantajı, DD katsayılarının doğrudan sınıflandırıcıya giriş olarak uygulanması sonucu hesaplama yükünün artmasıdır. Gaouda ve diğ. (1999), FD ve KZFD yöntemlerine alternatif olarak çoklu çözünürlük ayrışımı yöntemini GKB işaretlerinin tespit edilmesi ve bunların sınıflandırılması için tavsiye etmiştir [2]. Bu çalışmada, çoklu çözünürlük analiziyle her çözünürlük seviyesinin standart sapma değerinden elde edilen özellikler, k-en yakın komşu sınıflandırıcıya giriş olarak uygulanarak farklı GKB işaretlerinin otomatik sınıflandırılması gerçekleştirilmiştir. Böylece sınıflandırıcıya giriş olarak uygulanan veri boyutu indirgenmiş ve sınıflandırma başarımı artırılmıştır. Fakat, çalışmada kullanılan özellik çıkarım yöntemi, işaretlerin ayırt edici özelliklerini ortaya çıkarmada etkili olmasına rağmen, farklı gürültü ortamlarına karşı dayanıklı bir sınıflandırıcıyla birlikte kullanılmaması, onun bozulma olaylarını doğru tanıma oranını azaltmıştır. Bu çalışmaların ortak özelliği, analiz edilecek olan işaretlerin, bilgisayar ortamında işareti yaklaşık olarak temsil eden cebirsel denklemler kullanılarak oluşturulmalarıdır. Yapılan bazı çalışmalarda ise, analizlerin geçerliliğini biraz daha artırmak için, farklı güç kalitesi olaylarına ait dalga şekilleri, EMTP/ATP ve EMTDC/PSCAD gibi paket programlar kullanılarak benzetimler sonucu oluşturulmuştur [8, 9].

Bu çalışmada, GKB sınıflandırma sistemlerinin etkinliğini ve güvenilirliğini artırmaya yönelik güçlü bir algoritma önerilmiştir. Yöntem, DD temelli destek vektör makine (DVM) sınıflandırıcıdan oluşur. Öncelikle, önerilen algoritmada DD'nin entropi hesaplamasından, bozulma işaretlerinin ayırt edici özelliklerini kaybetmeksizin veri boyutunu indirgeyen bir özellik vektörü elde edilmiştir. Daha sonra, bu özellik vektörü, DVM örüntü sınıflandırıcısının girişine uygulanarak GKB türleri belirlenmiştir. Önerilen algoritmanın başarımı, üç farklı veri kümesi (gerçek güç sistemi verileri, ATP/EMTP modelinden elde edilen benzetim verileri ve matematiksel modellerden elde edilen yapay veriler) kullanılarak değerlendirilmiştir.

Bu çalışmada önerilen algoritmanın literatürdeki diğer GKB sınıflandırma algoritmalarına göre üstünlükleri aşağıda özetlenmiştir:

- Matematiksel modellerden elde edilen yapay veriler, ATP/EMTP modelinden elde edilen benzetim verilerinin yanında çalışmanın güvenilirliğini arttıracak gerçek bir güç sisteminden elde edilen verilerin kullanılmış olması.
- Güç sisteminden elde edilen işaretler üzerinde bir gürültü ayırıştırma işlemi yapmadan yüksek sınıflandırma başarımının sağlanması.
- Birden fazla bozulmayı içeren GKB işaretlerinin yüksek doğrulukla sınıflandırılması.

- YSA sınıflandırıcıya göre, hesaplama süresini azaltan ve doğru sınıflandırma oranını arttıran DVM sınıflandırıcının kullanılmış olması.

2. DALGACIK DÖNÜŞÜMÜ (WAVELET TRANSFORM)

DD, durağan ve durağan olmayan işaret analizinde kullanılan ve bir işareti farklı ölçeklerdeki çözünürlük seviyelerinde tek bir fonksiyonu genişleterek ayrıştıran, önemli bir matematiksel yöntemdir. Dalgacık dönüşümünü FD'den, ayıran en önemli özellik, FD'den bir işaretin frekans bilgisi elde edilirken DD'den, verilen bir işaretin aynı anda hem zaman hem de frekans temsilinin elde edilmesidir [10]. Bu nedenle DD'nin GKB işaretlerini belirleyebilme ve onlara ait özellikleri çıkarmada önemli üstünlükleri vardır.

DD, sürekli ve ayrık olmak üzere iki farklı şekilde incelenir. Sürekli DD'de ölçeklendirme ve dalgacık fonksiyonu parametrelerinin sürekli olarak değişiminden dolayı her bir ölçek için dalgacık katsayılarının hesaplanması zor ve zaman alıcı olmaktadır. Bu nedenle ayrık dalgacık dönüşümü (ADD) daha sık kullanılmaktadır.

Verilen bir $f(t)$ işaretinin J seviye ADD'ü, hem ölçekleme hem de dalgacık fonksiyonu terimleriyle aşağıdaki gibi tanımlanabilir:

$$f(t) = \sum_n a_J(n) \phi(t-n) + \sum_n \sum_{j=0}^{J-1} d_j(n) 2^{j/2} \psi(2^j t - n) \quad (1)$$

Burada a_J , J seviye ölçekleme katsayısını, d_j , j seviye dalgacık katsayısını, $\phi(t)$, ölçekleme fonksiyonunu, $\psi(t)$ dalgacık fonksiyonunu, J dalgacık dönüşümün en yüksek seviyesini ve t zamanı temsil eder. Çok çözünürlük ayrışımında, ölçekleme fonksiyonu ve dalgacık fonksiyonu farklı çözünürlük seviyelerinde işareti ayrıştırmak için kullanılır. Dalgacık fonksiyonu ayrıştırılmış işaretin ayrıştırma katsayılarını (d_j), ölçekleme fonksiyonu ise yaklaşık katsayılarını (a_j) oluşturacaktır.

$$a_{j+1}(n) = \sum_k h(m-2n) a_j(n) \quad (2)$$

$$d_{j+1}(n) = \sum_m g(m-2n) a_j(n) \quad (3)$$

Burada h ve g sırasıyla alçak geçiren ve yüksek geçiren filtrelerin filtre katsayılarıdır.

3. DESTEK VEKTÖR MAKİNELER (SUPPORT VECTOR MACHINES)

İlk olarak Vapnik ve çalışma arkadaşları tarafından ikili sınıflandırma problemlerinin çözümünde

kullanılan DVM'ler, istatistiksel öğrenme teoremine dayanan örüntü sınıflandırma yöntemidir [11].

DVM'de amaç, veri kümesini mümkün olduğu kadar iyi sınıflandıran en uygun ayırıcı düzlemin bulunmasıdır. Yani iki sınıf arasındaki uzaklığın maksimum (en büyük) olduğu durumun bulunması amaçlanmaktadır. Bu amaç, doğrusal olmayan örnek uzayının doğrusal olarak ayrılabilmesi yüksek boyuta aktarıldıktan sonra, farklı örnekler arasındaki en büyük sınırmın bulunmasıyla gerçekleştirilir [12].

DVM'ler, doğrusal ve doğrusal olmayan DVM olmak üzere ikiye ayrılır. Doğrusal DVM'nin yapısındaki çekirdek fonksiyonu sadece giriş uzayının bir ürünüdür ve doğrusal olmayan çekirdek fonksiyonlarının kullanılmasına gerek yoktur. Doğrusal olmayan DVM'de ise, probleme uygun doğrusal olmayan bir çekirdek fonksiyonunun seçilmesine ihtiyaç vardır.

3.1. Doğrusal Destek Vektör Makineler (Linear Support Vector Machines)

Doğrusal DVM'ler, doğrusal olarak ayrılabilen ve doğrusal olarak ayrılabilen DVM'ler olarak incelenmektedir. Doğrusal olarak ayrılabilme durumunda, eğitim için kullanılacak N elemandan oluşan bir veri kümesi $\{x_i, y_i\}, i=1,2,\dots,N$, olarak tanımlandığında, $y_i \in \{-1, +1\}$, etiket değerlerini ve d boyutlu $x_i \in \mathcal{R}^d$ özellik vektörünü temsil etmek üzere, bu iki sınıfı temsil eden örnekler doğrudan bir ayırıcı düzlem ile ayrılabilir. DVM'nin amacı, verilen veri kümesini, tanımlanan etiketlere göre bir alt düzlemlerle ayırıp, aynı sınıfa ait bütün veri noktalarını alt düzlemin aynı tarafında bırakmaktır. Ayırıcı düzlem üzerindeki herhangi bir x noktası, w ayırıcı düzlemin normali ve $|b|/\|w\|$ ayırıcı düzlemin orijine dik uzaklığı olduğu kabul edildiğinde, DVM algoritması

$$f(x) = w^T x + b = 0 \quad (4)$$

ile tanımlanan en uygun ayırıcı düzlemi bulmaya çalışır. Bunun için eğitim kümesinin aşağıdaki bağıntıyı sağlaması gerekmektedir:

