İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

DESTEK VEKTÖR REGRESYONU İLE PID KONTROLÖR TASARIMI

YÜKSEK LİSANS TEZİ

Kemal UÇAK

Kontrol ve Otomasyon Mühendisliği Anabilim Dalı

Kontrol ve Otomasyon Mühendisliği Programı

OCAK 2012

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

DESTEK VEKTÖR REGRESYONU İLE PID KONTROLÖR TASARIMI

YÜKSEK LİSANS TEZİ

Kemal UÇAK
(504081134)

Kontrol ve Otomasyon Mühendisliği Anabilim Dalı

Kontrol ve Otomasyon Mühendisliği Programı

Tez Danışmanı: Yrd. Doç.Dr.Gülay ÖKE

OCAK 2012

İTÜ, Fen Bilimleri Enstitüsü'nün **504081137** numaralı Yüksek Lisans Öğrencisi **Kemal UÇAK**, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı **"DESTEK VEKTÖR REGRESYONU İLE PID KONTROLÖR TASARIMI "** başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Yrd.Doç. Dr. Gülay ÖKE** .....
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prf.Dr. İbrahim EKSİN** .....
İstanbul Teknik Üniversitesi

Yrd. Doç.Dr. Sanem Sarıel TALAY .....
İstanbul Teknik Üniversitesi

Teslim Tarihi : **15 Aralık 2011**
Savunma Tarihi : **26 Ocak 2012**

Aileme ve Gerçek Dostlarıma,

ÖNSÖZ

Öncelikli olarak, değerli tez danışmanım Yrd.Doç. Dr. Gülay ÖKE' ye verdiği destek, harcadığı zaman ve bana olan güveni için teşekkürü bir borç bilirim.

Tez dönemi sürecinde bilimsel yönlendirmeriyle yardımcı olan, Prof. Dr. İbrahim EKSİN'e sonsuz teşekkürlerimi sunuyorum.

Lisans yıllarımda çalışmalarıyla beni akıllı kontrol sistemlerine yönlendiren, en zor günlerimde yardımını benden hiç bir zaman esirgemeyen değerli lisans bitirme projesi danışmanım Doç.Dr. Serdar İplikçi'ye sonsuz teşekkürlerimi sunuyorum.

Bu tezin yazım sürecinde ofisini benimle paylaşarak büyük bir incelik gösteren Dr. Mehmet Kürşat YALÇIN'a sonsuz teşekkürlerimi sunuyorum.

Benim için hiçbir maddi, manevi desteği esirgemeyen değerli aileme sonsuz teşekkürlerimi sunarım.

.

Ocak 2012

Kemal UÇAK
(Elektrik-Elektronik Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ ..... **vii**
İÇİNDEKİLER ..... **ix**
KISALTMALAR ..... **xi**
ÇİZELGE LİSTESİ ..... **xiii**
ŞEKİL LİSTESİ ..... **xv**
ÖZET ..... **xvii**
SUMMARY ..... **xxi**
1. GİRİŞ **1**
2. DESTEK VEKTÖR MAKİNELERİ **7**
2.1 Giriş 7
2.2 Doğrusal Sınıflandırma 7
2.3 Çekirdek Yaklaşımı 11
2.4 Doğrusal Olmayan Sınıflandırma 14
2.5 Doğrusal Regresyon 14
2.6 Doğrusal Olmayan Regresyon 16
3. DESTEK VEKTÖR MAKİNALARININ SİSTEM TANIMA VE KONTROLÖR TASARIMINDA KULLANIMI **19**
3.1 Giriş 19
3.2 Destek Vektör Makineleri ile Sistem Tanıma 20
3.3 Model Tabanlı Uyarlamalı PID Kontrolör Tasarımı 30
3.3.1 Öngörü ve jakobiyen matrisinin hesaplanması: 34
3.3.2 Manyetik askı sisteminin kontrolü: 38
3.4 Çevrimiçi En Küçük Kareler Destek Vektör Makinaları 42
3.5 Model Tabanlı Uyarlamalı PID Kontrolör Tasarımı 48
4. ÇEKİRDEK PARAMETRE UYARLAMASININ TANIMA VE KONTROLDEKİ ETKİLERİ **55**
4.1 Giriş 55
4.2 Çekirdek Parametresi 56
4.3 Eğim Düşümü Yöntemi ile Uyarlamalı Çekirdek 60
4.4 Çekirdek Uyarlamasının Tanılama ve Kontroldeki Etkileri 61
4.4.1 Çekirdek uyarlamasının tanılamadaki etkileri 62
4.4.2 Çekirdek uyarlamasının kontroldeki etkileri 67
5. SONUÇLAR VE GELECEK ÇALIŞMALAR **83**
KAYNAKLAR **85**
ÖZGEÇMİŞ **89**

KISALTMALAR

BFGS : Broyden-Fletcher-Goldfarb-Shanno
CLPSO : Comprehensive Learning Particle Swarm Optimizer
CSTR : Continuously Stirred Tank Reactor
ÇEK-DVM : Çevrimiçi En Küçük Kareler Destek Vektör Makineleri
ÇEK-DVR : Çevrimiçi En Küçük Kareler Destek Vektör Regresyon
DVM : Destek Vektör Makineleri
DVR : Destek Vektör Regresyon
DVS : Destek Vektör Sınıflandırıcı
EBMS : En Büyük Marjinli Sınıflandırıcı
EK-DVM : En Küçük Kareler Destek Vektör Makineleri
EK-DVR : En Küçük Kareler Destek Vektör Regresyon
LS-SVR : Least Square Support Vector Regression
NARX : Nonlinear Autoregressive Exogenous Model
OLS-SVR : Online Least Square Support Vector Regression
PID : Proportional Integral Derivative
SKTR : Sürekli Karıştırmalı Tank Reaktörü
SVM : Support Vector Machines
SVR : Support Vector Regression
USBÇS : Uyarlamalı Sinir Bulanık Çıkarım Sistemi

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Sistemin parametreleri..... 22
Çizelge 4.1 : Semboller. 73
Çizelge 4.2 : Model ve kontrolör performansı. 73
Çizelge 4.3 : Dayanıklılık(% Performans)..... 79
Çizelge 4.4 : Dayanıklılık(% Performans)..... 82

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : En iyi ayırıcı hiper düzlem. ... 8
Şekil 2.2 : En iyi ayırıcı hiper düzlem ve destek vektörler. ... 9
Şekil 2.3 : Destek vektör sınıflandırıcının ağ yapısı. ... 11
Şekil 2.4 : Doğrusal olarak ayrıştırılamayan veriler. ... 11
Şekil 2.5 : Doğrusal olarak ayrıştırılamayan verilerin çekirdek ile haritalanması. ... 12
Şekil 2.6 : Doğrusal olarak ayrıştırılamayan verilerin haritalanması. ... 13
Şekil 2.7 : Doğrusal olarak ayrıştırılamayan verilerin haritalanması. ... 14
Şekil 2.8 : Kayıp fonksiyonları. ... 15
Şekil 2.9 : Çekirdek yaklaşımı. ... 16
Şekil 2.10 : Kayıp fonksiyonları. ... 16
Şekil 3.1 : NARX modeli. ... 20
Şekil 3.2 : Dörtlü su tankı sistemi. ... 21
Şekil 3.3 : Giriş işaretleri. ... 23
Şekil 3.4 : Sistemin çıkışları. ... 23
Şekil 3.5 : DVR 1 eğitim hatası yüzeyi. ... 24
Şekil 3.6 : DVR 1 test hatası yüzeyi. ... 24
Şekil 3.7 : DVR 2 eğitim hatası yüzeyi. ... 25
Şekil 3.8 : DVR 2 test hatası yüzeyi. ... 25
Şekil 3.9 : DVR 3 eğitim hatası yüzeyi. ... 26
Şekil 3.10 : DVR 3 test hatası yüzeyi. ... 26
Şekil 3.11 : DVR 4 eğitim hatası yüzeyi. ... 27
Şekil 3.12 : DVR 4 test hatası yüzeyi. ... 27
Şekil 3.13 : Tank 1'in sıvı seviyesi. ... 28
Şekil 3.14 : Tank 2'nin sıvı seviyesi. ... 28
Şekil 3.15 : Tank 3'ün sıvı seviyesi. ... 29
Şekil 3.16 : Tank 4'ün sıvı seviyesi. ... 29
Şekil 3.17 : Uyarlamalı öngörülü model tabanlı PID kontrolör. ... 30
Şekil 3.18 : Manyetik askı sistemi. ... 38
Şekil 3.19 : Giriş işareti ve sistemin cevabı. ... 39
Şekil 3.20 : Mıknatısın konumu ve hızı. ... 39
Şekil 3.21 : Sistemin cevabı ve kontrol işareti. ... 40
Şekil 3.22 : Uyarlamalı PID kontrolörün parametreleri. ... 40
Şekil 3.23 : Mıknatısın konumu ve hızı. ... 41
Şekil 3.24 : Kontrol işaretini düzeltme terimi. ... 41
Şekil 3.25 : Çevrimiçi süreçte çekirdek matrisinin değişimi. ... 46
Şekil 3.26 : Sistemin dinamiklerinin uyarılması. ... 47
Şekil 3.27 : Çevrimiçi DVM modelin cevabı ve modelleme hatası. ... 47
Şekil 3.28 : Çevrimiçi model tabanlı uyarlamalı PID kontrolör. ... 49
Şekil 3.29 : Sistemin cevabı ve kontrol işareti. ... 50
Şekil 3.30 : Kontrolör parametrelerinin değişimi. ... 51
Şekil 3.31 : Çevrimiçi modelin ve sistemin cevabı. ... 51

