

Destek Vektör Makineler ve Dalgacık Dönüşümü Kullanarak Güç Sistemlerinde Geçici Rejim Bozulmalarının Sınıflandırılması

Hüseyin Erişti¹

Ayşegül Uçar²

Yakup Demir²

¹Tunceli Meslek Yüksek Okulu, Fırat Üniversitesi, Elazığ

²Elektrik Elektronik Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ

heristi@firat.edu.tr

agulucar@firat.edu.tr

ydemir@firat.edu.tr

Özetçe

Güç sistemlerinde önemli bir problem olan geçici rejim bozulmaları, meydana gelme olayına bağlı olarak; genlik, frekans ve süre değerlerine göre ayrı sınıflar altında incelenirler. Bu bildiride, Dalgacık Dönüşümleri (DD'ler), Destek Vektör Makineler (DVM'ler), İleri Beslemeli Yapay Sinir Ağları (İYSA'lar) ve Olasılıksal Sinir Ağları (OSA'lar) kullanılarak geçici rejim bozulmalarının sınıflandırılması için bir yaklaşım sunulmuştur. DD'ler ile sınıflayıcıların başarımını artırmak ve eğitim süresini azaltmak için özellik çıkarımı yapılarak giriş uzayının boyutu azaltılmıştır. Benzetim sonuçlarından DVM sınıflayıcının en yüksek başarımlı ürettiği gösterilmiştir.

1. Giriş

Güç sistemlerinde; kesicilerin açılıp kapanması, reaktör veya kapasitör bankalarının anahtarlanması, hatta ve yükte meydana gelen arızalar, yıldırım düşmesi, yüklerin hatalı işletilmesi, kısa süreli devreye bağlanması ve kararsızlığı gibi olaylar sonucunda geçici rejimler meydana gelir. Bunun sonucunda düşük elektrik güç kalitesine sebep olunur. Geçici rejim bozulmalarının nedenleri önceden bilinirse, gerekli önlemler hızlı biçimde alınarak güç kalitesinin iyileştirilmesi sağlanabilir. Yüksek frekansta ve genlikte meydana gelebilecek olan geçici rejimler, hattaki ve hat sonundaki elemanlar için problemler oluşturabilir. Bu nedenle güç sistemlerinde geçici rejimlerin tanımlanması ve sınıflandırılması önemli bir konuma sahiptir [1, 2].

Örüntü tanıma sistemleri öğrenme tabanlı olup, öğrendiklerinden çıkarım yaparak karar verebilmektedir. Örüntü tanıma çalışmalarının bir amacı da insan-makine arabirimini iyileştirmektir. Bu amaçla, olayların tanımlanması ve sağlıklı bir biçimde yorumlanabilmesi ana ilgi sahası olmuştur. İşaret örüntülerinin özellik çıkarımı, bu alandaki örüntü tanıma sistemlerinin en önemli bileşeni haline gelmiştir. İşaretin betimleyici özelliklerini elde etmek için, sadece zaman bölgesini kullanmak yerine, zaman ve frekans bölgelerinin ortak gösteriminden faydalanmak daha sağlam yapı sunar [2]. Dalgacık Dönüşümleri (DD'ler) günümüzde birçok mühendislik uygulamasında durağan ve durağan olmayan süreçlerin zaman-frekans gösterimlerinde başarılı sonuçlar veren, kullanışlı ve güçlü bir araçtır. Fourier dönüşümlerinin aksine, işaretin zamana bağımlı frekans değişim karakteristiklerini ölçmede güvenilirlikleri, durağan olmayan işaretlerin yapılarına uygun bir analiz şekli olduklarını göstermektedir. Çünkü DD'ler işaretin farklı bölümlerini analiz etmek için odağı ayarlanabilen matematik mikroskobu gibi davranabilirler. Bu yapısı ile DD'ler diğer yöntemlere seçenек bir yaklaşım olarak görülmektedir [3].