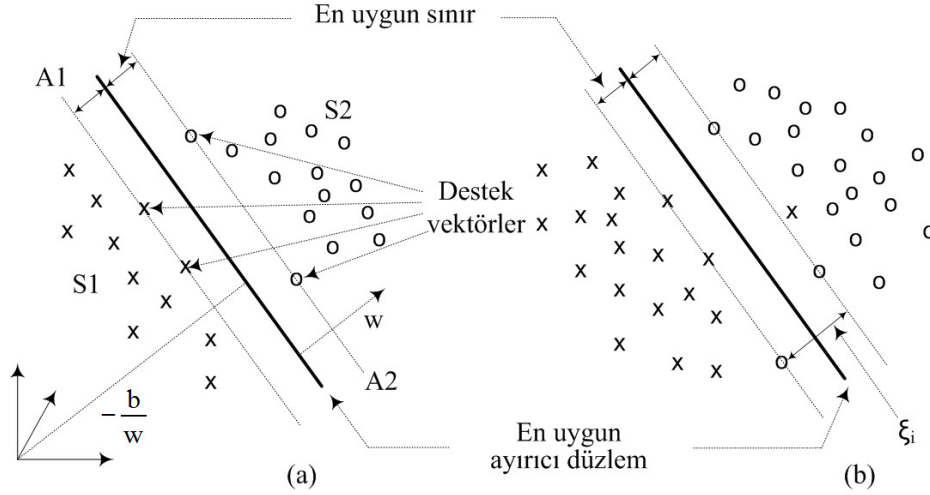
$$y_i = +1 \text{ için, } w^T x_i + b \geq +1 \quad (5)$$

$$y_i = -1 \text{ için, } w^T x_i + b \leq -1 \quad (6)$$

Bu eşitsizlikler bir arada ifade edildiğinde

$$y_i (w^T x_i + b) - 1 \geq 0 \quad i=0, 1, \dots, N \quad (7)$$

elde edilir. Burada en uygun ayırıcı düzlemi bulmak için w ve b değerleri hesaplanmalıdır. Doğrusal ayrılabilme durumuna ilişkin temsili gösterim Şekil 1(a)'da verilmiştir.



Şekil 1. (a) Doğrusal olarak ayrılabilir durumu (b) Doğrusal olarak ayrılamama durumu
((a) linearly separable case (b) linearly inseparable case)

Denklem (5)'in S1 sınıfını ayıran A1 ayrıcı düzlemini oluşturan eşitsizlik, denklem (6) eşitsizliğinin ise aynı şekilde S2 sınıfını ayıran A2 ayrıcı düzlemini oluşturan eşitsizlik olduğu kabul edildiğinde; A1 ayrıcı düzleminin orijine dik uzaklığı $l - |b|/\|w\|$ ve A2 ayrıcı düzleminin orijine uzaklığı $|-l - b|/\|w\|$ olacaktır. Bu iki ayrıcı düzlemin en uygun ayrıcı düzleme uzaklıkları ise $|l|/\|w\|$ kadardır. Bir başka deyişle, iki örnek kümesi arasındaki uzaklık A1 ve A2 ayrıcı düzlemlerinin birbirlerine paralel olmalarından dolayı $|2|/\|w\|$ kadardır. Burada A1 ve A2 ayrıcı düzlemleri arasında eğitim verilerine ait hiçbir örnek bulunmadığına dikkat edilmelidir. Bu iki ayrıcı düzlem arasındaki en büyük uzaklık ise $\|w\|$ değerinin en aza indirgenmesiyle bulunabilir. DVM yöntemiyle yapılmaya çalışılan, bu iki ayrıcı düzlemin arasındaki uzaklığın (sınırın) en büyük olmasını sağlamaktır. Bu iki düzlem arasında en büyük sınırın bulunması

$$\min \frac{1}{2} \|w\|^2 \quad (8)$$

$$y_i (w \cdot x_i + b) - l \geq 0 \quad (9)$$

ile ifade edilir. Burada denklem (8) çözülecek problemi, denklem (9) ise problemin çözümü sırasında kullanılan koşulu ifade eder. Ayrıca, bu ifade ikinci dereceden bir optimizasyon problemidir. Problemin çözümü için Lagrange formülasyonu uygulanabilir. Lagrange formülasyonunun uygulanmasının iki sebebi vardır. Birincisi Lagrange çarpanlarının hesaplanması daha kolaydır. İkincisi ise problemin doğrusal olmayan durum için de genelleştirilmesi daha uygundur [12]. Problemin Lagrange formülasyonu ise,

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N \alpha_i y_i (w^T x_i + b) + \sum_{i=1}^N \alpha_i \quad (10)$$

şeklinde dir. Bu formülasyonda $\alpha_i \geq 0$ değerleri pozitif Lagrange çarpanları olarak adlandırılır. Ancak denklem (10)'da ifade edilen formülasyonun çözülmesi oldukça karmaşıktır. Çözümün bulunması için denklem (10), Karush-Kuhn-Tucker (KKT) şartları kullanılarak ikili probleme dönüştürülmelidir. Bu problem için, KKT şartlarına bağlı çözüm;

$$L_p = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (11)$$

ifadesi ile elde edilmiş olur. Denklem (11)'deki ifadenin çözümü $\alpha_i \geq 0$ koşulları altında ikinci dereceden optimizasyon (en iyileme) problemi ile gerçekleştirilir. Burada dikkat edilirse, her eğitim örneği için bir tane Lagrange çarpanının olduğu görülür. Çözümde elde edilen Lagrange çarpanlarının büyük çoğunluğunun değeri sıfır olacaktır. Geriye kalan $\alpha_i \geq 0$ değerli x_i örnekleri destek vektörlerdir ve A1 veya A2 ayrıcı düzlemlerinin üzerinde yer alırlar. Lagrange çarpanı sıfır olan örnekler ise A1 veya A2 ayrıcı düzlemlerinin arka taraflarında kalan örneklerdir.

Eğer, örnekler doğrusal olarak tamamen ayrılabilir durumda değilse, problemin çözümü için pozitif zayıflık değişkenleri $\xi_i = 1, 2, \dots, N$ kullanılır. Bu duruma ait en uygun ayrıcı düzlemin temsili gösterimi Şekil 1(b)'de verilmiştir. Bu duruma göre denklem (5) ve (6)'daki koşullar $\xi_i \geq 0$ olmak üzere zayıflık değişkenleri ile yeniden tanımlanacak olursa

$$y_i = +1 \text{ için, } w^T x_i + b \geq +1 - \xi_i \quad (12)$$

$$y_i = -1 \text{ için, } w^T x_i + b \leq -1 + \xi_i \quad (13)$$

şeklinde olacaktır. $\xi_i = 0$ olması durumunda x_i örneği doğru sınıflandırılmış, $\xi_i \geq 1$ ise yanlış sınıflandırılmış demektir.

Doğrusal olarak ayrılama durumunda, eğitim verisi içindeki olası her duruma karşı bir çözüm üretilmesini engellemek için sisteme bir C düzenleme parametresi eklenir. Aynı zamanda bu parametre, Lagrange çarpanlarının alabilecekleri en büyük değeri de göstermektedir. Bu şekilde Lagrange çarpanlarının $0 \leq \alpha_i \leq C$ aralığında kalması sağlanmaktadır. C düzenleme parametresi, DVM'nin eğitim aşamasında belirlemesi gereken parametrelerden biridir. Bu doğrultuda Lagrange formülasyonu denklem (14)'deki gibi yeniden düzenlenir:

$$L_p = \frac{1}{2} \|w\|^2 + C \sum_i \xi_i - \sum_i \alpha_i \left\{ y_i (w^T x_i + b) - 1 + \xi_i \right\} - \sum_i \mu_i \alpha_i \quad (14)$$

Burada μ_i , zayıflık değişkenlerinin (ξ_i) pozitif değerde kalmasını sağlamak için kullanılmış bir Lagrange parametresidir. Bu Lagrange formülasyonunun çözümü için de KKT şartları uygulanırsa;

$$L_d = \sum_i \alpha_i - \frac{1}{2} \sum_{i,j} \alpha_i \alpha_j y_i y_j x_i^T x_j \quad (15)$$

elde edilir. Burada, $0 < \alpha_i < C$ aralığında yer alan ve Lagrange çarpanlarına karşılık gelen x_i değerleri destek vektörleri temsil eder.

3.2. Doğrusal Olmayan Destek Vektör Makineler (Nonlinear Support Vector Machines)

Doğrusal olmayan problemlerde çözümü bulmanın yolu, çekirdek fonksiyonları ile örneklerin öncelikle daha yüksek boyutlu ve doğrusal olarak ayrılacakları bir uzaya taşınıp çözümün bu yeni uzayda aranmasıdır. Bu durum $\Phi: \mathcal{R}^d \mapsto H$ olmak üzere, d boyutlu özellik uzayını bir H Öklid uzayına taşıyan Φ fonksiyonunun olduğu düşünülerek gerçekleştirilebilir. Böylece DVM'nin eğitim algoritması, H uzayındaki verilerin

$$\Phi(x_i) \cdot \Phi(x_j) = K(x_i, x_j) \quad (16)$$

şeklindeki iç çarpımlarına bağlı olacaktır. Burada K çekirdek fonksiyonunu temsil eder. Böylece sınıflandırıcı, eğitimden sonra herhangi bilinmeyen bir x örneği denklem (17)'deki karar fonksiyonuyla belirlenebilir.

$$f(x) = \sum_{i=1}^N \alpha_i y_i \Phi(x_i) \cdot \Phi(x) + b = \sum_{i=1}^N \alpha_i y_i K(x_i, x) + b \quad (17)$$

Bu fonksiyonda N destek vektörlerin sayısını, x_i ise destek vektörleri belirtir.