Şekil 3.32 : Sürekli hal hatası. 52
Şekil 3.33 : Sistemin cevabı ve kontrol işareti..... 53
Şekil 3.34 : Sürekli hal hatası. 53
Şekil 3.35 : Kontrolör parametrelerinin değişimi. 54
Şekil 3.36 : Çevrimiçi modelin ve sistemin cevabı. 54
Şekil 4.1 : Çekirdek fonksiyonu. 57
Şekil 4.2 : Verilerin destek vektöre benzerliği. 58
Şekil 4.3 : Regresyon problemi..... 58
Şekil 4.4 : Çevrimiçi regresyon. 59
Şekil 4.5 : Çekirdek matrisi(Sabit bant genişliği). 59
Şekil 4.6 : Çekirdek matrisi(Uyarlamalı bant genişliği). 60
Şekil 4.7 : Akış diyagramı. 61
Şekil 4.8 : Kontrol işareti ve sistem çıkışı. 63
Şekil 4.9 : Eğitim hataları ve performanstaki iyileşme. 63
Şekil 4.10 : Çekirdeğin band genişliğinin ilk değerleri ve yakınsanan değerler. 64
Şekil 4.11 : İlk koşullar(σ_0), eğitim hataları , performans, yakınsanan değerler..... 64
Şekil 4.12 : Band genişliklerinin değişimi. 65
Şekil 4.13 : Uyarlamasız çekirdeğe sahip modelin çıktısı. 65
Şekil 4.14 : Uyarlamalı çekirdeğe sahip modelin çıktısı. 66
Şekil 4.15 : Çekirdek parametresinin değişimi. 66
Şekil 4.16 : Kontrol ve modelleme yapısı..... 67
Şekil 4.17 : Uyarlamalı ve sabit çekirdek parametresinin sisteme etkisi..... 67
Şekil 4.18 : Çekirdeğin band genişiliği ve öğrenme oranı. 68
Şekil 4.19 : PID kontrolör parametreleri. 68
Şekil 4.20 : Sürekli hal hatası. 69
Şekil 4.21 : Uyarlamalı ve sabit çekirdek parametresinin sisteme etkisi..... 70
Şekil 4.22 : Çekirdeğin band genişiliği ve öğrenme oranı. 70
Şekil 4.23 : PID kontrolör parametreleri. 71
Şekil 4.24 : Sürekli hal hatası. 71
Şekil 4.25 : Oturma ve bozucu bastırma süreleri. 72
Şekil 4.26 : Çekirdek parametresi ve öğrenme oranı. 74
Şekil 4.27 : Uyarlamalı PID kontrolör parametreleri. 74
Şekil 4.28 : Uyarlamasız çekirdeğe sahip modelin çıktısı. 75
Şekil 4.29 : Uyarlamalı çekirdeğe sahip modelin çıktısı. 75
Şekil 4.30 : Sistemin değişen parametreleri. 76
Şekil 4.31 : Kontrol işareti ve sistem cevapları. 77
Şekil 4.32 : Uyarlamalı PID kontrolör parametreleri. 77
Şekil 4.33 : Çekirdek parametresi ve öğrenme oranı. 78
Şekil 4.34 : Sürekli hal hatası. 78
Şekil 4.35 : Sistemin zamanla değişen parametresi. 79
Şekil 4.36 : Kontrol işareti ve sistem cevapları. 80
Şekil 4.37 : Uyarlamalı PID kontrolör parametreleri. 80
Şekil 4.38 : Çekirdek parametresi ve öğrenme oranı. 81
Şekil 4.39 : Sürekli hal hatası. 81

DESTEK VEKTÖR REGRESYONU İLE PID KONTROLÖR TASARIMI

ÖZET

İlk olarak 1979 yılında Rus Matematikçi Vladimir VAPNIK tarafından önerilen DestekVektör Makineleri(DVM)'nin temelleri, 20. yüzyılın başlarında 1909 yılında yayınlanan James MERCER'ın makalesine kadar dayanmaktadır. 20. Yüzyılda Nöroloji biliminde meydana gelen nörolojik gelişmeler Yapay Sinir Ağları(YSA)'nın ortaya çıkmasını sağlarken aynı yüzyıldaki matematiksel gelişmeler de DVM'nin bilim dünyasındaki bu günkü yerini almasını sağlamıştır. Mercer, günümüzde Mercer teoremi olarak bilinen teoriyi içeren ve "Pozitif ile Negatif Fonksiyonlar ve Bunların İntegral Eşitlikler Teorisine Bağlantısı" adı ile yayımlanan makalesinde, DVM'nin temel kavramı olan çekirdek kavramını ortaya koymuştur. Daha sonraki yıllarda yayımlanan "Kernel Hilbert Uzayı'nın Yeniden Türetimi" makalesi de DVM'nin temelini oluşturmaktadır. İstatistiksel öğrenme teorisi bilim dalı 1974 yılında Vapnik ve Chernovenkis ile Rusyada başlamıştır. DVM'nin, Vapnik'in istatistiksel öğrenme kuramını daha da geliştirmesiyle ortaya çıktığı söylenebilir. DVM'nin bugünkü şekline çok yakın hali ilk olarak 1992 yılında COLT(Conference on Computational Learning Theory) 1992 isimli konferansta sunulmuştur. Cortes ve Vapnik tarafından 1995 yılında esnek marjin sınıflandırıcı algoritması ortaya konmuş ve aynı yılda bu algoritma regresyon problemleri için genişletilmiştir.
Geleneksel YSA yaklaşımında veriye uygun bir model yaratılması ve genellenmesi konusunda ciddi sorunlar ortaya çıkmaktadır. YSA için kullanılan parametrelerin belirlenmesi için deneysel ve istatiksel ölçümler gerekmektedir. Viladimir VAPNIK tarafından 1995 yılında ortaya atılan DVM ile ise deneysel araştırmalar üzerinde ciddi bir performans artışı gözlenmiştir.

YSA ve DVM üstün doğrusal olmayan genelleme yeteneklerinden dolayı son yıllarda sıklıkla sistem tanıma problemlerinde kullanılmaktadırlar. YSA'da, modelin başarısı ağ yapısına ve seçilen eğitim verilerine bağlıdır. YSA'da seçilen öğrenme algoritması ve konveks olmayan amaç fonksiyonu problemin çözümünün yerel minimuma takılmasına neden olabilmektedir. Genel anlamda tüm bu problemler DVM'de karşılaşılmamaktadır.