Destek Vektör Makineler (DVM'ler), deneysel riski enazlayan İleri Beslemeli Yapay Sinir Ağları (İYSA'lar) ve Olasılıksal Sinir Ağları (OSA'lar) gibi bilinen sınıflayıcıların aksine hem yapısal hem de deneysel enazladıkları için, test örnekleri üzerinde de eğitim örneklerininine yakın bir başarımlı sağlar. Düşük boyutlu giriş uzayındaki verileri, yüksek boyutlu diğer uzaya doğrusal olmayan bir biçimde taşıyarak doğrusal ayrıştırılabilir duruma getirir. En uygun doğrusal ayrıştırıcı düzlem olarak, ayrıştıran düzlemler arasından sınıflara uzaklığı en çok olan seçilir. Böylece tek bir çözümü olan en uygun sınıflayıcı oluşturulur. Temelleri istatistiksel öğrenme kuramına dayanan DVM'ler, örüntü tanıma problemlerinin çözümünde sağlam ve etkin bir yöntem olarak kullanılmaktadır [4].

Bu çalışmada güç sistemlerinde geçici rejim bozulmalarının sınıflandırılması için DVM'ler, İYSA'lar ve OSA'lar kullanılmıştır. İlk olarak geçici rejim verilerine DD ve enerji yöntemi [5] uygulanarak özellik çıkarımı yapılmış, daha sonra sınıflama işlemi gerçekleştirilmiştir. Elde edilen sonuçlar karşılaştırılmalı olarak sunulmuştur.

2. Geçici Rejim Bozulma Türleri

Bu bildiride normal sinüse ilave olarak, güç sistemlerinde geçici rejim bozulmalarını gösteren 4 farklı türü daha seçilerek sınıflama problemi oluşturulmuştur. Bu türler aşağıda belirtilmiş ve tanımlanmıştır. [6,7]. Her bir sınıfa ait birer veri Şekil 1'de gösterilmiştir.

Sınıf 1: Normal sinüs (S1),

Sınıf 2: Çökme (S2),

Sınıf 3: Sıçrama (S3),

Sınıf 4: Kesinti (S4),

Sınıf 5: Salımlı geçici rejim (S5).


Çökme: Şebeke frekansında, 10 ms'den fazla (0.5 periyot) ve 1 dakikadan az olmak kaydıyla nominal gerilim veya akımın etkin değerinin %10 - %90 arasında azalma göstermesi olarak tanımlanır. Gerilim çökmeleri, genellikle sistem arızalarına bağlıdır. Ayrıca büyük yüklerin devreye girmesi veya büyük güçlü motorların çalışması esnasında da meydana gelebilmektedir.

Sıçrama: Şebeke frekansında, 10 ms'den fazla (0.5 periyot) ve 1 dakikadan az olmak kaydıyla nominal gerilim veya akımın etkin değerinin %110 - %180 arasında artış göstermesi olarak tanımlanmaktadır. Gerilim çökmesinde olduğu gibi, gerilim sıçramaları da genellikle sistem arızalarına bağlıdır. Fakat gerilim sıçramaları, gerilim çökmeleri kadar yaygın olarak görülmezler. Örneğin, bir tek faz-toprak kısa devre arızası

esnasında, arızasız fazlar üzerinde meydana gelen geçici gerilim artışı, sıçrama oluşmasının en önemli sebeplerinden biridir.

Kesinti: Kaynak gerilimi veya yük akımının etkin değerinin, 1 dakikayı aşmayan bir süre boyunca %10'un altına düşmesi sonucu meydana gelmektedir. Kesintiler, güç sistemi arızaları, ekipman arızaları ve kontrol sistemlerinin yanlış çalışması sonucu meydana gelebilmektedir. Kesinti esnasında, gerilimin genliği daima nominal gerilimin %10'unun altına düştüğünden kesintiler sürelerine göre değerlendirilir.

Salınlı geçici rejim: Akım, gerilim veya her ikisinin sürekli durum şartlarında meydana gelen ve hem pozitif hem de negatif değerler alan anlık değişimleri olarak tanımlanır. Salınlı geçici rejimler, ani değerleri hızlı bir şekilde kutuplarını değiştiren, akım ve gerilimlerden oluşmuştur. Bu geçici rejimler, frekans spektrumu, devamlılık süresi ve genlik değerleri ile ifade edilirler.