Literatürde farklı alanlarda çekirdek fonksiyonlarının sınıflandırma başarımını değerlendirmek üzerine bazı çalışmalar yapılmıştır. Bu çalışmalarda genellikle radyal tabanlı çekirdek fonksiyonları kullanılmasıyla yüksek sınıflandırma başarımının elde edilebileceği vurgulanmıştır [13]. Çünkü, radyal tabanlı çekirdek fonksiyonları, seçilen parametre aralıklarına bağlı

olarak, hem sigmoid çekirdek fonksiyonunun hem de doğrusal çekirdek fonksiyonunun özelliklerini gösterebilmektedir [14].

DVM temelde iki sınıflı problemlerin çözümü için kullanılan bir yöntem olmasına rağmen, son yıllarda geliştirilen yaklaşımlarla ikiden fazla sınıfa ait veri kümesini sınıflandırabilen ve çok sınıflı DVM olarak isimlendirilen yöntemler önerilmiştir [15, 16]. Bu yaklaşımlardan en önemlileri, bire karşı-diğerleri ve bire karşı-bir yöntemleridir.

4. GKB SINIFLANDIRMA ALGORİTMASI (POD CLASSIFICATION ALGORITHM)

GKB işaretlerini sınıflandırmak için kullanılan algoritma özellik çıkarma, sınıflandırma ve karar olmak üzere üç aşamadan oluşur. Önerilen GKB sınıflandırma algoritmasının blok şeması Şekil 2'de verilmiştir.

4.1. Özellik Çıkarım Aşaması (Feature Extraction Stage)

Herhangi bir örüntü tanıma sisteminin en önemli bileşeni özellik çıkarım aşamasıdır. Özellik çıkarımı, sınıflandırıcının başarımına önemli oranda katkıda bulunur ve örüntü verisinin belirli ayırt edici özelliklerini çıkararak boyutunda indirgeme yapar [17]. Karmaşık bir sınıflandırıcı yapısını tasarlamak yerine, örüntüler arasındaki ayrımı sağlayacak anahtar özellikleri belirlemek, günümüz örüntü tanıma sistemlerinin odağı haline gelmiştir. Çünkü uygun özellik çıkarımı yapılmadığı takdirde, sınıflandırıcı ne kadar iyi tasarlanırsa tasarlanırsa, başarımı yine çıkarılan özellik uzayına bağlı kalacaktır [17].

Bu aşamada, ADD çoklu çözünürlük ayrıştırma katsayılarının norm entropi hesaplamalarına dayalı bir yöntem kullanılmıştır [17, 18]. ADD temelli norm entropi özellik çıkarım yönteminin blok şeması, Şekil 3'te verilmiştir. ADD temelli özellik çıkarım yönteminde, Daubechies-4 dalgacık fonksiyonu kullanılarak 8 seviyeli ayrışım yapılmıştır. Bir bozulma işaretinin $U = \{u_j, j = 1, 2, \dots, N\}$ şeklinde olduğu düşünüldüğünde, U işareti içerisindeki j noktanın norm entropi değeri,

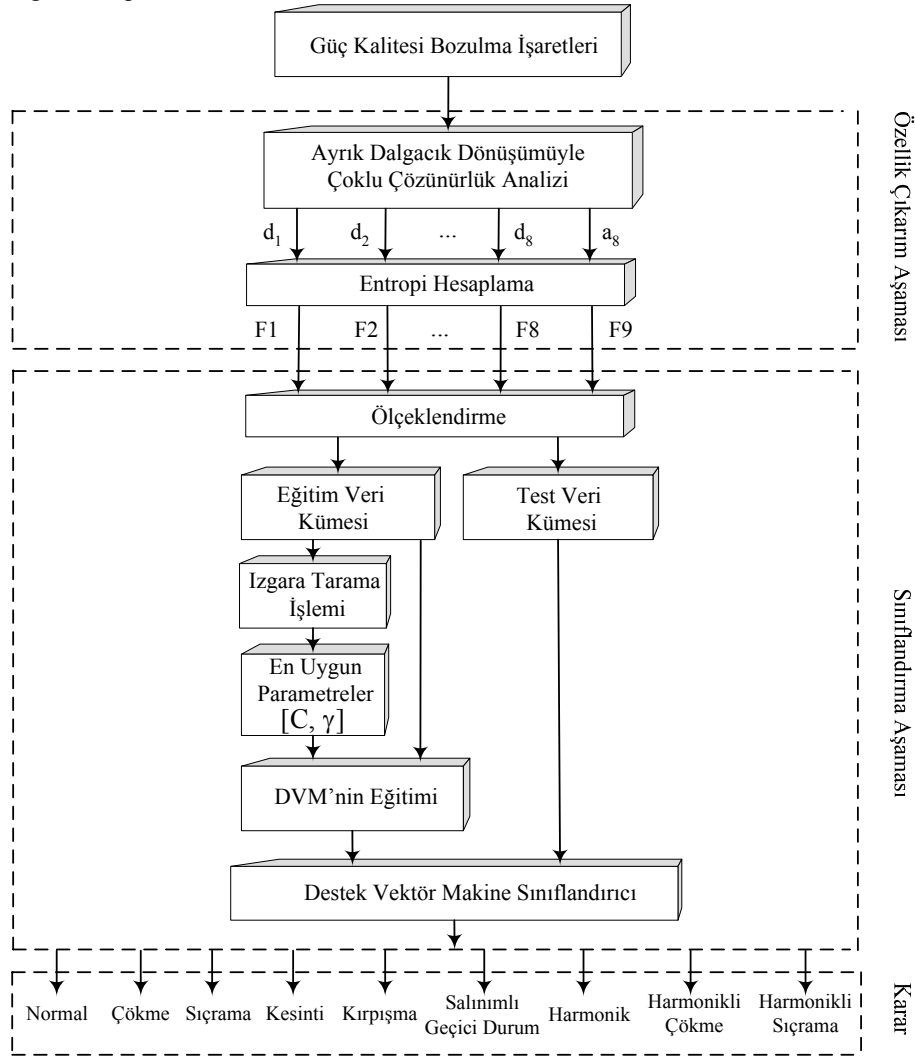
$$NE_j = |u_j|^P \quad (18)$$

şeklinde tanımlanır. Burada P güçtür ve $1 \leq P < 2$ olmalıdır. Bu durumda, U işaretinin tamamı için norm entropi değeri ise,


$$NE = \sum_{j=1}^N |U_j|^P \quad (19)$$

şeklinde ifade edilir. ADD'ye norm entropi yöntemini uygulamak için denklem (19)'daki hesaplama işlemi kullanılabilir. Bu çalışmada norm entropi hesaplamalarında, P değeri 3/2 olarak seçilmiştir. ADD'den elde edilen her ayrıştırma seviyesindeki

detay ve yaklaşık katsayılarından özellik çıkarım işlemi aşağıdaki gibi hesaplanır.



Şekil 2. Önerilen GKB sınıflandırma algoritmasının blok şeması (The block diagram of the proposed PQD classification algorithm)



Şekil 3. ADD temelli norm entropi özellik çıkarım yönteminin blok şeması (The block diagram of norm entropy feature extraction method based on ADD)

$$Wd_j = \sum_{j=1}^J \left(\frac{1}{N_j} \sum_n |d_j[n]|^p \right)$$

$$Wa_J = \frac{1}{N_J} \sum_n |a_J[n]|^p \quad (j = 1, 2, \dots, J) \quad (20)$$

seviyesini, a_j , J seviyesinde ADD'nin yaklaşık katsayısını, d_j ise ADD'nin l 'den j 'ye kadar detay seviyeleri için işaretin katsayılarını temsil eder. Denklem (20), denklem (22)'de görüldüğü gibi düzelenir.