DVM, istatistiksel öğrenme teorisine ve yapısal risk minimizasyonu prensiplerine dayanmaktadır. DVM'nin üstünlüğü, sınıflandırma ve regresyon problemlerini yerel minimuma takılmadan çözebilmeleridir. Konveks olmayan problem karesel programlama problemine dönüştürülerek global minimum garantilenmektedir.
Üstün genelleme yeteneklerinden dolayı, DVM, sınıflandırma ve regresyon problemlerinin çözümünde başarılı bir şekilde kullanılmaktadır. Kanser hücreleri için gen seçme, yüz tanıma, kanser teşhisi ve internette saldırı algılama DVM' nin örüntü tanıma problemlerinde uygulama alanlarından bazılarıdır. Mikrodalga iletimin modellenmesi, robot manipülatörün kontrolü, model öngörülü kontrol ve kontrolör parametrelerinin uyarlanması DVM'nin tanılama problemlerinde kullanıldığı bazı uygulama alanlarıdır. DVM'ler model tabanlı uyarlamalı PID kontrolörlerin

parametrelerinin uyarlanmasında jakobiyen bilgisinin kestirimi için de kullanılabilmektedir.
Bu tezde, Bölüm 2'de DVM'nin temelleri hakkında ayrıntılı bilgi verilerek, sınıflandırma ve regresyon problemlerinin oluşturulması ve global çözümün nasıl garanti edildiği hakkında ayrıntılı olarak açıklanmıştır. İlk olarak iki sınıf için doğrusal sınıflandırma problemi ele alınmış ve doğrusal sınıflandırma formülasyonları inşa edilmiştir. Doğrusal sınıflandırmanın mümkün olmadığı durumlarda kullanılan, DVM'nin temelini oluşturan çekirdek kavramından bahsedilmiştir. Çekirdek fonksiyonu giriş uzayında doğrusal olarak sınıflandırılamayan verilerin, doğrusal olarak sınıflandırılabilmelerine olanak sağlayan öznitelik uzayına haritalanmalarını sağlamaktadır.
Bölüm 3'te DVM'nin üstün genelleme yeteneğinden faydalanıldığı alanlardan biri olan sistem tanıma ve kontrolör tasarımı hakkında bilgi verilmiş ve bu konularda yapılan uygulamaların sonuçları aktarılmıştır.

Sistem tanıma problemi, sistemin girişi ile çıkışı arasındaki haritalama fonksiyonunun bulunması problemidir. Sistem tanıma problemlerinin özelliği tanılama probleminin regresyon problemine dönüştürülmesidir. Yapay sinir ağı, bulanık mantık ve uyarlanabilir bulanık sinir ağları temelli modeller sistem dinamiklerinin kestirimi için başarılı modeller elde edilmesine olanak sağlamaktadır. Son yıllarda global minimumu garanti ettikleri için destek vektör makineleri temelli modeller sıklıkla kullanılmaktadır.

Yapay sinir ağı, bulanık mantık ve uyarlanabilir bulanık ağların ortak özelliği, öğrenme algoritmaları ve konveks olmayan amaç fonksiyonlarından dolayı lokal minimuma takılabilmeleri sonucunda lokal model oluşmasına neden olmalarıdır. Destek Vektör Makinelerinde amaç fonksiyonu konveks, optimizasyon problemi kısıtlı optimizasyon problemidir. Bu nedenle sistem dinamiklerinin kestirimi için çok iyi bir tanılama aracı olarak kullanılabilmektedirler. Model tabanlı uyarlamalı kontrolörlerin başarısı doğrudan modelin başarısına bağlıdır. Bu nedenle, DVM'nin sistem tanımadaki başarısından yararlanarak, DVM temelli kontrolör yapılarından son zamanlarda sıklıkla faydalanılmaktadır.

Veri örneklemeye dayalı sistem tanıma problemlerinde amaç öncelikli olarak sistemin mümkün olan bütün dinamiklerinin ortaya çıkarılmasıdır. Doğrusal olmayan sistemlerde sistemin dinamiklerinin ortaya çıkarılması için farklı genlik ve genişliklere sahip, sistemin giriş işaretinin sınırları içinde rastgele değişen basamak işaretleri kullanılmaktadır. Amaç iyi bir modelleme için sistemin mümkün olduğunca bütün frekans bileşenlerinde uyarılmasıdır. Bölüm 3.2'de DVR ile sistem modelleme ele alınmıştır. DVR'nin başarımını test etmek için 4'lü tank sisteminin dinamikleri kestirilmiştir. Izgaralama yöntemi kullanılarak en iyi çekirdek parametresi araştırması yapılmıştır. Sonuçlar DVR'nin oldukça az eğitim verisiyle başarılı modeller elde edilmesine olanak sağladığını göstermektedir. Bölüm 3.3'te önceden literatürde önerilen ε-DVR model tabanlı kontrolör tasarımı sunulmuştur. Literatürde önerilen kontrolör 5 parçadan oluşmaktadır. Bunlar;

1-Klasik PID Kontrolör

2-Sistemin DVR Modeli

3-Çizgi arama Bloğu(Altın Bölme vb.)

4-Kontrol İşareti düzeltme bloğu

5-Kontrolör Parametresi ayarlama bloğu

Burada ε-DVR model, PID kontrolörün parametrelerinin uyarlanması için gerekli olan sistem jakobiyen bilgisinin kestirimi için kullanılmaktadır. PID kontrolör parametreleri Levenberg Marquard algoritması kullanılarak uyarlanmıştır. Jakobiyen Matrisi zincir kuralı kullanılarak 2 tane bloğa bölünmüştür. Bu bloklardan biri kontrol işaretini düzeltme için kullanılırken diğeri kontrolör parametrelerinin kestirimi için kullanılmıştır. Sistemin geçici hal davranışında üretilen kontrol sinyali sistemi istenilen cevaba süremeyebileceği için kontrol işareti düzeltme bloğu kullanılmıştır. Öğrenme oranın belirlenmesi için altın bölme yöntemi kullanılmıştır. Çalışmamızda bu kontrolör yapısını kullanarak kararsız ve doğrusal olmayan manyetik askı sisteminin kontrol edilmesi amaçlanmıştır. ε-DVR çevrimdışı bir tanılama aracıdır ve ε-DVR'de regresyon probleminin çözümü için kullanılan karesel problem çözümleyici oldukça büyük bir işlemsel yük getirir. Bu sorunları çözmek için En Küçük Kareler Destek Vektör Makineleri(EK-DVM) kullanılabilir. Bölüm 3.4'de EK-DVM'nin tanılama probleminde kullanılması ile ilgili ayrıntılı bilgi verilmiştir. Daha sonra çevrimdışı bu algoritmanın çevrimiçi tanılamaya uyarlanması anlatılmıştır. Çevrimiçi En Küçük Kareler Destek Vektör Regresyonun (ÇEK-DVR) başarımı, 3. dereceden doğrusal olmayan bir sistem olan sürekli karıştırmalı tank reaktör sistemi üzerinde denenmiştir. ÇEK-DVR sistem tanılama aracı kullanılarak sistemin doğrusal olmayan dinamiklerinin başarılı bir şekilde modellendiği gözlemlenmiştir. Çevrimdışı modeller sistem ve ortam belirsizliklerinden etkilenebileceği için kontrolör tasarımında gerekli olan jakobiyen bilgisinin yanlış kestirilmesine neden olabilirler. Bu dezavantajı ortadan kaldırmak için ÇEK-DVR kullanılarak tasarlanan uyarlamalı PID kontrolör hakkında geniş bilgi verilmiştir. ÇEK-DVR kullanılarak uyarlamalı PID kontrolörün başarımı sürekli karıştırmalı tank reaktörü üzerinde test edilmiştir. Kontrolörün gürültülü koşulardaki performansı için ölçme gürültüsü altında çalışması incelenmiştir.

Bölüm 4'de bu çalışmanın ana fikrini oluşturan, DVM'nin ana tasarım bileşeni olan, giriş uzayı ile öznitelik uzayı arasındaki doğrusal olmayan haritalamayı sağlayan çekirdek fonksiyonu parametresinin çevrimiçi uyarlanması hakkında bilgi verilmiştir. Çekirdeğin ana fonksiyonu düşük dereceden giriş uzayında doğrusal olarak ayrıştırılamayan sınıflandırma problemini, doğrusal olarak sınıflandırmanın yapılabileceği daha yüksek dereceden öznitelik uzayına haritalamaktır. Böylece doğrusal regresyon ve sınıflandırma tekniklerinin doğrusal olmayan problemler için kullanımı mümkün olabilecektir. Haritalamada kullanılan çekirdek fonksiyonlarının nümerik parametreleri regresyon ve sınıflandırma performasını doğrudan etkilemektedir. Bundan dolayı, çekirdek fonksiyonu ve ona ait parametrelerin seçimi modelleme ve kontrol performansı açısından büyük öneme sahiptir. Gauss çekirdek için, band genişliği ana nümerik parametredir. Band genişliği çok küçük seçildiğinde, öznitelik uzayında benzer öznitelikler farklı lokasyonlara haritalanacak ve model için büyük bir öneme sahip öznitelikler, öznitelik uzayına aktarılamayabilecektir. Eğer çok büyük seçilirse, model için önemsiz farklı öznitelikler, öznitelik uzayında çok yakın lokasyonlara haritalanacaktır. Sonuç olarak, çekirdek parametresinin çok küçük veya çok büyük seçilmesi durumunda çekirdeğin doğrusal olmama özelliğini kaybolacaktır. En iyi regresyon performansı model için gereksiz özniteliklerin filtrelenmesi ile elde edilebilir. Bu gibi etkenlerden dolayı, optimal çekirdek parametresinin seçimi, çekirdek makinesinin eğitim ve test performansı açısından büyük bir öneme sahiptir.