Şekil 1: Normal sinüs ve geçici rejim bozulma türleri

3. Dalgacık Dönüşümü ve Özellik Çıkarımı

DD, işaretin ölçeklenebilir bir zaman-frekans gösterimi ile analizini sağlar ve geleneksel işaret işleme teknikleri tarafından görülmeyen detayları meydana çıkarır. Kısa zamanlı Fourier dönüşümün sınırlamalarından biri olan, kullanılan pencerenin sabit olması DD'de ölçeklenebilir bir pencere ile giderilmiştir. Böylece işaret içindeki düşük frekans eğilimlerini açmak için geniş bir pencere, yüksek frekans detaylarını analiz etmek için sıkıştırılmış bir pencere kullanılır. Bunun için, DD ölçeklenebilir temel bir dalgacık işlevi kullanıp sabit çözünürlük problemine çözüm getirerek, işaretin farklı çözünürlüklerde daha esnek bir zaman bölgesi analizini yapar [3].

Dalgacık katsayılarını her olası ölçek için hesaplamak çok fazla işlem yapmayı gerektirir ve bunun sonucunda da çok fazla veri elde edilir. Bunun yerine 2'nin katlarını temel alacak şekilde ölçekler ve ötelemeler seçilirse, yapılacak analizler çok daha etkindir. Dalgacık katsayılarını hesaplamada kullanılan bu tekniğe Ayrık Dalgacık Dönüşümü (ADD) denilmektedir. Sürekli dalgacık dönüşümü sonsuz sayıda girişe ihtiyaç duyduğundan bilgisayar analizi için uygun değildir. Bilgisayar analizleri için (1)'de verilen ADD kullanılır.


$$ADD(m, n) = 2^{-m/2} \int f(t) \psi(2^{-m}t - n) dt \quad (1)$$

Burada m frekansı, n ötelemeyi (zamanı), f(t) sinyali ve $\Psi(t)$ dalgacığı belirtmektedir.

Ayrıştırma işlemi Şekil 2'de gösterildiği gibi birçok kez yapılabilir. Böylece, incelenecek işaret daha az çözünürlüklü birçok alt bileşenine ayrılacaktır. Buna çok çözünürlüklü ayrıştırma denir. Bu ayrıştırma işleminde ayrıştırmanın özini olmasından dolayı, teoride bu işlem sınırsız olarak devam ettirilebilir. İşaretin alçak ve yüksek geçiren filtreler yardımıyla alt bant frekans bileşenlerine (yaklaşık ve detaylarına) ayrılması olayı Şekil 2'de gösterilmiştir. İncelenen işaret (S), örneğin üçüncü seviyede yaklaşık ve detay bileşenleri cinsinden ifade edilmek istenirse (2)'deki gibi ifade edilebilir:

$$S = a_3 + d_3 + d_2 + d_1 \quad (2)$$

Burada; d1, d2, d3 her seviyenin detay katsayılarını, a3 ise yaklaşık katsayısını temsil etmektedir [2, 3, 5].



Şekil 2: Üç seviyeli dalgacık çözünürlük ağacı

Bir örüntü tanıma sisteminde en önemli aşama özellik çıkarımıdır. Özellik çıkarımının yapılmasındaki en önemli amaç ölçüm veya örnek uzayında daha küçük boyuta düşürmeyi sağlamaktır. Bu şekilde sınıflandırıcı daha küçük hatalar ile eğitimi ve karar aşamasını daha kısa sürede gerçekleştirir. Özellik çıkarımı işleminde yaygın olarak kullanılan yöntem enerji hesaplamasıdır. İşaret işleme işlevi çıkışından elde edilen, her bir seviyenin detay ve yaklaşık katsayıları için enerji hesaplama işlemi yapılır. Böylece sınıflandırıcının girişini oluşturan özellik vektörü elde edilir. Her bir seviyeye ait enerji,

$$ED_i = \sum_{j=1}^N |D_{ij}|^2 \quad i = 1, 2, \dots, \ell \quad (3)$$

$$EA_\ell = \sum_{j=1}^N |A_{\ell j}|^2 \quad (4)$$

ile hesaplanır. Burada ℓ dalgacık dönüşüm seviyesini, N her bir seviyedeki yaklaşık ve detay katsayılarını, ED_i detay katsayılarının enerjisini ve EA_i ise yaklaşık katsayılarının enerjisini göstermektedir [5].