$$W_{isare} = [Wd_1, \dots, Wd_J, Wa_J] \quad (21)$$

$$Wnd_j = (Wd_j)^{\frac{1}{2}} \quad Wna_J = (Wa_J)^{\frac{1}{2}} \quad (22)$$

Burada, W_{isare} ADD'nin her çözünürlük seviyesindeki entropi değerlerini, J toplam çözünürlük

$$Wn_{isare} = [Wnd_1, \dots, Wnd_J, Wna_J] \quad (23)$$

Burada $Wn_{işaret}$ bozulmuş işaretin normalize edilmiş (düzeltilmiş) özellik vektörünü temsil eder. Çıkarılan bu özellikler bir bozulma olayını diğerinden ayırt etmeye yardım edebilir. Fakat, burada entropi daima pozitif değerlere sahip olduğu için gerilim çökmesi, gerilim şıçraması gibi bozulmalarda benzer özellikler göstererek, bu işaretler için özellik vektörünün ayırt edici etkisini azaltacaktır. Bu durum, sınıflandırma aşamasında bu iki bozulmanın birbiriyle çakışmasına yol açabilir ve doğru tanıma oranını azaltabilir. Bu sorunu en aza indirmek için bozulmuş işaretler, referans olarak seçilen bozulmamış bir işaretle karşılaştırılmıştır. Bu amaçla, referans işaret için aynı hesaplama işlemleri yapılmalıdır. Denklem (20) ve denklem (22)'deki hesaplama adımları, denklem (24)'te verildiği gibi referans işaret için hesaplanabilir.

$$Wn_{ref} = [Wnd_1, \dots, Wnd_J, Wna_J] \quad (24)$$

Sonuçta, bozulmayı temsil eden özellik vektörü (ΔW), denklem (23)'ten denklem (24) çıkarılarak elde edilir.

$$\Delta W = Wn_{işare} - Wn_{ref} \quad (25)$$

$$\Delta W = [\Delta Wd_1, \Delta Wd_2, \dots, \Delta Wd_J, \Delta Wa_J] \quad (26)$$

4.2. Sınıflandırma Aşaması (Classification Stage)

Örüntü tanınmanın bir diğer aşaması, kullanılacak sınıflandırma algoritmasıdır. Sınıflandırıcılar, örüntüleri özellik uzaylarına göre kendilerine en yakın sınıflara en küçük hata ile eşleştiren matematiksel modellerdir. Bu modellerden, hızlı sonuç üretebilme, öğrenebilme ve öğrendiklerinden genelleme yapabilme yeteneklerine sahip olması beklenir [19].

GKB işaretlerinin türünün belirlenmesi için sınıflandırma aşamasında, ADD tabanlı özellik vektörünün giriş olarak uygulanacağı DVM sınıflandırıcı kullanılmıştır. Eğitim hızı, YSA'daki gibi yerel çözümler yerine global çözümler üretmesi ve buna bağlı olarak genelleme yeteneğinin yüksek olması bu sınıflandırıcının tercih edilmesinin en önemli sebepleridir.

DVM sınıflandırıcıyla etkili bir tanıma sistemi oluşturmak için en önemli aşamalardan biri de ayırıcı düzlem parametrelerinin seçimidir. Bu parametreler düzenleme parametresi (C) ve kullanılan çekirdek fonksiyonuna bağlı çekirdek parametresidir. DVM sınıflandırıcının eğitiminde, radyal tabanlı çekirdek fonksiyonu kullanılmıştır. Bu çekirdek fonksiyonu için γ , belirlenmesi gereken parametredir. Her iki parametrenin de geniş bir değer aralığına sahip olduğu düşünüldüğünde, bu parametrelerin en uygun değerlerinin belirlenmesi için etkili bir tarama algoritmasına ihtiyaç vardır. Bu adımı

gerçekleştirmek için, parametre uzayında iki aşamalı bir ızgara tarama algoritması kullanılmıştır. İlk aşamada, artış adımları büyük seçilen ve seyrek ızgaralı bir tarama işlemiyle, parametre uzayının tarama bölgesi daraltılır. İki aşamada da geçerli olmak üzere, her ızgara noktasındaki parametre değeri için, k-kat çapraz geçerlilik (k-fold cross-validation) yöntemiyle ortalama hata karelerinin toplamının karekökü (OHKT değeri) hesaplanır. Böylece, ilk aşama için tarama bölgesinde en düşük OHKT değerli parametre aralığı belirlenmiş olur. Daha sonra, sık ızgaralı tarama olarak isimlendirilen ikinci bir tarama işlemi, seyrek tarama işlemindeki düşük OHKT değerli bir alt bölge içerisinde gerçekleştirilir. Bu taramadan elde edilen en düşük OHKT değerine karşılık gelen parametreler, DVM sınıflandırıcının eğitiminde kullanılacak olan en uygun ayırıcı düzlem parametrelerini temsil eder. Şekil 4'te iki aşamalı ızgara tarama işleminin işleyişi gösterilmiştir.

4.3. Karar Aşaması (Decision Stage)

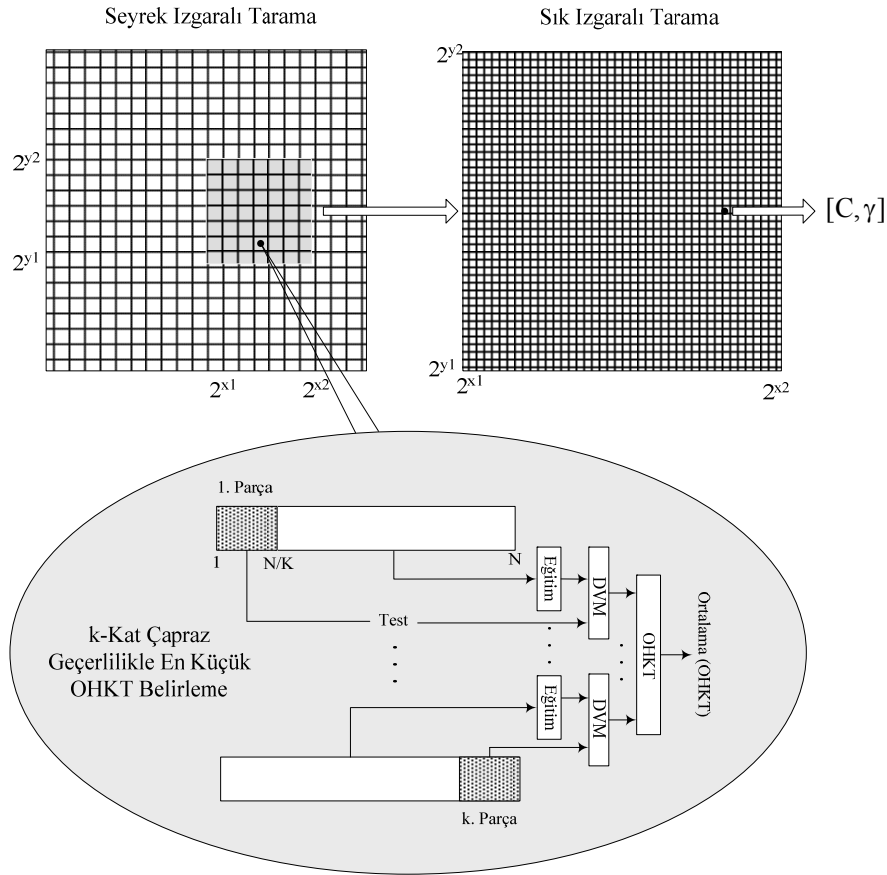
Karar aşamasında sonuçlar $N \times N$ karar matrisi şeklinde verilmiştir. Burada N sınıf sayısını temsil etmektedir. Karar matrisinin köşegen elemanları doğru sınıflamaları, diğerleri ise yanlış sınıflamaları temsil eder. Matrisin köşegen elemanlarının toplamı, GKB işaretlerinin toplam sayısına bölüldüğünde ortalama başarımlar elde edilir.

5. UYGULAMALAR VE TARTIŞMA (APPLICATIONS AND DISCUSSION)

Sınıflandırma işleminin başarımlarını değerlendirmek için, gerçek güç sistemi verileri ve benzetim verileri olmak üzere iki farklı veri kümesi (VK-1 ve VK-2) kullanılmıştır. Ayrıca, sınıflandırma başarımlarını değerlendirmenin diğer bir ölçütü ise başarımların karşılaştırılmasıdır. Böylece, önerilen yöntemlerin etkinliği, geçerliliği ve güvenilirliği ortaya çıkmış olur. Bunu gerçekleştirmek için, iki aşamalı bir karşılaştırma çalışması yapılmıştır. İlk olarak DVM sınıflandırıcının sonuçları, literatürde sıkça kullanılan YSA sınıflandırıcının sonuçlarıyla karşılaştırılmıştır. İkinci aşamada, matematiksel modele dayalı olarak üretilen veriler (VK-3) kullanılarak elde edilen sınıflandırma sonuçları, literatürde aynı şekilde ve yaklaşık olarak aynı sayıda veri üreten çalışmaların sonuçlarıyla karşılaştırılmıştır.

5.1. Güç Kalitesi Bozulma İşaretleri (Power Quality Disturbance Signals)

Sınıflandırma sistemi için kullanılacak verilerin güvenilir ve yeterli sayıda olması, en önemlisi de güç sistemlerinde sıkça karşılaşılan GKB işaretlerini kapsamı gerekmektedir. Bu amaçla, üç farklı veri kümesi oluşturulmuş ve önerilen sınıflandırma sisteminin başarımlarını bu veri kümeleriyle yapılan çalışmalarda gösterilmiştir.