Teknik literatürde, çekirdek parametresinin uyarlanması 'çekirdek polarizasyonu' olarak adlandırılmaktadır ve sınıflandırma problemlerinde optimal parametreyi

belirlemek için çeşitli yaklaşımlar önerilmiştir. Bu yaklaşımlardan bazıları; ızgaralama (grid search), çapraz doğrulama (cross validation), birini dışarıda bırakma (leave one out), logaritmik konveks konkav prosedür (LCCP (log convex concave procedure)), ve evrimsel arama algoritmalarıdır. Genetik algoritmalar (genetic algorithms), sürü optimizasyonu (swarm optimization), benzetilmiş tavlama (simulated annealing), kuantum- esinlenmiş savunma sistemleri (quantum-inspired immune systems) ve yapay savunma sistemleri (artificial immune systems) çekirdek parametresinin hesaplanmasında kullanılan evrimsel algoritmalardan bazılarıdır.

Bu yaklaşımlardaki ortak özellik çekirdek parametresinin çevrimdışı uyarlanmasıdır. Bu çalışmada literatürdeki yaklaşımlardan farklı olarak ÇEK-DVM'ye ait çekirdek parametresi çevrimiçi uyarlanmıştır. Çekirdeğe katılan adaptasyon yeteneğinin sistem tanılama ve model tabanlı uyarlamalı kontrolör tasarımındaki başarımını değerlendirmek için sürekli karıştırmalı tank reaktör sistemi (CSTR) üzerinde benzetimler yapılmıştır. Öncelikli olarak Bölüm 4.2 de çekirdek parametresinin öznitelik uzayındaki etkileri incelenmiş ve çekirdek parametresinin doğru belirlenememesi durumunda problemin doğrusal olmama özelliğini nasıl yitirdiği anlatılmıştır. Çekirdek parametresinin optimal olarak seçilmesinin regresyon performansı açısından önemi ifade edilmiştir. Çekirdeğe çevrimiçi uyarlama yeteneğinin katılması sonucunda çekirdek matrisindeki değişimler hakkında açıklayıcı bilgiler verilmiştir. Bölüm 4.3'de eğim düşümü metodu ile çekirdek parametresinin uyarlanması anlatılmıştır. Önerilen metodun tanılama problemi üzerindeki etkilerini incelemek için farklı ilk koşullara sahip çekirdek değerleri için benzetimler yapılmıştır. En küçük eğitim hatası $\sigma(0)=1$ iken elde edildiği için bu değer kontrol sürecinde de ilk değer olarak kullanılmıştır. Bölüm 4.4'te yöntemin kontrolör tasarımındaki etkileri incelenmiş, ayrıca çekirdeğe katılan uyarlama özelliğinin ölçme gürültüsü ve bozucu olması durumunda ve sistem parametreleri değiştiğinde kontrolör dayanıklılığını nasıl etkilediği araştırılmıştır.

Bölüm 5'de yöntemin tanılama ve kontrol performansı açısından etkileri hakkında kısaca bir tartışma yapılmış ve gelecek çalışmalar hakkında bilgiler verilmiştir.

DESIGN OF PID CONTROLLER VIA SUPPORT VECTOR REGRESSION

SUMMARY

The basics of the SVM, firstly proposed by Vladimir VAPNIK in 1979, are based on the article of the James MERCER owing to kernel notion. While the developments of neurological science in 20th century provided the emergence of the Neural Network, develeopments in mathematics at the same century have led to its present position in the world of science. Mercer, now known for Mercer's Theorem published with the name of "Functions of Positive and Negative Type and their Connection with the Theory of Integral Equations ", revealed the kernel notion, the basic concept of the SVM. The article, published with the name of " Reproducing Kernel Hilbert Space" in later years, underlied the fundamentals of the SVM. Statistical learning theory emerged with Vapnik and Chervonenkis in 1974. However, it is possible to say that SVMs came about when Vapnik integrated further developments to statistical learning theory in 1979. Vapnik suggested the first form of SVMs close to their current form with a paper at the COLT (Conference on Computational Learning Theory) conference in 1992. The soft margin classifier was proposed in 1995 by Cortes and Vapnik and the algorithm was developed for regression by Vapnik in the same year.

Traditional ANN approach poses serious problems about the composition and generalization of an appropriate model. Experimental and statistical measurements are required to determine the parameters of ANN. Significant improvement was observed on the experimental research in SVM proposed by Vapnik.

Data sampled modelling techniques based on Artificial Neural Network (ANN) and Support Vector Machines(SVM) are popularly applied in recent years owing to their non-linear prediction ability. The performance of models based on ANNs depends on the network's structure and the selection of training samples. The possibility of convergence to a local minima is the persistent problem in ANNs(such as multilayer perceptrons). These problems are generally avoided in SVMs.

The SVMs rely on the statistical learning theory and the principle of structural risk minimization. The superiority of SVMs is that they can solve classification and regression problems without getting stuck at local minima.The global minima is ensured by transforming the nonconvex objective function in primal form into a convex one in dual form.

Owing to their eximious generalization ability, SVMs have been successfully used to solve both classification and regression problems.Gene selection for cancer cells , face recognition , and intrusion detection are some of the areas where SVMs are used as pattern classifiers. Modeling of microwave transition, robot manipulator control, model predictive control and PID controller tuning are examples of applications where Support Vector Regression technique has been employed for identification. SVMs can be utilized so as to approximate the jacobian of the system to tune PID controller parameters.

In this thesis, the basics of SVM and how SVMs ensure global minima has been explained in section 2. Firstly, linear classification for two classes has been persued and the formulation for linear classification problem has been constructed. The kernel, employed for the case where linear classification is not possible, has been mentioned. The kernel functions to map the training data, not separable by a linear plane in the input space, to a high dimensional feature space where linear classification or regression can be successfully performed.

In Section 3, System Identification and Controller Design, the application area where SVMs are succesfully employed, has been presented and results of these applications are given. The system identification problem deals with finding the mapping function from input to ouput. The main feature of the system identification problem is to convert the identification problem to a regression problem.

The dynamics of nonlinear systems has been identified with artificial intelligence methods such as ANN, ANFIS and SVM. Models based on SVM, have recently been preferred to update controller parameters over Neural Network (NN) and ANFIS Models due to their apparent strength of ensuring global minima.

The common feature of ANN, FL(Fuzzy Logic) and ANFIS is that they get stuck at local minima because of their non-convex objective functions. The objective function of SVM in dual form is convex and the optimization problem is a constrained optimization problem. Because of this, they can be utilized as an identification tool to approximate the dynamics of systems. The achievements of the model based controllers directly depend on the performance of the model. Therefore, controller structures based on SVM have often been utilized in recent times.

The aim in data sampled modeling technique is to reveal all possible dynamics of the system. An input varying between the limits of the input signal is applied to reveal the dynamics of the nonlinear systems. The aim is to stimulate the systems with all possible frequencies. System modeling has been explained in Section 3.2. The identification performance of SVR has been evaluated on a quadruple tank system as an example of MIMO modeling. The kernel parameters play a crucial role in the modeling performance, so a grid search analysis has also been carried out to find the best kernel parameter set. The results indicate that SVR allows to obtain better models with very few training data. An adaptive PID Controller based on ε-SVR, proposed in technical literature formerly, has been presented. The controller consists of 5 parts. These are ;

a) Classical PID controller
b) SVR Model of the plant,
c) Line search block
d) Control signal correction block
e) Controller parameter tuner.

ε-SVR model has been utilized to approximate the system jacobian information. PID parameters has been tuned using Levenberg Marquard algorithm. Jacobian matrix is separated into two blocks using chain rule. One block is for control signal correction and the other is for parameter tuning. The updated controller parameters may not be optimal enough to force the plant output toward the desired trajectory. Therefore, control signal correction block has been employed. Optimum step size has been obtained via golden section method. The Magnetic Levitation system has been controlled using this controller type as an example of a nonlinear and unstable system. ε-SVR is an offline identification tool and it uses quadratic programming

solver to seek global minima in ε-SVR which presents a computational load. Least Square Support Vector Machines(LSSVM) can be employed in order to eliminate this drawback. In section 3.4, detailed information about LSSVM in identification has been given. Then, conversion of this offline algorithm to an online algorithm is explained.

