

Destek Vektör Makineleri Tabanlı Hedef Takip Yöntemleri

Support Vector Machines Based Target Tracking Techniques

Sedat Özer¹, Hakan A. Çırpan¹ ve Nihat Kabaoğlu²

¹Elektrik ve Elektronik Mühendisliği Bölümü
İstanbul Üniversitesi, Avcılar, İstanbul
{sedat,hcirpan}@istanbul.edu.tr
²Teknik Bilimler Meslek Yüksek Okulu
Kadir Has Üniversitesi, Selimpaşa, İstanbul
nihat@khas.edu.tr

Özetçe

Bu makalede çekirdek tabanlı, güçlü istatistiksel örüntü sınıflandırma algoritmalarının hedef takibinde kullanılması amaçlanmaktadır. Direk bir tanımlayıcı olarak uygulamak yerine, Destek Vektör Makineleri Bağlanım şekli kullanılarak bir konum belirleyici sunulmuştur. Önerilen yöntemde dinamik modellemeyle beraber özellik vektörleri sunulmuş, ve hiperdüzlem ve dolayısıyla da destek vektörlerin, bu özelliklerdeki değişiklikleri takip etmeleri sağlanmıştır. Önerilen takipçinin başarımı bir sensor ağ senaryosunda, polinom tabanlı bir rotada ilerleyen bir hedef üzerinde gösterilmiştir.

Abstract

This paper addresses the problem of applying powerful statistical pattern classification algorithms based on kernels to target tracking. Rather than directly adapting a recognizer, we develop a localizer directly using the regression form of the Support Vector Machines (SVM). The proposed approach considers using dynamic model together as feature vectors and makes the hyperplane and the support vectors follow the changes in these features. The performance of the tracker is demonstrated in a sensor network scenario with a moving target in a polynomial route.

1. Giriş

Destek Vektör Makineleri (DVM) 1970'lerin sonlarında sunulmuş, istatistiksel makine öğrenimine dayalı işlev yaklaşılama yöntemidir [1-2]. Formülasyonu, yapısal risk enküçültmesi prensibine dayanmaktadır. Çekirdek işlevi eşleşmesi yönteminin kullanımı ile DVM'ler, kısa uzunluklu veriler üzerinde de iyi bir sınıflama genelleştirme sağlayabilir [3-5]. Ayrıca, DVM'ler özellikle son yıllarda pek çok çekici özelliği ile teorik ve mühendislik uygulamalarında büyüyen bir ilgi görmektedir. Model tanıma, izole edilmiş el yazısı tanıma, nesne tanıma, ses tanıma, görüntüde yüz arama ve yazı karakterize etme gibi konularda ve ayrıca regresyon, işlev kestirimi alanlarında kullanılmaktadır [10,11].

Ardışık Monte Carlo ve ilgili parçacık filtreleme yöntemlerinde son yıllarda ortaya çıkan önemli gelişmeler, bu yöntemlerin hedef takibi uygulamalarında kullanılmasına imkân tanımaktadır [9]. Ancak, ardışık Monte Carlo yöntemleri kullanılması durumunda özyineli veri ve ölçüm

ifadelerine (durum uzay modellemesi) ihtiyaç duyulmasından ötürü alternatif yaklaşımların sunulması gerekmektedir. Özellikle DVM yaklaşımı, Monte Carlo yöntemlerinde üretilen veri setindeki bilginin daha az sayıda destek vektörü ve DVM'e ait çekirdek işlevi ile ifade edilmesini sağlar [1,4,7]. Bu nedenle, bu çalışmada hedef takibi probleminin çözümü için DVM tabanlı bir yaklaşım sunulmaktadır. Önerilen bu yaklaşım ile DVM'lerin işlev yaklaşılama özelliğinden faydalanarak hedefe ait durum vektörü elde edilmektedir.

2. Destek Vektör Makineleri

DVM her ne kadar sınıflandırma amaçlı tasarlanmış olsa da, günümüzde artık birçok uygulamada bağlanım amaçlı da kullanılmaktadır.

DVM bağlanımında farklı türden yitim işlevleri kullanılabilir. Bunlar:

- 1) ε - Duyarsız Yitim İşlevi
- 2) Karesel Yitim İşlevi
- 3) Laplace Yitim İşlevi
- 4) Huber Yitim İşlevi

olarak listelenebilir [4,7].