Şekil 4. İki aşamalı ızgara tarama işlemi (Two stage grid search process)

5.1.1. Gerçek Güç Sistemi Ölçüm Verileri (Real Power System Data)

Gerçek bir güç sistemi, farklı seviyelerde gürültüler, dengesizlikler, farklı frekans içerikli işaretleri de kapsayacak bütün dinamik davranışları yapısında bulundurabilir. Böylece, bir GKB tanıma sistemi için önerilen algoritmaların başarımını değerlendirmede gerçek sistem verileriyle çalışmak son derece önemlidir.

Bu çalışmada, (Güç Kalitesi Milli Projesi olarak isimlendirilen, TEİAŞ, Tübitak Uzay, ODTÜ, HÜ, YTÜ ve DEÜ ile birlikte yürütülen proje kapsamında) Türkiye iletim şebekesinin farklı bir çok bölgesinden alınan ölçüm verileri çalışmanın başarımını değerlendirmek amacıyla kullanılmıştır [3-20]. Makale içerisinde bu veri kümesi VK-1 olarak isimlendirilmiştir.

Şekil 5'te GKB türlerine ait örnek dalga şekilleri gösterilmiştir. Dalga şekli kaydedilen GKB türleri, her GKB türünün sınıf etiket numaraları ve bunlara ait veri sayıları Tablo 1'de verilmiştir. Bu GKB türlerine ait işaretlerin örnekleme frekansı 3.2 kHz'dir. İşaretler için pencere genişliği, en az 1 periyot bozulma öncesi, en fazla 8 periyot bozulma süresi ve en az 1 periyot da

bozulma sonrası olmak üzere toplam 10 periyot olacak şekilde düzenlenmiştir.

Tablo 1. Gerçek güç sistemi ölçümlerinden elde edilen GKB türleri ve işaretlerin sayısı (PQD types and number of signals obtained from real power system)

GKB türü	Sınıf etiketi	İşaretlerin sayısı
Normal sinüs	S1	100
Gerilim çökmesi	S2	125
Gerilim sıçraması	S3	65
Anlık gerilim kesintisi	S4	40
Gerilim kırışması	S5	50
Harmonik bozulma	S6	80
Toplam		460

5.1.2. Benzetim Çalışmalarından Elde Edilen Veriler (Data Obtained From Simulation Studies)


Benzetim çalışmaları için, güç sistemlerini modellemede gerçeğe yakın sonuçların elde edilebildiği ve literatürde yaygın bir şekilde kullanılan ATP/EMTP (Alternative Transient Program/ Electro Magnetic Transient Program) paket programı kullanılmıştır [21, 22]. Bu çalışmada, ATP/EMTP paket programı kullanılarak bir güç sistemi modeli

oluşturulmuştur. Bu model üzerinde, genellikle arızalardan kaynaklanan S2, S3 ve S4 bozulmaları için, simetrik ve simetrik olmayan bazı arıza kombinasyonları oluşturulmuştur. Bu bozulma türleri içerisinden, veri çeşitliliği sağlamak amacıyla, arıza başlangıç-bitiş sürelerine bağlı olarak bozulmanın süresi, arıza direnci ve arıza yerine bağlı olarak da bozulma işaretlerinin genlik değerleri değiştirilmiştir. Gerilim değişimleri, farklı baralara bağlı ölçüm noktalarından izlenmiştir. Ayrıca, doğrusal olmayan yüklerden kaynaklanan ve sistemin güç kalitesini olumsuz yönde etkileyen S5, S6, S7 bozulmaları ise, model üzerine, ark fırını, kompanzasyon amacıyla kullanılan kapasitör grupları ve asenkron motor hız sürücüsü yerleştirilerek elde edilmiştir. ATP programı yardımıyla oluşturulan örnek güç sistemi modeli ve bu güç sistemine ait parametreler Ek-1'de sunulmuştur. Benzetim çalışmalarında elde edilen GKB türleri ve bu türlere ait işaret sayıları Tablo 2'de verilmiştir. Benzetimlerde kullanılan örnekleme frekansı ve pencere genişliği, gerçek ölçüm verileriyle

uyumlu olması için aynı seçilmiştir. Makale içerisinde bu veri kümesi VK-2 olarak isimlendirilmiştir.

Tablo 2. Benzetim çalışmalarından elde edilen GKB türleri ve işaretlerin sayısı (PQD types and number of signals obtained from simulation studies)

GKB türü	Sınıf etiketi	İşaretlerin sayısı
Normal sinüs	S1	200
Gerilim çökmesi	S2	200
Gerilim sıçraması	S3	200
Anlık gerilim kesintisi	S4	200
Gerilim kırışması	S5	200
Salınımlı geçici durum	S6	200
Harmonik bozulma	S7	200
Harmonikli gerilim çökmesi	S8	200
Harmonikli gerilim sıçraması	S9	200
Toplam		1800



Şekil 5. Gerçek güç sistemi ölçümlerinden elde edilen GKB türlerine ait örnek dalga şekilleri (Sample wave forms of PQD types obtained from real power system)

5.1.3. Matematiksel Modellerden Elde Edilen Veriler (Data Obtained from Mathematical Models)

Geçmiş yıllarda, önerilen GKB sınıflandırma sistemlerinin başarımını karşılaştırmak için standart bir referans (benchmark) veri bankasının olmaması, bu alanda yapılan bazı çalışmaların geçerliliğini sınırlandırmıştır. Bu sorunu en aza indirmek amacıyla, güç sistemlerinde sıkça karşılaşılan ve GKB işaretlerini yaklaşık olarak temsil eden matematiksel modele dayalı veri üretim yaklaşımı önerilmiştir [9]. Daha sonra bu modellere dayalı veri üretim yaklaşımı, farklı çalışmalarda önerilen yöntemlerin geçerliliğini gösterme ve karşılaştırma amacıyla kullanılmıştır [9, 18, 23]. Bu matematiksel modeller ve kontrol parametreleri referans [9, 18]' de ayrıntılı bir şekilde sunulmuştur. Modellere dayalı olarak üretilen GKB türleri ve bunlara ait veri sayıları Tablo 3'te verilmiştir.

Matematiksel modelden veri üretimi, belirtilen aralıklarda tamamen rast gele parametre değişimiyle gerçekleştirilir. Bu verilerin tamamı karşılaştırma amacıyla kullanıldığı için, literatürde bu yaklaşımla veri üreten çalışmaların işaret üretim adımları referans alınmıştır [9]. Diğer veri kümelerinden farklı olarak modele dayalı veri üretiminde örnekleme frekansı 12.8 kHz'dir. Makale içerisinde bu veri kümesi VK-3 olarak isimlendirilmiştir.

Tablo 3. Matematiksel modele dayalı elde edilen GKB türleri ve işaretlerin sayısı (PQD types and number of signals obtained from mathematical model)

GKB türü	Sınıf etiketi	İşaretlerin sayısı
Normal sinus	S1	400
Gerilim çökmesi	S2	400
Gerilim sıçraması	S3	400
Anlık gerilim kesintisi	S4	400
Harmonik bozulma	S5	400
Harmonikli gerilim çökmesi	S6	400
Harmonikli gerilim sıçraması	S7	400
Toplam		2800

5.2. Uygulama Sonuçları (Application Results)

Önerilen algoritma kullanılarak, üç veri kümesi için özellik çıkarım işlemleri gerçekleştirilmiştir. Normalde bir periyodunda 64 örnek bulunan, 10 periyotluk bir işaretin veri boyutu 640x1'dir. Fakat işaretin ayırt edici özelliklerini taşıyan özellik vektörü, 9x1 boyutunda bir matrisle temsil edilmektedir. Her GKB türünü S1, S2,...,S9 sınıf etiket numaraları temsil etmek üzere VK-2 içerisinde rast gele seçilen 20 farklı örnek işaret ile her işarete özgü tanımlayıcı karakteristikler gösterilmiştir. Şekil

6, her GKB türünün ayırt edici karakteristiğini yansıtan özelliklerin dağılımını göstermektedir.

Gerilim çökmesi, gerilim sıçraması ve anlık gerilim kesintisi (S2, S3 ve S4) işaretleri, şebeke frekansından farklı bir frekans bileşeni içermez. Şekil 6'dan görüldüğü gibi, 6. seviye özelliğinin entropi değerleri S2 ve S4 işaretlerinde negatif değerlere, S3 işaretlerinde ise pozitif değerlere sahiptir. Bu nedenle, şebeke frekansının frekans bandına karşılık gelen 6. seviye özelliğinin entropi değerleri bu işaretleri karakterize etmede önemli yere sahiptir. Fakat benzer özellikler gösteren S2 ve S4 işaretlerini bu yaklaşımla görsel olarak ayırt etmek oldukça zordur. Bu işaretlerin ayırt edilmesinde, 6. seviye özelliğinin entropi değerindeki bazı farklılıklar ve S4 işaretinin 9. seviye özelliğinin pozitif değerler alması önemli rol oynar.