The identification performance of the Online LSSVR has been evaluated by simulations carried out on a CSTR system. It has been observed that nonlinear dynamics can be succesfully modelled when OLSSVR is used as an identification tool. Since the offline model can be affected by model and system uncertainities, it may result in erroneous jacobian information. Adaptive PID Controller based on OLSSVR can be utilized to come over this complication. The dynamics of the CSTR system has been controlled using an adaptive controller based on OLS-SVR. The performance of the controller with respect to measurement noise has been evaluated.

In section 4, online tuning of kernel parameter, the main idea of this study, is explained. Kernel function allows a nonlinear mapping between input and feature space. The main function of the kernel is to map the training data, not separable by a linear plane in the input space, to a high dimensional feature space where linear classification or regression surface can be successfully carried out. Thus, linear techniques can be utilized in the high dimensional feature space. The numerical values of the kernel effects directly the classification and regresion performance. The regression performance of a SVM depends on the chosen kernel function which is generally parametric and the numerical values of these parameters are important in determining the location of the features mapped onto the feature space, however there is no theoretical method to determine them numerically. Because of this, the selection of the kernel function and the numerical values of its parameters are very crucial in terms of modeling and control performance. For a gaussian kernel, the bandwidth is the main numerical parameter. When it is chosen to be very small, similar features are mapped to distant locations in feature space and some features significant for the model may be discarded. If it is chosen very large, different features are mapped very close to each other in feature space and redundant or irrelevant features may also be mapped. Consequently, kernel may lose its nonlinearity. Better regression performance can be obtained by discarding redundant features. Due to such factors, the selection of optimal kernel parameter is crucial in terms of training and testing performance of the kernel machine.

In technical literature tuning the kernel parameter is named as “kernel polarization” and various approaches have been proposed to find an optimal solution to it for classification problems. Gradient descent, grid search algorithm, cross validation, leave one out, log convex concave procedure (LCCP), and evolutionary search algorithms have been used to seek optimal kernel parameter. Evolutionary algorithms like genetic algorithms, swarm optimization, simulated annealing, quantum-inspired immune systems and artificial immune systems have been employed to compute the kernel parameter.

The common aim in all these approaches is to compute the kernel parameter offline. In this study, unlike different approaches in literature, the kernel parameter has been adapted online. The simulations have been carried out on a continuously stirred tank reactor(CSTR) so as to examine the effects of the interfused flexibility to the kernel in terms of system identification and controller design. Firstly in section 4.2, the impacts of the kernel parameter in feature space for a gaussian kernel have been

analysed. How a non-optimal kernel parameter leads to the loss of problem nonlinearity, is explained. The significance of the selection of kernel parameter regarding regression performance has been expressed. The discriptive information about changes in the kernel matrix as a result of online adaptation ability has been given. The tuning of the kernel parameter via gradient descent has been presented in section 4.3. In order to examine the effects of kernel bandwidth adaptation in comparison with the fixed bandwidth case, various simulations have been performed with different initial values of bandwidth. Since the smallest modeling error is obtained with $\sigma(0)=1$ this value has been used in control procedure as the initial value of the kernel bandwidth. In section 4.4, influence of the method in controller design has been examined. Besides, how the controller performance is affected under measurement noise and disturbance as well as under system parameter changes has been investigated.

A brief discussion on the effects of the method in terms of identification and control performance and future study prospects are given in section 5.

1. GİRİŞ

Destek Vektör Makineleri (DVM) ilk olarak Yapay Sinir Ağları (YSA) gibi 20. yüzyılda ortaya atılmıştır. YSA 20. yüzyılda meydana gelen nörolojik buluşlardan sonra şekillenirken DVM aynı yüzyıldaki matematiksel gelişmeler sayesinde bilim dünyasında bugünkü yerini almıştır. DVM'nin temelleri tam olarak 20. yüzyıl başlarında 1909 yılında yayınlanan James MERCER'in makalesine dayanmaktadır. Mercer, günümüzde Mercer teoremi olarak bilinen teoriyi içeren ve "Pozitif ile Negatif Fonksiyonlar ve Bunların İntegral Eşitlikler Teorisine Bağlantısı" adı ile yayımlanan makalesinde, DVM'nin temel kavramı olan çekirdek kavramını ortaya koymuştur. Daha sonraki yıllarda yayımlanan "Kernel Hilbert Uzayı'nın Yeniden Türetimi" makalesi de DVM'nin temelini oluşturmaktadır.

1964 yılında Aizerman, Braverman ve Rozoner, Mercer teoremi ve durum uzayında iç çarpım kullanılmasıyla çekirdeklerin dönüşümü kavramını ortaya çıkarmışlardır. 1979 yılında Viladimir VAPNIK, daha önceki yıllarda yayımlanmış olan bu makaleleri baz alarak DVM'yi ortaya atmıştır [1]. Bu ortaya koyma üzerindeki bilimsel ilk atıflar da yine Viladimir VAPNIK tarafından 1995 yılındaki makalesinde yapılmıştır [2].

Geleneksel YSA yaklaşımında veriye uygun bir model yaratılması ve genellenmesi konusunda ciddi sorunlar ortaya çıkmaktadır. YSA için kullanılan parametrelerin belirlenmesi için deneysel ve istatiksel ölçümler gerekmektedir. Viladimir VAPNIK tarafından 1995 yılında yayımlanan makalede ortaya atılan DVM ile ise deneysel araştırmalar üzerinde ciddi bir performans artışı gözlenmiştir.

Üstün genelleme yeteneklerinden dolayı, DVM, sınıflandırma ve regresyon problemlerinin çözümünde başarılı bir şekilde kullanılmaktadır. Kanser hüçreleri için gen seçme, kanser teşhisi [3], yüz tanıma[4], ve internette saldırı algılama[5] DVM'nin çeşitli örüntü tanıma uygulaması örneklerinden bazılarıdır. Mikrodalga iletimin modellenmesi[6], robot manipülatörün kontrolü[7], model öngörülü kontrol[8] ve kontrolör parametrelerinin uyarlanması[9,10] DVM'nin kullanıldığı

bazı kontrol problemi uygulamalarıdır. DVM'ler sıklıkla PID kontrolörlerde, sistem modelini elde etmek ve jakobiyen bilgisini kestirmek için kullanılırlar.

PID kontrolörler, uygulamadaki basit yapıları ve belirsizliklere karşı dayanıklılıklarından dolayı en önemli kontrolör yapısıdırlar[11-13]. Uzun yaşam güçleri uygulamadaki basitliklerinden ve etkilerinden kaynaklanmaktadır[12]. PID kontrolörler, sabit kontrolör parametreleri ile tasarlanabileceği gibi parametreleri uyarlamalı hale getirmekde mümkündür. Sistem yapısı kontrol sürecinde değişikliğe uğradığında veya değişen koşullara uyum açısından kontrolörün adaptasyon yeteneğinin bulunması izleme hatasının minimize edilmesi açısından büyük bir öneme sahiptir. Kontrolörün adaptasyon yeteneğinin bulunması özellikle doğrusal olmayan veya kararsız sistemlerin kontrolü için gerekmektedir. Doğrusal olmayan sistemler için kontrolör tasarımında sistemin gelecekteki davranışlarını içeren bilgi, özellikle sistemin jakobiyeninin bilgisi gerekmektedir. Teknik literatürde jakobiyen bilgisinin büyük bir doğrulukla hesaplanması için çeşitli metodlar bulunmaktadır. [9,10]'de kontrolör parametrelerinin uyarlanması için gereken sistem jakobiyen bilgisinin hesaplanması için model tabanlı kontrolör yapısı uygulanmıştır. Doğrusal olmayan sistemlerin dinamikleri, YSA, Uyarlamalı Sinir Bulanık Çıkarım Sistemi (USBÇS) ve DVM gibi yapay zeka metodları ile tanılanabilir [14-16]. Model tabanlı kontrolör parametresi uyarlama metodlarında, kontrolör parametrelerinin optimal değerlerine yakınsama hızı doğrudan modelleme performansına bağlıdır. Son zamanlardaki çalışmalarda kontrolör parametrelerinin uyarlanmasında, global minimumu garanti etme özelliklerinden dolayı, YSA yerine DVM tabanlı modeller tercih edilmektedir [9,10,17,18].