4. Öğrenme Algoritmaları

4.1. Destek Vektör Makineleri

DVM'ler, verileri yüksek boyutlu uzaya taşıyarak, o uzayda (5) ile verilen düzlemi oluşturup sınıflama yapmak üzere tasarlanmıştır,

$$d(x) = w^T \phi(x) + b. \quad (5)$$

Burada $w \in \mathcal{R}^n$ ve $b \in \mathcal{R}$ çok boyutlu düzlemi oluşturan parametreler ve $\phi(x)$ verileri giriş uzayından yüksek boyutlu uzaya dönüştürmek için kullanılan dönüşüm işlevidir [2, 4].

DVM'ler, (6) ile verilen birincil eniyileme problemini çözerek eğitim hatasını (birinci terim) ve genelleme hatasını (ikinci terim) aynı anda enazlar.

$$L(w, \xi_i) = \frac{C}{L} \sum_{i=1}^L \xi_i + \frac{1}{2} \|w\|^2 \quad (6)$$

$$y_i [w^T \phi(x_i) + b] \geq 1 - \xi_i, \quad \xi_i \geq 0. \quad (7)$$

Burada L eğitim örneklerinin sayısını, C genelleme ve eğitim hatası arasındaki ödünleşimi nitelemektedir, ξ_i ise $w^T \phi(x_i) + b$ ve y_i arasındaki mutlak hatayı göstermektedir. (6)'daki ikinci teriminin enazlanması, öz nitelik uzayında zıt sınıfın iki en yakın verisi arasındaki mesafe olarak bilinen payın ençoklanması karşılık gelir. Genellikle verileri yüksek boyutlu uzaya dönüştüren $\phi(x)$ bilinmediğinden, hesaplamalarda kolaylık sağlamak için veriler bu işlevi kullanmadan bir çekirdek yardımıyla örtük olarak yüksek boyutlu uzaya taşınır. Bu amaçla birincil eniyileme problemi, Lagrange çarpanları yöntemi kullanarak ikincil forma çevrilir.

$$L_{ikincil}(\lambda) = -\frac{1}{2} \sum_{i,j=1}^L \lambda_i \lambda_j y_i y_j K(x_i, x_j) + \sum_{i=1}^L \lambda_i \quad (8)$$

$$\text{kısıtları: } \sum_{i=1}^L y_i \lambda_i = 0,$$

$$0 \leq \lambda_i \leq \frac{C}{L}, \quad i = 1, \dots, L. \quad (9)$$

Burada; λ_i Lagrange çarpanlarını ve $K(x_i, x_j)$ çekirdeği $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ ile hesaplanan iç çarpımı göstermektedir.

Sonuç karar işlevi ise çekirdek ve Lagrange çarpanları kullanarak

$$d(x) = \text{sign} \left(\sum_{\text{destek vektörler}} y_i \lambda_i K(x_i, x_j) + b \right) \quad (10)$$

ile hesaplanır. Burada; destek vektörler $\lambda_i > 0$ Lagrange çarpanlarına karşılık gelen x_i değerlerini göstermektedir [4].

4.2. Olasılıksal Sinir Ağları

OSA'lar Bayes sınıflandırıcılar gibi olasılıksal modele sahip olan denetleyicili öğrenme algoritmasının bir türüdür. OSA'nın öğrenme süresi İYSA'lardan daha kısadır. Eğitim örnekleri, OSA'nın temel prensibi olan olasılıksal yoğunluk

işlevinin dağılım değerine göre sınıflandırılır. (11) bağıntısı ile verilen basit bir olasılıksal yoğunluk işlevi,

$$f_k(X) = \frac{1}{L_k} \sum_{j=1}^{L_k} \exp \left(-\frac{\|X - X_{kj}\|^2}{2\sigma^2} \right) \quad (11)$$

OSA'nın H gizli katmanında kullanılırsa,

$$H_h = \exp \left(\frac{-\sum_i (X_i - w_{ih}^{xh})^2}{2\sigma^2} \right) \quad (12)$$