Gerilim kırışması (S5) gibi şebeke frekansının altında bir frekans içeriğine sahip işaretlerin karakteristiği, 6. ve 7. seviyelerdeki özelliklerin entropi değerlerinden ayırt edilebilir. Ayrıca 9. seviye entropi değerindeki değişim de S5 işaretlerini ayırt etmede belirgin bir özellik olduğu söylenebilir.

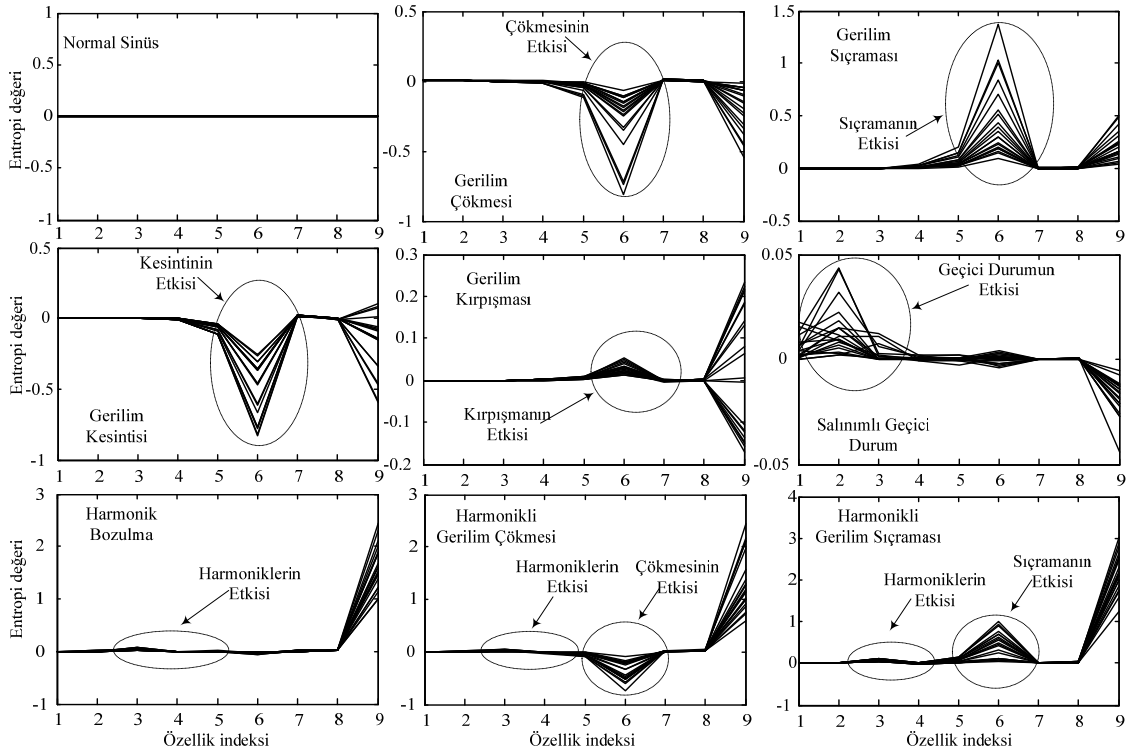
Salımlı geçici durumlar (S6), genellikle şebeke frekansının 10-20 katı frekans içeriğine sahip olabilir. Bu nedenle S6 işaretlerinin en belirgin ayırt edici özellikleri 1. ve 2. seviye özelliklerinin entropi değerindeki değişimlerden ortaya çıkmaktadır. Ayrıca 9. seviye entropi değerinin diğer GKB türlerine göre daha düşük değere sahip olması bu işaretin ayırt edilmesinde önemli bir özelliktir.

Harmonik içerikli işaretler (S7, S8 ve S9) içerinde şebeke frekansından yüksek frekanslı bileşenler bulunduğu için, 3., 4. ve 5. seviyelerdeki entropi dağılımlarında bir farklılık görülmektedir. 5. ve 7. harmoniklerden dolayı özellikle 3. ve 4. seviye özelliklerinin entropi değerindeki değişim, bu işaretlerin karakteristiğini yansıtmada önemli rol oynar. Harmonik bozulmanın yanında farklı bozulmalar da içeren S8 ve S9 işaretleri, S2 ve S3 işaretlerindeki gibi 6. seviye özellikleriyle karakterize edilebilir. Ayrıca 9. seviye özelliğinin entropi değerinin diğer GKB türlerine göre yüksek olması harmonik içerikli işaretlerin ayırt edilmesinde önemli bir yeri vardır.


Üç veri kümesinin verilerin yarısı DVM sınıflandırıcının eğitimi için, diğer yarısı ise, sınıflandırıcının başarımını değerlendirmek için kullanılmıştır. Eğitim ve test verilerinin geniş ve dağınık bir özellik uzayında olması sınıflandırıcının başarımını etkileyeceği için, veri kümeleri [-1, 1] aralığında ölçeklendirilmiştir. k-kat çapraz geçerlilik işlemi için eğitim veri kümelerini tam sayı olarak bölen k=5 değeri seçilmiştir. VK-1 için toplam 460 adet GKB işaretinin 230 tanesi eğitim, kalan 230 tanesi test aşaması için ayrılmıştır. ADD-Entropi

özellik çıkarım yönteminden elde edilen özellik vektörleriyle birlikte, eğitim kümesinin boyutu 230×9 olarak ifade edilir. Bu veri kümesi, hem çapraz geçerlilik yöntemiyle en uygun parametre seçiminde, hem de seçilen parametrelere göre gerçek sınıflandırıcının belirlenmesinde kullanılmaktadır. Parametre seçiminde, 5 aşamadan oluşan çapraz geçerlilik işleminin her aşamasında, 184×9 'luk bir matris DVM'nin eğitimi için, kalan 46×9 'luk bir matris ise test için kullanılmıştır. Bu işlemler, hem seyrek ızgaralı tarama işleminde, hem de sık ızgaralı tarama işleminde ayrı ayrı gerçekleştirilmiştir. Her iki tarama aşaması için parametrelerin değerlerinin artışına bağlı olarak OHKT değerindeki değişim Şekil 7'de verilmiştir. Seyrek ızgaralı tarama işlemi için düzenleme parametresinin aralığı $C = \{2^1, 2^2, \dots, 2^{16}\}$, çekirdek parametresinin aralığı ise

$\gamma = \{2^{-8}, 2^{-6}, \dots, 2^4\}$ olarak seçilmiştir. Bu işlemin ardından en düşük OHKT değerlerini alan bölgenin, γ için $[2^{-6}, 2^{-3}]$ ve C için $[2^{10}, 2^{15}]$ olduğu görülmüştür. Daha sonraki aşama olan sık ızgaralı tarama işleminde en düşük OHKT değerine göre en uygun parametrelerin $2^{-4.8}$ (0.03589) ve $2^{13.8}$ (14263) olduğu tespit edilmiştir. Bu işlemlerin ardından, belirlenen en uygun parametrelere göre ayarlanmış DVM algoritması, eğitim için ayrılan 230×9 boyutlu veri kümesiyle eğitilmiştir. Son olarak bilinmeyen olarak kabul edilen 230×9 'luk bir veri kümesiyle test aşaması gerçekleştirilmiştir. Test işleminin ardından sınıflandırma sonuçları karar aşamasında görülmektedir. VK-1 için önerilen algoritma kullanılarak elde edilen sınıflandırma işlemlerinin sonuçları Tablo 4'te verilmiştir.



Şekil 6. Farklı bozulma işaretleri için özellik vektörlerindeki değişimler (Variations in feature vectors for different disturbance signals.)



Şekil 7. (a) Seyrek ızgaralı tarama (b) Sık ızgaralı tarama ((a) search with coarse grid (b) search with finer grid)

Tablo 4. VK-1 için sınıflandırma sonuçları
(Classification results for VK-1)

Sınıf	S1	S2	S3	S4	S5	S6	Doğruluk (%)
S1	97	0	0	0	1	2	97,0
S2	1	121	0	2	1	0	96,8
S3	0	0	62	0	2	1	95,4
S4	0	1	0	39	0	0	97,5
S5	1	0	3	0	46	0	92,0
S6	2	0	0	0	0	78	97,5
Ortalama başarımlar						96,30	

için bu gecikme, toplam gecikme süresi bakımından önemsenmeyecek derecededir.

VK-1 için yapılan işlemlerin bir benzeri de VK-2 için gerçekleştirilmiştir. VK-2 için toplam 1800 adet GKB işaretinin rastgele seçilmiş 900 tanesi eğitim, kalan 900 tanesi test aşaması için ayrılmıştır. Tarama algoritmasıyla elde edilen en uygun ayırıcı düzlem parametreleri, $2^{-6.6}$ ve $2^{11.4}$ olarak belirlenmiştir. VK-2 için önerilen algoritmanın sınıflandırma sonuçları Tablo 5'te verilmiştir.