Bu tezde önce ε-Destek Vektör Regresyon (ε-DVR) yöntemi tanılama ve kontrol problemlerinin çözümüne uygulanarak sonuçlar incelenmiştir. Tanılama problemi için 4'lü tank sistemi ele alınmış, sistem dinamikleri ε-DVR ile kestirimiştir, elde edilen sonuçlar Bölüm 3.1 de verilmiştir. Daha sonra, Bölüm 3.2'de kararsız ve doğrusal olmayan bir sistem olan manyetik askı sisteminin kontrolü için, dinamikleri ε-DVR ile kestirilmiş model tabanlı bir uyarlamalı PID kontrolör tasarlanmıştır. Kontrolör parametreleri Levenberg Marquard algoritmasıyla uyarlanmıştır. ε-Destek Vektör Makineleri (ε-DVM) tabanlı problemlerin çözümü için karesel problem çözücü gerekmektedir. Karesel problem çözümleyicinin getirdiği işlemsel yük, çevrimdışı DVM'nin hızlı sistemlerde gerçeklenmesini sınırlamaktadır. Ayrıca,

sistemin belirsiz parametreleri çevrimdışı modeller açısından zorluk yaratır. Çevrimiçi modeller, belirsizliklerle baş etmekte çevrimdışı metodlara göre daha üstündürler ve gerçek zamanlı uygulamalarda optimal performansı elde etmeyi sağlayacak çekirdek parametresinin çevrimiçi uyarlanmasına izin vermektedirler. Bu nedenle, hız ve adaptasyonun önemli olduğu uygulamalarda çevrimiçi metodlar önerilmektedir. Bölüm 3.4'de doğrusal olmayan bir sistem olan sürekli karıştırmalı tank reaktörünün (Continuously Stirred Tank Reaktör (CSTR)) dinamiklerinin modellenmesi için Çevrimiçi En Küçük Kareler Destek Vektör Makineleri(ÇEK-DVM)'den yararlanılmıştır. Sistemin kontrolü için [9]'de önerilen uyarlamalı PID kontrolör yapısı kullanılmıştır.

Bu tezde ikinci olarak DVR çekirdek paremetresinin uyarlanması üzerinde durulmuştur. YSA'larına kıyasla DVM tabanlı modellemenin en önemli özelliği yerel minimuma takılmaması ve önemli ölçüde az eğitim verisiyle güçlü genelleme yeteneğine sahip olmasıdır. DVM'de çekirdek, giriş verilerinin benzerliğini ifade eden, ana tasarım bileşenidir [19,20]. Bu benzerliklerin doğrusal olmayan temsili çekirdek ile sağlanmaktadır. Doğrusal olmayan sınıflandırma veya regresyon problemleri, çekirdek yardımıyla, doğrusal sınıflandırmanın veya regresyonun başarılı bir şekilde gerçeklenebileceği yüksek dereceden öznitelik uzayına haritalanabilmektedir. Çekirdek parametresi dolaylı olarak, maksimum marjinli hiper düzlemin bulunduğu, yüksek boyutlu öznitelik uzayının yapısını tanımlamaktadır [21]. DVM'nin regresyon performansı, genellikle parametrik olan ve özniteliklerin lokasyonunu belirleyen çekirdek fonksiyonunun parametrelerine bağlıdır. Ancak çekirdek parametrelerini nümerik olarak belirlenmesini sağlayacak teorik bir yöntem bulunmamaktadır [22,23]. Gauss çekirdek için, band genişliği ana numerik parametredir. Band genişliği çok küçük seçildiğinde, giriş uzayındaki benzer veriler öznitelik uzayında benzerlik bilgisini yitirip çok farklı verilermiş gibi algılanabilirler ve model için büyük bir öneme sahip veriler, öznitelik uzayına aktarılmayabilir. Eğer çok büyük seçilirse, model için önemsiz farklı giriş verileri, öznitelik uzayında çok benzer verilermiş gibi algılanabilirler. Sonuç olarak, çekirdek parametresinin çok küçük veya çok büyük seçilmesi durumunda çekirdek doğrusal olmama özelliğini kaybedecektir [24]. En iyi regresyon performansı model için gereksiz özniteliklerin filtrelenmesi ile elde edilebilir. Bu gibi etkenlerden dolayı, optimal çekirdek parametresinin seçimi, çekirdek makinesinin eğitim ve test performansı açısından büyük bir öneme sahiptir.

Teknik literatürde, çekirdek parametresinin uyarlanması ‘çekirdek polarizasyonu’ olarak adlandırılmaktadır ve sınıflandırma problemlerinde optimal parametreyi belirlemek için çeşitli yaklaşımlar önerilmiştir. Eğim düşümü [25,26,27], ızgaralama, çapraz doğrulama [28], birini dışarıda bırakma [29] (leave one out [29]), logaritmik konveks konkav prosedür (LCCP (log convex concave procedure)) [30], ve evrimsel arama algoritmaları, optimal çekirdek parametresini aramak için kullanılmıştır. Genetik algoritmalar (genetic algorithms) [31], sürü optimizasyonu (swarm optimization) [32,33,34], benzetilmiş tavlama (simulated annealing) [35], kuantum- esinlenmiş savunma sistemleri (quantum-inspired immune systems) [36] ve yapay savunma sistemleri (artificial immune systems) [37] gibi yöntemlerden çekirdek parametresinin hesaplanmasında yaralanılmıştır. [38]’de, parametre kümesinin kararlılığını iyileştirmek için hibrit CLPSO-BFGS uygulanmıştır. Regresyon problemleri için, çapraz doğrulama (Cross validation [39]), parçacık sürü optimizasyonu (particle swarm optimization) [40,41], örüntü arama (pattern search) [42], model tabanlı global optimizasyon metodu [43] ve ızgaralama-elmas (grid-diomand search) [44], çekirdek parametresinin uyarlanmasında başarılı bir şekilde kullanılmıştır. Bu yaklaşımlardaki ortak özellik çekirdek parametresinin çevrimdışı uyarlanmasıdır.

Bu tezde Çevrimiçi En Küçük Kareler Destek Vektör Regresyon (ÇEK-DVR) için seçilen gauss çekirdek parametresi eğim düşümü yöntemiyle uyarlanmıştır. Tanılama ve kontrol problemleri için uygulamalar yapılarak, sonuçlar değerlendirilmiş, gürültülü durumda ve sistemde bozucu olması durumunda başarımın nasıl etkilendiği irdelenmiştir. ÇEK-DVR’de çekirdek polarizasyonu ve eğim düşümü metodunun bu amaçla kullanılması, bizim bilgimiz dahilinde teknik literatürde daha önce yapılmamış bir çalışmadır. Tez, aşağıdaki gibi organize edilmiştir. Bölüm 2 de DVM‘de sınıflandırma ve regresyon problemleri için optimizasyon problemlerinin nasıl formüle edildiği hakkında detaylı bilgi verilmiştir. Bölüm 3.1 ve 3.2’de ε-DVM ile çevrimdışı tanılama problemi ele alınmış ve kontrolörün başarımı doğrusal olmayan ve kararsız bir sistem olan manyetik askı sistemi üzerinde test edilmiştir. Bölüm 3.3 ve 3.4’de ÇEK-DVR ile sürekli karıştırmalı tank reaktörünün(SKTR) çevrimiçi tanılanması ve uyarlamalı PID ile kontrolü yapılmıştır. ÇEK-DVR‘nın regresyon performansını iyileştirmek için Bölüm 4’de çekirdek polarizasyonu ele alınmıştır ve tezin temel fikri olan çekirdek parametresinin çevrimiçi uyarlanması anlatılmıştır. Bölüm 4.2’de çekirdek parametresinin giriş ve öznitelik uzayındaki

etkileri incelenmiştir. Çekirdek parametresinin eğim düşümü yöntemi kullanılarak çevrimiçi uyarlanması Bölüm 4.3'de verilmiştir. Bölüm 4.4.1'de çekirdek parametresine katılan çevrimiçi adaptasyon yeteneğinin tanılama üzerindeki etkileri farklı ilk koşullar kullanılarak sürekli karıştırmalı tank reaktörü üzerinde gerçeklenmiştir. Uyarlamanın regresyon performansına katkılarından bahsedilmiştir. Sabit çekirdek değerine ve uyarlamalı çekirdeğe sahip çevrimiçi modeller Bölüm 4.4.2'de sistemin kontrolü için kullanılan uyarlamalı PID nin parametrelerinin ayarlanmasında kullanılmıştır. Önerilen çekirdek uyarlamasının kontrolör üzerindeki etkilerini incelemek için kontrolör gürültülü ve bozucu etkili ortamlarda test edilmiştir. Kontrolörün dayananıklılığını test etmek için sistemin sabit parametrelerine dinamikler etklenerek kontrolörlerin dayanıklılığı test edilmiştir. Tezde elde edilen sonuçlarla ilgili kısa bir tartışma Bölüm 5'de sunulmuştur.