ε - Duyarsız Yitim İşlevi şu şekilde tanımlanır:

$$Y_{\varepsilon}(\mathbf{y}) = \begin{cases} 0 & , |f(\mathbf{x}) - \mathbf{y}| < \varepsilon \\ |f(\mathbf{x}) - \mathbf{y}| - \varepsilon & , |f(\mathbf{x}) - \mathbf{y}| \geq \varepsilon \end{cases} \quad (1)$$

Doğrusal bağlanım yaparken DVM, girilen

$$D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}; \mathbf{x} \in R^m, y \in R$$

D verileri ile eğitildikten sonra,

$$f(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle + b \quad (2)$$

olarak tanımlanan lineer bir işlev oluşturulur. Bu işlevin doğrusal olması için \mathbf{w} değerlerinin mümkün olduğunca küçük olması gerekir. Bu durumda problem

$$\phi(\mathbf{w}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i^n (\xi_i^- - \xi_i^+) \quad (3)$$

Bu çalışma 104E130 numaralı TÜBİTAK araştırma projesi tarafından desteklenmektedir.

olarak tanımlanan ϕ işlevinin enküçüklenmesi problemine dönüşür. Burada C önceden tanımlanan bir değerdir ve düzlemin doğruluğu ile, göz ardı edilen ε değerlerinden daha büyük hata değerleri arasındaki dengeyi sağlar. ξ ise çıkışın alt ve üst sınırlarını belirleyen esnek bir değişkendir. Burada enküçükleme işlemi yapılırken

$$\begin{cases} y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle - b \leq \varepsilon + \xi_i \\ \langle \mathbf{w}, \mathbf{x}_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

koşulları da sağlanmalıdır.

Bu doğrultuda, yukarıdaki kısıtlamaların Lagrange çarpanları şeklinde ϕ işlevine ilave edilmesiyle elde edilen ikincil denkleminin enküçüklenmesi, bize $f(\mathbf{x})$ işlevinde tanımlanan \mathbf{w} değerlerini verir. Bu noktada da problem, bir optimizasyon problemine dönüşür [4-6]:

$$\begin{aligned} L := & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i^n (\xi_i + \xi_i^*) \\ & - \sum_{i=1}^n \alpha_i (-y_i + \langle \mathbf{w}, \mathbf{x}_i \rangle + b + \xi_i + \varepsilon) \\ & - \sum_{i=1}^n \alpha_i^* (y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle - b + \xi_i^* + \varepsilon) \\ & - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*) \end{aligned} \quad (4)$$

Burada $\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0$ koşulu da sağlanmalıdır.

L işlevin $\mathbf{w}, b, \xi_i, \xi_i^*$ ilk değerlerine göre kısmi türevlerinin alınması, bizi enuygun sonuca götürecektir. Bu durumda

$\mathbf{w} = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \mathbf{x}_i$ elde edilir. Son durumda $f(\mathbf{x})$ işlevi şu hali alır:

$$f(\mathbf{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle \mathbf{x}_i, \mathbf{x} \rangle + b \quad (5)$$

Bu ifade Destek Vektör Açılımı olarak ifade edilir. Burada \mathbf{w} vektörü, sadece girilen eğitici verilerin doğrusal bir kombinasyonu olarak ifade edilir. Eğitici veriler arasında $(\alpha_i - \alpha_i^*)$ katsayısı sıfırdan farklı olan değerlere Destek Vektörleri denilir. (5) işlevinde bulunması gereken bir diğer değer olan b ise farklı şekillerde hesaplanabilir. Önerilen yöntem:

$$b = \begin{cases} y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle - \varepsilon, \alpha_i \in (0, C) \\ y_i - \langle \mathbf{w}, \mathbf{x}_i \rangle + \varepsilon, \alpha_i^* \in (0, C) \end{cases} \quad (6)$$

Doğrusal olmayan DVM bağlanımında ise, Mercer koşullarını sağlayan ve simetrik kesin pozitif olan "Çekirdek İşlevleri" kullanılarak doğrusal olmayan sistemin doğrusal olan bir uzaya dönüştürülmesi sağlanır. Yüksek derecede boyuta sahip

olan bu uzayda yapılacak her iç çarpıma denk gelen bir çekirdek işlevi, mevcut uzayda tanımlıdır [5-8]:

$$K(\mathbf{x}, \mathbf{x}') = \langle \phi(\mathbf{x}), \phi(\mathbf{x}') \rangle \quad (7)$$

Çekirdek işlevi için aşağıdaki işlevler örnek olarak verilebilir:

1. Polinom İşlevler

$$K(\mathbf{x}, \mathbf{x}') = \langle \mathbf{x}, \mathbf{x}' \rangle^d \quad (8a)$$

veya

$$K(\mathbf{x}, \mathbf{x}') = (\langle \mathbf{x}, \mathbf{x}' \rangle + 1)^d \quad (8b)$$

2) Gauss Radyal Tabanlı İşlevler

$$K(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\sigma^2}\right) \quad (9)$$

3) Çok Katmanlı Algılayıcı İşlevler

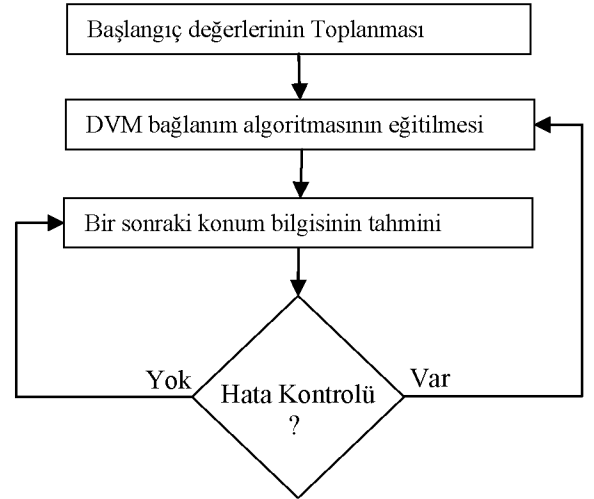
$$K(\mathbf{x}, \mathbf{x}') = \tanh(\rho \langle \mathbf{x}, \mathbf{x}' \rangle + \varepsilon) \quad (10)$$

4) Spline İşlevler

$$K(\mathbf{x}, \mathbf{x}') = 1 + \langle \mathbf{x}, \mathbf{x}' \rangle + \frac{1}{2} \langle \mathbf{x}, \mathbf{x}' \rangle \min(\langle \mathbf{x}, \mathbf{x}' \rangle) - \frac{1}{6} \min(\langle \mathbf{x}, \mathbf{x}' \rangle)^3 \quad (11)$$

3. Algoritma

Bu çalışmada benzetim örnekleri için kullanılan algoritmaya ilişkin akış şeması Şekil 1' de verilmiştir.



Şekil 1: Kullanılan algoritmaya ilişkin akış şeması

Verilen bir dizi DVM vektör değeri kullanılarak, bu vektörü oluşturan sistemdeki değişiklerin çıkarımı için, durum değişimleri iki aşamada elde edilir. İlk aşamada (2) denkleminde göre, eğitici veriler girilerek destek vektörleri ve

dolayısıyla w değerleri tanımlanır. İkinci aşamada ise bu destek vektörleri kullanılarak oluşturulan bağnım fonksiyonu kullanılarak sistem dinamiğindeki değişiklikler kestirilir.

Bu noktada, her bir durum vektörü için ayrı bir SVM çalıştırılmıştır.

3.1. Başlangıç Değerlerinin Toplanması

DVM algoritmanın başlatılabilmesi için eğitici veriye ihtiyaç duyulur. Bu noktada, ilk gelen veri ile hemen eğitim işlemine de geçilebileceği gibi, sistemi karakterize edecek en küçük sayıda verinin toplanması da beklenerek bu değerden sonra eğitim işlemi başlatılabilir. Bizim uygulamamızda ilk 5 değer gelmesi beklenmiş ve daha sonra sistem bu değerleri kullanarak eğitilmiştir.

3.2. DVM Bağlanım Algoritmasının Eğitilmesi

Bu noktada DVM, öncelikle giriş ve çıkış verilerine göre Destek Vektörleri bulur ve sonra da bu vektörler yardımıyla w ve b bilinmeyenleri bulur. Bu değerlerle (5) denkleminde uygun olarak $f(x)$ işlevi üretilir. Buna göre mevcut verilerden faydalanarak, önceki değerler ile sonraki değerler arasındaki ilişkiyi kurarak sistemi karakterize etmiş olan DVM, bir sonraki konumu kestirmeye hazır hale gelmiş olur..

3.3. Konum Tahmini ve Hata Kontrolü

Destek vektörleri (5) denkleminde kullanılarak, yeni girilen değerlere sistemin vereceği cevap kestirilir, bu durumda eğer kestirilen veri, bir sonra gözlenen hatadan farklı ise sistem son gelen veri ile yeniden eğitilir.