Tablo 5. VK-2 için sınıflandırma sonuçları (Classification results for VK-2)

Sınıf	S1	S2	S3	S4	S5	S6	S7	S8	S9	Doğruluk (%)
S1	100	0	0	0	0	0	0	0	0	100
S2	0	91	0	7	0	0	0	2	0	91
S3	1	0	96	0	0	0	0	0	3	96
S4	0	7	0	93	0	0	0	0	0	93
S5	3	0	2	0	95	0	0	0	0	95
S6	0	0	3	0	0	97	1	0	0	97
S7	1	0	0	0	0	2	94	2	1	94
S8	0	3	0	0	0	0	1	96	0	96
S9	0	0	1	0	0	0	2	0	97	97
Ortalama başarımlar						95,44				

5.3. Başarım Karşılaştırması (Performans Comparison)

Önerilen algoritma kullanılarak VK-1 ve VK-2 veri kümeleriyle elde edilen sınıflandırma sonuçları, referans olarak değerlendirilen YSA sınıflandırıcı sonuçlarıyla karşılaştırılmıştır. Başarım karşılaştırmasında, eğitim süresi, test süresi ve sınıflandırma doğruluğu değerlendirme kriterleri olarak seçilmiştir. Karşılaştırma sonuçları Tablo 6'da verilmiştir.

Tablo 6. DVM'nin YSA sınıflandırıcısıyla karşılaştırılması (The comparison of SVM with ANN classifier)

Veri kümesi	Sınıflandırıcı	Eğitim süresi (s)	Test süresi (s)	Doğruluk (%)
VK-1	DVM	0,672	0,047	96,30
	YSA	20,03	0,032	95,21
VK-2	DVM	2,937	0,153	95,44
	YSA	55,89	0,032	95,11

Tablo 6'dan görüldüğü gibi, VK-1 ile yapılan sınıflandırma işleminde, DVM'nin sınıflandırma doğruluğu, YSA'nın doğruluğunu yaklaşık %1,1 oranında aşmıştır. Aynı zamanda DVM, eğitim aşamasını, YSA'ya göre yaklaşık 19,35 s daha önce gerçekleştirmiştir. DVM'de test aşaması YSA'ya göre daha uzun sürmesine rağmen algoritma içerisinde eğitim aşamasının ardından test aşamasına geçildiği

YSA ile sınıflandırma algoritması oluşturulurken en uygun ağ yapısını belirlemek için, ara katman sayısı, ara katmandaki nöron sayısı, etkinleştirme fonksiyonunun türü, öğrenme oranı, momentum değeri gibi farklı parametrenin belirlenmesi gerekmektedir. Tasarım aşamasında bu parametreleri belirlemek zaman kaybına yol açmaktadır. DVM sınıflandırıcıda ise düzenleme parametresi (C) ve çekirdek fonksiyonunun türüne bağlı çekirdek parametresi olmak üzere sadece iki veya üç değişkenin belirlenmesi gerekmektedir. Böylece, tasarım süreci kısalmış ve bunun sonucunda sonradan mimari üzerinde yapılabilecek her türlü değişiklik daha hızlı bir şekilde gerçekleştirilir. Bu durum DVM algoritmasının daha esnek bir yapıya sahip olduğunun bir göstergesidir.

Bu çalışmada, önerilen GKB sınıflandırma sisteminin sonuçları, literatürde yaklaşık aynı sayıda ve aynı modelleri kullanarak veri üreten GKB sınıflandırma çalışmalarının sonuçlarıyla karşılaştırılmıştır. Karşılaştırma, modele dayalı veri üretim yaklaşımını kullanan [9], [18] ve [22] 'nin çalışmalarının sonuçlarıyla yapılmıştır. Ayrıca, önerilen sistemin gürlütlü ortamlar için başarımını değerlendirmek amacıyla işaretlere, işaret/gürlütlü (İ/G) oranı 50 dB, 40 dB, 30 dB ve 20 dB olan dört farklı seviyede beyaz

Gaussian gürültü ilave edilmiştir. I/G , denklem (27)'deki eşitlik ile tanımlanmaktadır [24].

$$I/G(\text{dB}) = 10 \log \left(\frac{P_s}{P_n} \right) \quad (27)$$

Burada P_s işaretin, P_n ise gürültünün gücünü (varyansını) temsil etmektedir. Denklem (27)'den görüldüğü gibi, gürültü değeri arttıkça I/G değeri azalmaktadır. Dolayısıyla 20 dB en yüksek gürültü oranını belirtmektedir. Literatürde 30 dB'in, işaretin tepe değerinin genliğinde yaklaşık %3.5 oranında artışa eşdeğer bir gürültü olduğu bildirilmiştir [25]. Ayrıca, güç sistemlerinde %5'in üstündeki gürültü değerleriyle nadiren karşılaşılabileceği vurgulanmıştır [26].

Karşılaştırma sonuçları, gürültü ilave edilmemiş işaretler ve gürültü ilave edilmiş işaretler olmak üzere iki durum için verilmiştir. Burada, ADD-temelli özellik çıkarım işleminde, ayrıştırma seviyesi, örnekleme frekansına (12.8 kHz) bağlı olarak 10 seçilmiştir. Dolayısıyla, bu özellik vektörünün boyutu 400x11 olarak değişmiştir. Tablo 7, önerilen algoritmanın gürültülü ve gürültüsüz işaretler için elde edilen sınıflandırma sonuçlarını göstermektedir. Bu sonuçlara karşı, modele dayalı veri üretim yaklaşımı kullanarak GKB sınıflandırma yöntemi öneren çalışmaların sonuçları Tablo 8'de verilmiştir. Önerilen algoritmanın sınıflandırma sonuçlarında diğer çalışmalara göre doğru sınıflandırma oranının gürültüsüz işaretler için ortalama % 3.5, gürültülü işaretler için ise ortalama % 1.5 arttığı görülmüştür. Diğer çalışmalara göre doğru sınıflandırma oranındaki bu artışa, işaretin ayırt edici özelliklerini kaybetmeksizin veri boyutunu indirgeyen norm entropi özellik çıkarım yönteminin ve genelleme yeteneği yüksek DVM sınıflandırıcının sebep olduğu söylenebilir.

Tablo 7. Gürültü içeren ve içermeyen işaretler için sınıflandırma sonuçları (Classification results for noiseless and noisy signals)

Sınıf	Normal	50 dB	40 dB	30 dB	20 dB
S1	200	200	200	197	194
S2	184	179	171	164	161
S3	192	188	186	181	177
S4	185	181	174	168	165
S5	200	200	198	195	194
S6	200	200	198	193	191
S7	200	200	199	196	194
Başarım (%)	97,21	96,28	94,71	92,42	91,14

Tablo 8. Doğru sınıflandırma sonuçlarına göre başarımların karşılaştırılması (Performance comparison in terms of correct classification results)

GKB sınıflandırma çalışmaları	Sınıflandırma doğruluğu (%)				
	Normal	50 dB	40 dB	30 dB	20 dB
Kaynak [9]	90,42	-	-	-	-
Kaynak [23]	94,93	94,35	93,15	91,75	90,15
Kaynak [18]	95,71	95,14	93,64	91,85	89,92
Bu makale	97,21	96,28	94,71	92,42	91,14

TEŞEKKÜR (ACKNOWLEDGEMENTS)

Yazarlar, gerçek güç sistemi ölçüm verilerinin elde edilmesine yardımcı olan Güç Milli Kalitesi Projesi yürütücülerini ve bu proje kapsamında Tübitak Uzay bünyesinde araştırmacı olarak çalışan görevlilere teşekkür eder.

6. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, güç kalitesinde meydana gelen bozulmaların türünü belirlemek için örüntü tanıma yaklaşımlarına dayalı bir algoritma önerilmiştir. Önerilen yöntem, ADD'nin çoklu çözünürlük ayrıştırma katsayılarının norm entropi hesaplamasından elde edilen özelliklerin DVM sınıflandırıcıya giriş olarak uygulanmasına dayanır. ADD analizi ile durağan olmayan bir GKB işaretine birden çok perspektiften bakılarak elde edilen her bir işaret bileşeninin norm entropi değerleri hesaplanmıştır. Zaman bölgesinde 640 örnekten oluşan bir GKB işareti, ADD-Entropi özellik çıkarım yöntemiyle, sadece 9 örnekten oluşan bir özellik vektörü ile tanımlanmıştır. Özellik vektörünün boyutu az olmasına rağmen, GKB işaretlerini ayırt edebilme yeteneği oldukça yüksektir. Bu durum, özellik çıkarım algoritmasının sağlam temellere dayalı olduğunu göstermektedir. Ayrıca, özellik uzayının boyut olarak küçük olması, sınıflandırıcının karmaşıklığını ve dolayısıyla hesaplama süresini azaltacağı için GKB tanıma sistemini gerçek zamanlı uygulamalara daha uygun hale getirmektedir.