2. DESTEK VEKTÖR MAKİNELERİ

2.1 Giriş

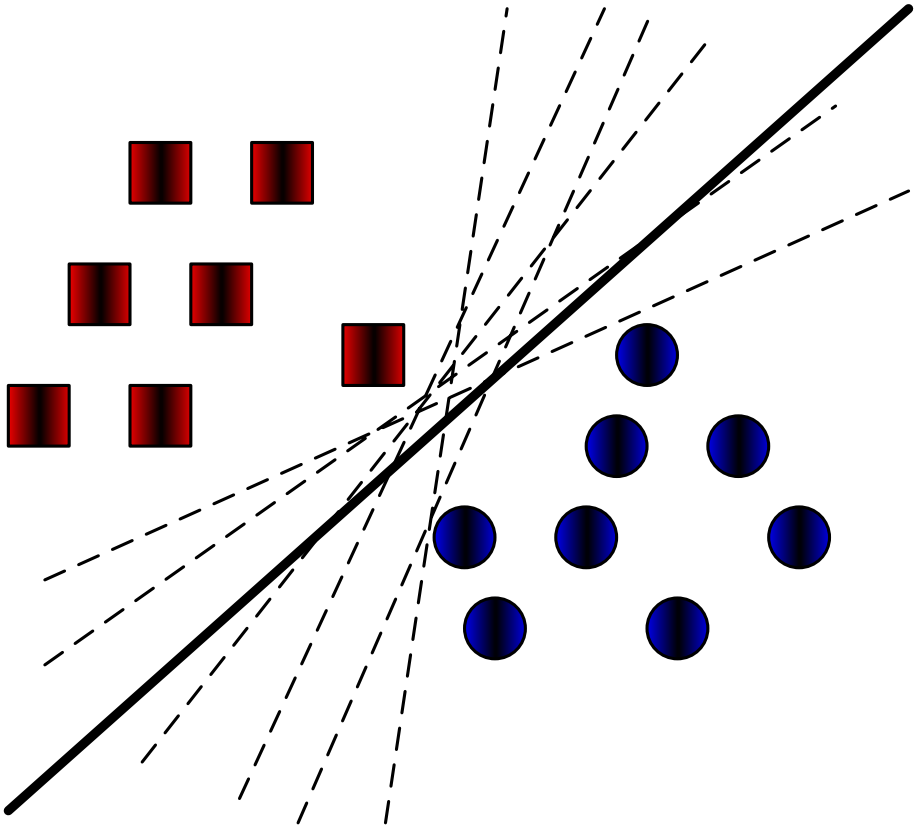
DVM algoritmaları istatistiksel öğrenme teorisi ve yapısal risk minimizasyonuna dayanmaktadır. DVM'lerin üstünlüğü sınıflandırma ve regresyon problemlerini lokal minimaya takılmadan çözebilmeleridir [16]. Problemi karesel programlama problemine dönüştürerek global minimayı elde edebilmektedirler [16].
Son zamanlardaki çalışmalarda, YSA'da kullanılan emprik risk minimizayonu yerine yapısal risk minimizasyonuna dayanmalarından dolayı [16], birçok sınıflandırma ve regresyon probleminin çözümünde YSA yerine DVM kullanılmıştır [3,6,20].
Üstün genelleme yeteneklerinden dolayı DVM hem sınıflandırma hemde regresyon problemlerinin çözümünde başarılı bir şekilde kullanılmaktadır. Kanser hücreleri için gen seçimi [3], yüz tanıma [4], ve internette saldırı tespiti [5] DVS nin örüntü sınıflandırıcı olarak kullanıldığı alanlardan bazılarıdır. Mikrodalga geçişlerinin modellenmesi [6], robot manipulatör kontrolü [7], model öngörülü kontrol [8] ve PID kontrolör parametrelerinin uyarlanması [9,10] DVR nin tanılama için kullanıldığı uygulamalardır.

Bu bölümde sınıflandırma ve regresyon problemlerine çözüm getirmek üzere tasarlanmış ve birçok farklı alanda uygulamaları bulunan DVM açıklanacaktır.

2.2 Doğrusal Sınıflandırma

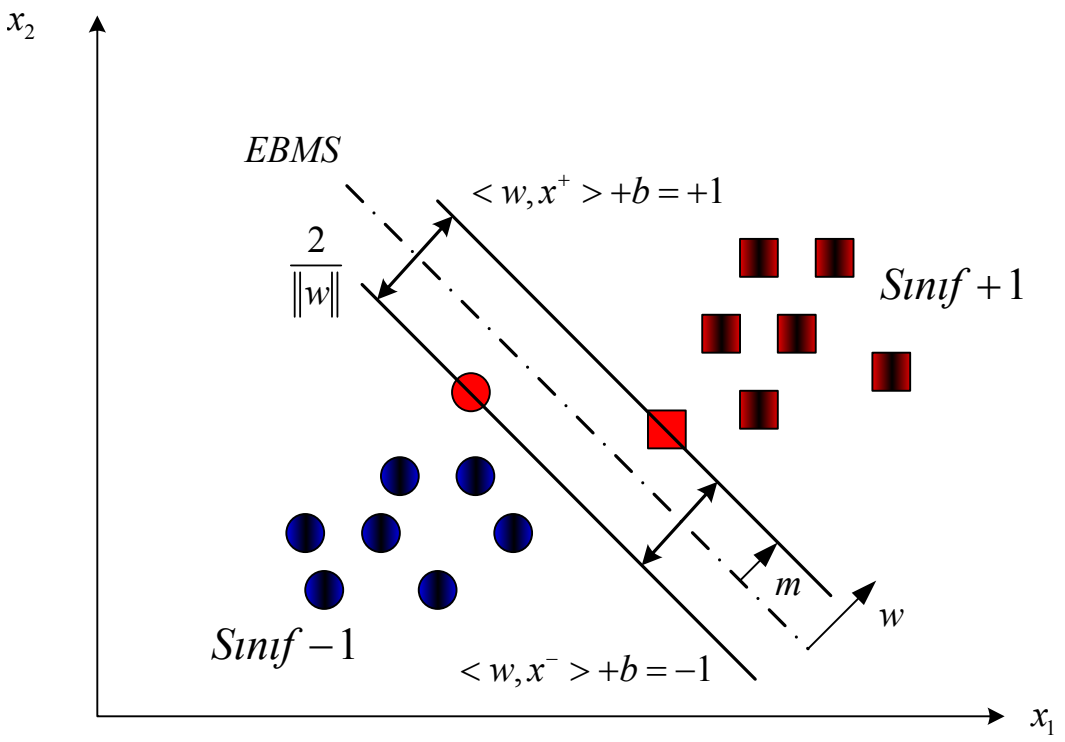
Sınıflandırma problemleri, için önce 2 sınıfın birbirinden ayırt edilmesi durumu ele alınacaktır. Daha sonra bu, daha fazla sınıf için genelleştirilebilir. Sınıflandırma problemlerinde amaç iki sınıfı birbirinden ayıran uygun sınıflandırıcı fonksiyonunu bulmaktır. Amaç var olmayan veriler için bile en iyi doğrusal sınıflandırıcı düzlemi bulmaktır. Şekil 2.1 deki veri grubunu düşünelim. İki sınıfın arasındaki maksimum uzaklığa marjin adı verilmektedir. Bu iki sınıfı ayıracak sonsuz sayıda doğru bulunmaktadır. Fakat marjini maximize eden sadece bir tane doğru bulunmaktadır. Bu doğru en iyi ayırıcı hiper düzlem olarak adlandırılmaktadır. DVM'de amaç,

sınıflandırma problemini karesel programlama problemine dönüştürerek, en iyi hiper düzlemi temsil eden global minimumu bulmaktır.



Şekil 2.1 : En iyi ayırıcı hiper düzlem.

$S = \{\mathbf{x}_k, y_k\}_{k=1}^{N}$, $\mathbf{x}_k \in R^n$, $y_k \in \{-1,+1\}$ şeklinde verilen veri kümesini düşünelim. $\mathbf{x}_k$ *k.* verinin *n* boyutlu uzaydaki yerini belirten vektörü, y_k da ona karşı düşen sınıfı (pozitif veya negatif) göstermektedir. İki sınıftan oluşan bir veri kümesindeki verileri, $\boldsymbol{w}$ ağırlık vektörü, b de eşik değeri, ve $\langle . \rangle$ iç çarpım olmak üzere $\langle \mathbf{w}, \mathbf{x} \rangle + b = 0$ şeklinde bir karar düzlemi ile ayrılabilmektedir. Şekil 2.1'den görüldüğü gibi pek çok karar düzlemiyle bu sınıflandırmayı yapmak mümkündür. Ancak mevcut karar düzlemleri içinde en iyisi, sınıflandırmayı hatasız yapan ve kendine en yakın vektörlere olan uzaklığı en büyük olan düzlemdir. Bu düzleme *En Büyük Marjinli Sınıflandırıcı* (EBMS) adı verilmektedir. Bu düzleme en yakın vektörler karesel programlama sonucunda Lagrange çarpanları sıfırdan farklı olan veriler diğer bir değişle *destek vektörleri* olarak adlandırılırlar. Artık sınıflandırıcının temsil edilmesinde, Lagrange çarpanları sıfırdan farklı eğitim verilerinin yani sadece destek vektörlerinin bilinmesi yeterlidir.