4. Benzetim Örneği

Şekil 2, Şekil 3, Şekil 4, Şekil 5 ve Şekil 6` da farklı çekirdek fonksiyonları için takip sonuçları verilen benzetim örneğinde, sırayla x ve y eksenleri üzerinde, doğrusal olmayan, $x = 4t^3 - 2t^2 + 0.7$ ve $y = 2t^2 + 0.5$ denklemlerine uygun olarak hareket ettiği varsayılan bir cismin şu andaki konumunun, önceki gözlem verilerinden faydalanarak tahmin edilmesi sağlanmıştır. Burada t zamanı ifade eder. Kullanılan DVM`de çekirdek işlevi olarak Polinom, Spline ve Radyal tabanlı işlevler kullanılmıştır. Her bir çekirdek ile elde edilen sonuçlar farklı parametreler doğrultusunda sunulmuştur.

Başlangıç noktası (0,0) olan ve sürekli çizgi boyunca yol aldığı varsayılan cisim için beyaz gürültü eklenen gözlem değerleri kullanılmış ve tahmin değerleri (+) ile gösterilmiştir.

5. Sonuçlar

Bu çalışmada bağlanım özelliğinden faydalanılarak önerilen DVM tabanlı hedef takip yönteminin farklı çekirdek fonksiyonları için başarımlı incelenmiştir. Elde edilen ilk benzetim sonuçları doğrultusunda aşağıdaki çıkarımlar sıralanabilir:

- DVM kullanımında, her ne kadar uygun parametre ile Radyal tabanlı çekirdekler en iyi fonksiyon yaklaşımını sunuyormuş gibi görünseler de hedef takibi konusunda yetersiz kalmaktadırlar. Şekil 4`de

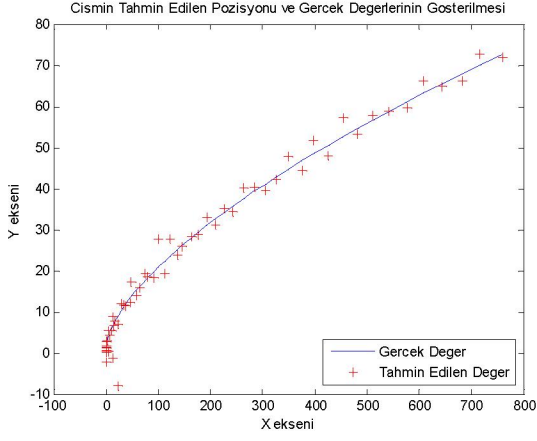
gösterildiği üzere tahmin edilen değerler, fonksiyon üzerinde başlangıç noktasına doğru sıkışmaktadır.

- Polinom tabanlı çekirdekler ise Şekil 6` da gösterildiği üzere iyi sonuçlar vermelerine rağmen, optimizasyon aşamasında simetrik kesin pozitif tanımlı matris sorunları ile daha kolay karşılaşmaktadırlar.
- Spline çekirdekler ise, uygulamamızda, Polinom çekirdeklere oranla daha iyi sonuçlar vermemekle birlikte optimizasyon aşamasında, polinom çekirdeklere oranla daha kararlı bir kullanım olanağı sundukları gözlenmiştir.
- Hedef takibinde, DVM fonksiyon yaklaşıklığı kullanımı, hedefin dinamik karakteristiği hakkında edinilecek ön bilgi, buna bağlı olarak uygun çekirdek ve uygun çekirdek değişkenlerini seçerek yapılabilir. DVM kullanarak kestirilen konum, daha az veriye ihtiyaç duymaktadır. Böylece bellek sorunu ile karşılaşılacak durumlarda DVM kullanımını uygun bir seçenek olarak karşımıza çıkmaktadır.

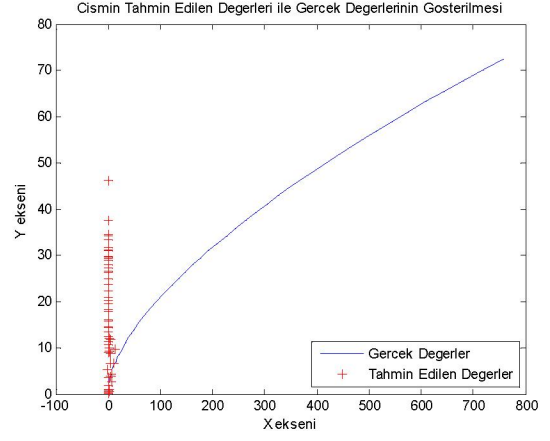
DVM bağlanım yöntemleri kullanılarak bir sonraki konumun kestirilmesiyle beraber, sensör ağlarda bu konumu izleyen sensörün de aktif hale getirilmesi ve kendi alanına giren hedefi takip etmesi için sensör çizelgelemesi mümkün olur.