Bu çalışmada, farklı seviyelerde gürültüler, farklı frekans içerikli işaretler gibi bütün dinamik davranışları yapısında bulundurabilen VK-1 ile yapılan sınıflandırma işleminde, ortalama % 96,3 sınıflandırma başarımları elde edilmiştir. Bu sonuçlara göre önerilen algoritmanın herhangi bir gürültü ayrıştırma işlemi yapmadan, gerçek güç sisteminde meydana gelen bozulma işaretlerini yüksek bir doğrulukla tanıdığı görülmüştür. ATP/EMTP modellerinden elde edilen VK-2 ile yapılan başarımların değerlendirilmesinde, ortalama % 95,5 sınıflandırma başarımları elde edilmiştir. Önerilen bozulma tanıma sistemi, sınıf sayısının artmasına ve birden fazla bozulma işareti içermesine rağmen, doğru tanıma başarımlarını büyük oranda koruduğu görülmüştür.

Son olarak, sınıflandırma doğruluğunun yüksek ve hesaplama süresinin az olmasında kullanılan DVM sınıflandırıcının rolü çok büyüktür.

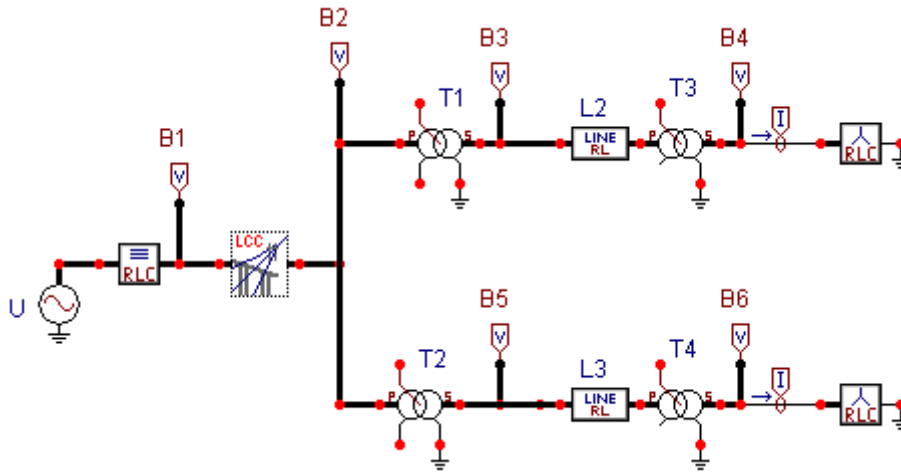
KAYNAKLAR (REFERENCES)

1. Dugan, R.C., Mcgranaghan, M.F., Santoso, S. ve Beaty, H.W., **Electrical Power Systems Quality**, McGraw-Hill, New York, 2002.
2. Gaouda, A.M., Salama, M.M.A., Sultan, M.R., Chikhani, A.Y., “Power “Quality Detection and Classification using Wavelet-Multiresolution Signal Decomposition”, **IEEE Trans. on Power Deliv.**, 14, 4, 1469-1476, 1999.
3. Güç Kalitesi Milli Projesi, <http://www.guckalitesi.gen.tr>.
4. Gaouda, A.M., **Wavelet-Automated Recognition System for Power Quality Monitoring**, Phd Thesis, University of Waterloo, 1999.
5. AbdelGalil, T., **Automated Recognition System for Power Quality Disturbances**, Phd Thesis, University of Waterloo, 2003.
6. Flores, R.A., “State of the Art in the Classification of Power Quality Events, an Overview”, **10th Int. Conf. Harmonics Quality of Power**, Rio de Janeiro, Brazil, 1, 17–20, 2002.
7. Perunicic, B., Mallini, M., Wang, Z., Liu, Y., “Power Quality Disturbance Detection and Classification using Wavelets and Artificial Neural Networks”, **8th Int. Conf. on Harmonics and Quality of Power**, Athens, Greece, 1, 77–82, 1998.
8. Liao, Y., Lee, J.-B., “A Fuzzy-Expert System for Classifying Power Quality Disturbances”, **International Journal of Electrical Power & Energy Systems**, 26, 3, 199-205, 2004.
9. AbdelGalil, T.K., Kamel, M., Youssef, A.M., El-Saadany, E.F., Salama, M.M.A., “Power Quality Disturbance Classification using the Inductive Inference Approach”, **IEEE Trans. Power Deliv.**, 19, 4, 1812–1818, 2004.
10. Strang, G., Nguyen, T., **Wavelets and Filter Banks**, Cambridge Press, Wellesley, 1996.
11. Cortes, C., Vapnik, V. N., “Support Vector Networks”, **Machine Learning**, 20, 3, 273-293, 1995.
12. Vapnik, V.N., **The Nature of Statistical Learning Theory**, Springer-Verlag, New York, 1995.
13. Schölkopf, B., Sung, K., Burges, C., Girosi, F., Niyogi, P., Poggio, T., Vapnik, V., “Comparing Support Vector Machines with Gaussian Kernels to Radial Basis Function Classifiers”. **IEEE Trans. on Signal Processing**, 45, 11, 2758–2765., 1997.
14. Keerthi, S.S., Lin, C.-J., “Asymptotic Behaviors of Support Vector Machines with Gaussian Kernel”, **Neural Computation**, 15, 7, 1667–1689, 2003.
15. Vapnik V.N., **The Nature of Statistical Learning Theory**, Second Edition, Springer Science, New York, 2000
16. Cristianini, N., Shawe-Taylor, J., **An Introduction to Support Vector Machines and Other Kernel-Based Learning Methods**, Cambridge University Press, New York, 2000.
17. Uyar, M., **Güç Kalitesindeki Bozulma Türlerinin Akıllı Örüntü Tanıma Yaklaşımları ile Belirlenmesi**, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2008.
18. Uyar, M., Yildirim, S., Gencoglu, M.T., “An Effective Wavelet-Based Feature Extraction Method for Classification of Power Quality Disturbance Signals”, **Electric Power Systems Research**, 78, 10, 1747–1755, 2008.
19. Türkoğlu, İ., **Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma**, Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2003.
20. Salor, Ö., Buhan, S., Ünsar, Ö., et.al., “Mobile Monitoring System to Take Nationwide PQ Measurements on Electricity Transmission Systems”, **Measurement**, 42, 501–515, 2009.
21. Dommel H.W., **Electromagnetic Transients Program. Reference Manual (EMTP theory book)**, Bonneville Power Administration, Portland, 1986.
22. Kizilcay, M., **Review of Solution Methods in ATP-EMTP**, EEUG News, 2001.
23. He, H., Starzyk, J.A., “A Self-Organizing Learning Array System for Power Quality Classification Based on Wavelet Transform”, **IEEE Trans. Power Deliv.**, 21, 1, 286–295, 2006.
24. Yang, H.T., Liao, C.C., “A De-Noising Schemes for Enhancing Wavelet-Based Power Quality Monitoring System”, **IEEE Trans. Power Deliv.**, 16, 7, 353–360, 2001.
25. Panigrahi, B.K., Sinha, S.K., “Detection and Classification of Non-Stationary Power Disturbances in Noisy Conditions”, **Power Electronics, Drives and Energy Systems PEDES’06**, New Delhi, India, 1–5, 2006.
26. Janik, P., Lobos, T., “Automated Classification of Power-Quality Disturbances using SVM and RBF Networks”, **IEEE Trans. on Power Deliv.**, 21, 3, 1663–1669, 2006.

EK-1 (APPENDIX-1)



Şekil E1.1. Örnek güç sisteminin tek hat şeması (One-line diagram of sample power system)



Şekil E1.2. Örnek güç sisteminin ATP modeli (ATP model of sample power system)

Line/Cable Data: C:\EEUGLCC\A2tipiLCC.atc

Model Data

System type: Overhead Line #Ph: 3

Standard data: Rho (ohm/m) 100, Freq. init (Hz) 0.005, Length (km) 80

Model Type: Bergeron, Decades 8, Points/Dec 5

Comment: 154 kV'luk hattın modeli

Line/Cable Data: C:\EEUGLCC\A2tipiLCC.atc

Model Data

#	Ph.no	Rin [cm]	Rout [cm]	Resis [ohm/km DC]	Horiz [m]	Vtower [m]	Vmid [m]
1	1	0	1.0885	0.1194	-6.8	18.845	18.845
2	2	0	1.0885	0.1194	0	18.845	18.845
3	3	0	1.0885	0.1194	6.8	18.845	18.845
4	0	0	0.472	2.61	-4.45	22.745	22.745
5	0	0	0.472	2.61	4.45	22.745	22.745

Şekil E1.3. L1 orta iletim hattının hat modeli ve parametreleri (Line model and parameters of L1 medium transmission line)

Tablo E1.1. L2 ve L3 kısa iletim hattı parametreleri (L2 and L3 short transmission line parameters)

İletim Hattı	Hattın Uzunluğu (km)	Gerilim Seviyesi (kV)	R (Ω /km)	L (mH/km)
L2	50	34.5	0.193	1.018
L3	20	34.5	0.193	1.018

TabloE1.2. Transformatör parametreleri (Transformer parameters)

Transformatör No	S _n (MVA)	U _{sn} (kV)	U _{pn} (kV)	R _p (Ω)	L _p (mH)	R _s (Ω)	L _s (mH)
Tr1 Tr2	40	154	34,5	11,85	452	1,19	30,30
Tr3 Tr4	1,5	34,5	0,4	0,892	22,73	0,00013	0,04