Y çıkış vektörü,

$$\text{net}_j = \frac{1}{N_j} \sum_h w_{hj}^{hy} H_h \quad \text{ve} \quad M_j = \sum_h w_{hj}^{hy} \quad (13)$$

$$\text{net}_j = \max_k (\text{net}_k) \text{ ise } y_j=1, \text{ değil ise } y_j=0$$

olarak elde edilir [8]. Burada i , h ve j sırasıyla giriş, gizli ve çıkış katman sayılarını, k eğitim örneklerinin sayısını, M_k sınıfların sayısını, σ düzeltme katsayısını (standart sapmayı), X giriş vektörünü göstermektedir. $\|X - X_{kj}\|$, X_{kj} ve X arasındaki Euclidean uzaklığı tanımlanmaktadır.

4.3. İleri Beslemeli Yapay Sinir Ağları

İYSA'lar bir giriş, bir veya daha fazla gizli ve bir de çıkış katmanından oluşmaktadır. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemlerdeki giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunur. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme dayanılarak belirlenir. Y_j çıkışı (14)'de gösterilen giriş katsayıları ile ağırlıkların çarpımına ait toplamın bir doğrusal olmayan f aktivasyon işlevinden geçirilmesi ile elde edilir. Doğrusal, sigmoid, hiperbolik tanjant ve radyal tabanlı işlevler yaygın olarak kullanılan aktivasyon işlevleridir [9],


$$Y_j = f \left(\sum_i w_{ji} X_i \right). \quad (14)$$

5. Uygulamalar

Bu bildiride, DD ile dönüşümüyle özellik çıkarma ve öğrenme algoritmaları ile sınıflama için belirlenen sınıflara ait veriler [5, 10]'da verilen parametrik denklemler vasıtasıyla üretilmiştir. Bu denklemlerde genlik, frekans ve süreler ait parametreler verilen aralıklarda rasgele olarak seçilerek her bir sınıf için 1000 veri üretilmiştir. Bu veriler toplam 16 periyot sürmekte ve her bir periyot 256 örnekten oluşmaktadır. Eğitim ve test aşaması için 200 örnek elde edilmiştir. Bu veriler DD ve enerji yöntemi uygulanarak özellikleri çıkarılmıştır. Bu özelliklere göre eğitim ve test işlemleri yapılmıştır.

Örüntü tanıma için yapılan işlemlere ait model Şekil 3'de görülmektedir. Bu model, DD, enerji hesaplaması ve öğrenme algoritmasından oluşmaktadır. Bu bildiride öğrenme algoritması olarak DVM'nin çok fazla veri içeren

problemlerde hızlı ve etkin bir çözüm sunan DVMLight algoritması [11], OSA ve YSA'lar kullanılmıştır. Tüm hesaplamalar ve benzetimlerde MATLAB ile yapılmıştır.



Şekil 3: Örüntü tanıma modeli

Şekil 3'deki modele göre incelenen 5 sınıfa ait giriş işaretlerinin toplam boyutu 1000x4096'dır. Özellik çıkarma işlemi sonucunda bu boyut 1000x14'e indirgenerek sınıflama işlemi yapılmıştır. Bilimsel yazında bu sınıflara ait bozulmaların özellik çıkarma işlemi için 13 seviyeli DD'nin en uygun seviye olduğu ifade edilmiştir [8]. Bu seviyede yapılan dönüşümde ilk sekiz seviyeye kadar yüksek frekans özelliği, sonraki seviyelerde ise alçak frekans özelliği gösterir.

Tablo 1: DVM, YSA ve OSA test aşaması sonuçları

DVM YSA OSA	S1	S2	S3	S4	S5
S1	200 200 200	0 0 0	0 0 0	0 0 0	0 0 0
S2	1 0 0	172 168 170	1 0 2	25 32 30	1 0 0
S3	1 1 3	0 0 0	199 199 197	0 0 0	0 0 0
S4	0 0 0	14 25 47	0 0 0	186 175 153	0 0 0
S5	9 4 23	0 0 0	0 1 0	2 0 0	189 195 177
Toplam Başarım:	DVM % 94.6	YSA % 93.7	OSA % 89.7		