6. Kaynakça


- [1] V. N. Vapnik. "Statistical Learning Theory", John Wiley and Sons, New York, 1998.
- [2] V. N. Vapnik. "The Nature of Statistical Learning Theory", Springer-Verlag, New York, 1995.
- [3] B. Schölkopf. "Support Vector Learning", R. Oldenbourg Verlag, Munich, 1997.
- [4] A. Smola and B. Schölkopf. "A Tutorial on Support Vector Regression", NeuroCOLT2 Technical Report NC2-TR-1998-030, 1998.
- [5] C. Campbell, "Kernel Methods: A Survey of Current Techniques", Neurocomputing vol. 48, p:63-84, 2002.
- [6] P. Wolfe, "A Duality Theory for Nonlinear Programming", Quarterly of Applied Mathematics, 19: p239-244, 1961.
- [7] O.L. Mangasarian, D.R. Musicant, "Robust Linear and Support Vector Regression", IEEE Transactions on Pattern Analysis and Machine Intelligence: vol.22, no.9, Sep 2000.
- [8] J. Mercer. "Functions of Positive and Negative Type and Their Connection With the Theory of Integral equations", Philos. Trans. Roy. Soc. London, A 209:415-446, 1909.
- [9] D. Marinakis, G. Dudek, D. J. Fleet, "Learning Sensor Network Topology through Monte Carlo Expectation Maximization", IEEE International Conference on Robotics and Automation, Barcelona, 2005
- [10] D. Comaniciu, V. Ramesh, P. Meer, "Kernel-based object tracking", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.: 25, no:5, p:564- 577, 2003
- [11] C. J. C. Burges, "A Tutorial on Support Vector Machines for Pattern Recognition", Data Mining and Knowledge Discovery, Vol.:2-2, p:121-167,1998



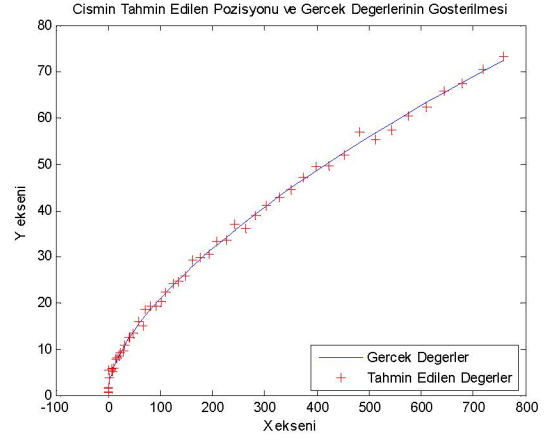
Şekil 2: Spline çekirdek kullanılarak, SNR oranı 10 dB iken elde edilen sonuçlar.



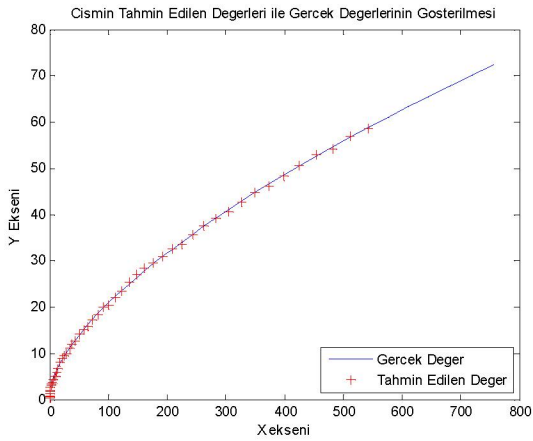
Şekil 5: SNR oranı 10 dB iken çekirdek varyansı $\sigma=2$ olan Radyal Tabanlı Gauss Çekirdek kullanılması durumunda elde edilen sonuçlar.



Şekil 3: SNR oranı 10 dB iken çekirdek varyansı $\sigma=1000$ olan Radyal Tabanlı Gauss Çekirdek kullanılması durumunda elde edilen sonuçlar.



Şekil 6: SNR oranı 10 dB iken Polinom Çekirdek kullanılması ve $d = 2$ alınması durumunda elde edilen sonuçlar.



Şekil 4: SNR oranı 10 dB iken çekirdek varyansı $\sigma=100000$ olan Radyal Tabanlı Gauss Çekirdek kullanılması durumunda elde edilen sonuçlar.