Sınıflama işleminde DVMLight için RTİ çekirdek kullanılmıştır. Çekirdek parametresinin değeri 2.12 ve C parametresi değeri de 2000 olarak seçilmiştir. YSA'nın yapısında 18 gizli katman nöronu ve 5 çıkış katman nöronu kullanılmıştır. Çıkış katmanında [1 0 0 0], [0 1 0 0], [0 0 1 0], [0 0 0 1] ve [0 0 0 0] mantığı ile sınıflama işlemi yapılmıştır. Öğrenme yöntemi olarak Levenberg-Marquardt yöntemi seçilmiştir. OSA'nın yayılma parametresi için 0.018 değeri seçilmiştir. Elde edilen sınıflama sonuçları Tablo 1'de verilmiştir.

6. Sonuçlar

Bu bildiriye, güç sistemlerinde meydana gelen; çökme, sıçrama, kesinti ve salınımlı geçici rejim bozulmalarının tespiti sınıflama problemi olarak oluşturulmuştur. Sınıflayıcı olarak DVM'ler, İYSA'lar ve OSA'lar kullanılmıştır. Sınıflara ait verilere DD ve enerji yöntemi uygulanarak özellik vektörü elde edilmiştir. Böylece belirli bir periyotta veya sürede meydana gelen örneklerin kendi sınıfına ait özellikleri çıkarılarak, sınıflama işlemi için daha az veri girişi sağlanmış ve sınıflayıcıların iyi bir başarımla yakaladığı gözlemlenmiştir. Yapılan sınıflama işlemi sonucunda en iyi başarımla DVM ile elde edilmiştir. Ayrıca güç sistemlerinde yapılan benzer sınıflama işlemleri için DVM ile en iyi örüntü tanıma işlemi yapılabileceği sonucuna varılmıştır.

7. Kaynakça

- [1] Chen, J., Kinsner, W. ve Huang, B., "Power System Transient Modeling and Classification", IEEE Canadian Conference on Electrical & Computer Engineering, 184-189, 2002.
- [2] Erişti, H., "Destek Vektör Makineleriyle Geçici Rejim Bozulmalarının Sınıflandırılması", Doktora Semineri F.Ü. Fen Bil. Enst., 2007.
- [3] Türkoğlu, İ., "Durağan Olmayan İşaretler İçin Zaman-Frekans Entropilerine Dayalı Akıllı Örüntü Tanıma", Doktora Tezi, F.Ü. Fen Bil. Enst., 2002.
- [4] Uçar, A., "Destek Vektör Makine Tabanlı Bulanık Sistemler, Yeni Bir Gürbüz Sınıflayıcı ve Regresör Tasarımı", Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, 2006.
- [5] He, H. ve Starzyk, J. A., "A Self-Organizing Learning Array System for Power Quality Classification Based on Wavelet Transform", IEEE Trans. on Power Delivery, 21(1):286-295, 2006.
- [6] IEEE Std. 1159, IEEE Recommend Practice for Monitoring Electric Power Quality, 1995.
- [7] Dugan, R. C., Mcgranaghan, M. F., Santoso, S. ve Beaty, H. W., Electrical Power Systems Quality, McGraw-Hill, New York, 2002.
- [8] Gaing Z. L. ve Huang H.S., "Wavelet-Based Neural Network for Power Disturbance Classification", IEEE Power Engineering Society General Meeting, 3, 1621-1628, 2003.
- [9] Acir, N., "Classification of ECG Beats by Using a Fast Least Square Support Vector Machines with a Dynamic Programming Feature Selection Algorithm" Springer-Verlag London, Neural Comput & Applic, 14, 299-309, 2005.
- [10] Abdel-Galil, T. K., Kamel, M., Youssef, A. M., El-Saadany, E. F. ve Salama, M. M. A., "Power Quality Disturbance Classification Using the Inductive Inference Approach", IEEE Trans. on Power Delivery, 19, 4, 1812-1818, 2004.
- [11] Joachims, T., "Making Large-Scale Support Vector Machine Learning Practical", In Schölkopf, B., Burges, C. ve Smola, A. editors, Advances in Kernel Methods - Support Vector Learning, MIT Press, 169-184, 1999.