Şekil 2.2 : En iyi ayırıcı hiper düzlem ve destek vektörler.

Şekil 2.2'den görüleceği gibi , EBMS, $\mathbf{x}^+$ pozitif sınıfına, $\mathbf{x}^-$ negatif sınıfına ait bir destek vektörü(DV) olmak üzere, $\langle \mathbf{w}, \mathbf{x}^+ \rangle + b = +1$ ve $\langle \mathbf{w}, \mathbf{x}^- \rangle + b = -1$ fonksiyonel marjinleri arasındaki uzaklığı en büyük olan düzlemi bulmaya çalışır. Bu uzaklık *geometrik marjin* olarak adlandırılır ve

$$m = \frac{1}{\|w\|} \tag{2.1}$$

şeklindedir. (2.1)'den görüldüğü gibi EBMS bulmakla minimum normlu ağırlıklara sahip düzlemi bulmak aynıdır. Böylece EBMS düzlemin bulunması aşağıdaki optimizasyon problemine dönüşmektedir:

$$\min_{w,b} \ \frac{1}{2}\|w\| \qquad \text{Kısıtlamalar:} \quad y_i(\langle w, x_i \rangle + b) \geq 1 \ , \ \ i = 1, 2, \cdots, N \tag{2.2}$$

(2.2) optimizasyon probleminin primal formu olarak adlandırılmaktadır. DVM'de ana fikir, primal amaç fonksiyonu ve kısıtlardan Lagrange fonksiyonu oluşturmaktır.

(2.2)'deki amaç fonksiyonu ve kısıtlar kullanılarak Lagrange fonksiyonu aşağıdaki gibi türetilir:

$$L(\mathbf{w},b,\boldsymbol{\alpha}) = \frac{1}{2}\langle \mathbf{w},\mathbf{w}\rangle - \sum_{i=1}^{N}\alpha_i\left[y_i\left(\langle \mathbf{w}_i,\mathbf{x}_i\rangle + b\right)-1\right] \qquad \textbf{(2.3)}$$

Burda $L(\mathbf{w},b,\boldsymbol{\alpha})$ Lagrange fonksiyonunu, α_i ise Lagrange çarpanlarını göstermektedir. Lagrange fonsiyonu, çözümde, primal ve dual değişkenler cinsinden semer noktasına sahip olduğu için, optimallik için primal değişkenlerin türevi sıfıra eşitlenir :

$$\begin{aligned}\frac{\partial L(\mathbf{w},b,\alpha)}{\partial \mathbf{w}} &= \mathbf{w} - \sum_{i=1}^{N} y_i\alpha_i\mathbf{x}_i = 0\\ \frac{\partial L(\mathbf{w},b,\alpha)}{\partial b} &= \sum_{i=1}^{N} y_i\alpha_i = 0\end{aligned} \qquad \textbf{(2.4)}$$

Buradan en iyi düzleme ilişkin ağırlık vektörü aşağıdaki gibi bulunur:

$$\mathbf{w}^* = \sum_{k=1}^{N} y_k\alpha_k^*\mathbf{x}_k \qquad \textbf{(2.5)}$$

Primal değişkenlerin Lagrange çarpanları cinsinden değerleri yazılırsa:

$$L(\mathbf{w},\mathbf{b},\alpha) = \sum_{i=1}^{N}\alpha_i - \sum_{i=1}^{N}\sum_{j=1}^{N} y_iy_j\alpha_i\alpha_j\left\langle \mathbf{x}_i,\mathbf{x}_j\right\rangle \qquad \textbf{(2.6)}$$

ifadesi elde edilir.

Lagrange çarpanları $\alpha_k \geq 0$ olmak üzere Lagrangian ifadesi yazılırsa problemin dual ifadesi aşağıdaki gibi elde edilir:

$$\begin{aligned}&\max_{\alpha} \sum_{i=1}^{N}\alpha_i - \frac{1}{2}\sum_{i=1}^{N}\sum_{j=1}^{N} y_iy_j\alpha_i\alpha_j\left\langle \mathbf{x}_i\mathbf{x}_j\right\rangle\\ &\text{Kısıtlamalar:}\\ &\sum_{i=1}^{N} y_i\alpha_i = 0,\ \alpha_i \geq 0\end{aligned} \qquad \textbf{(2.7)}$$

Unutulmamalıdırki, bir problemin primal formunu minimize etmek, dual formunu maximize etmektir.

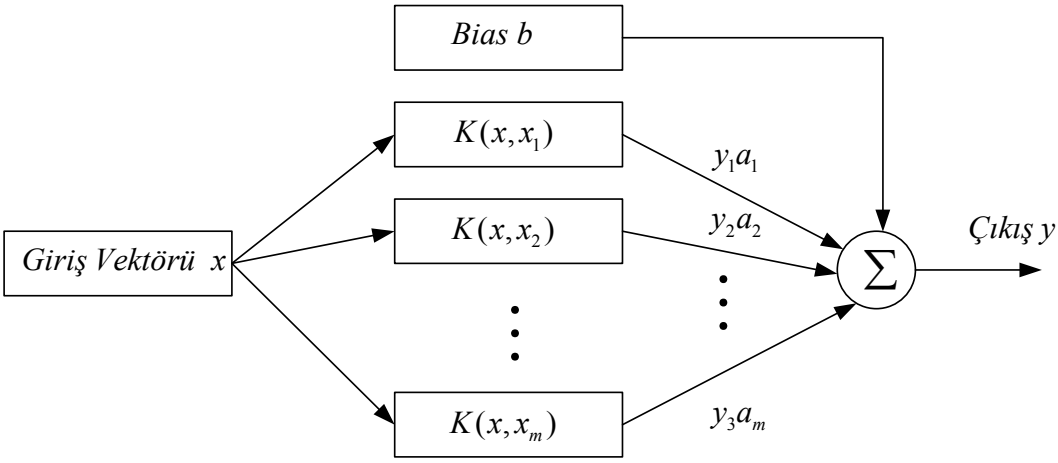
Eşik değeri olan b^* değeri dual problemde gözükmediği için primal kısıtlamalardan yola çıkılarak değeri hesaplanmalıdır:

$$b^* = -\frac{\max_{y_i=-1}\left(\left\langle \mathbf{w}^*, \mathbf{x}_i \right\rangle\right) + \min_{y_i=1}\left(\left\langle \mathbf{w}^*, \mathbf{x}_i \right\rangle\right)}{2} \tag{2.8}$$

Bu problem herhangi bir QP (quadratic programming) çözücü algoritmasıyla çözülebilir. Sınıflandırıcı modeli aşağıdaki gibi modellenebilir:

$$\begin{aligned} f\left(\mathbf{x}, \alpha^*, b^*\right) &= \sum_{i=1}^{N} y_i \alpha_i^* \left\langle \mathbf{x}, \mathbf{x}_i \right\rangle + b^* \\ &= \sum_{i \in DV} y_i \alpha_i^* \left\langle \mathbf{x}, \mathbf{x}_i \right\rangle + b^* \end{aligned} \tag{2.9}$$

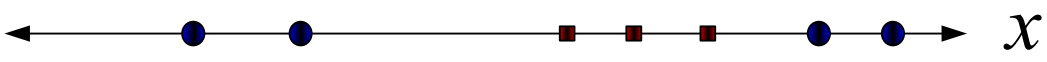
Ayırıcı düzleme en yakın noktalardaki vektörlere ilişkin Lagrange çarpanları sıfırdan farklı diğerleri ise sıfırdır. Sıfırdan farklı Lagrange çarpanlarına sahip eğitim verileri destek vektörler(DV) olarak adlandırılır. Toplam ifadesindeki DV destek vektörleri kümesini ifade etmektedir. Modelde sadece destek vektörleri ve onlara ait çarpanlar bulunur. Şekil 2.3'de DVM'nin ağ yapısı verilmiştir.



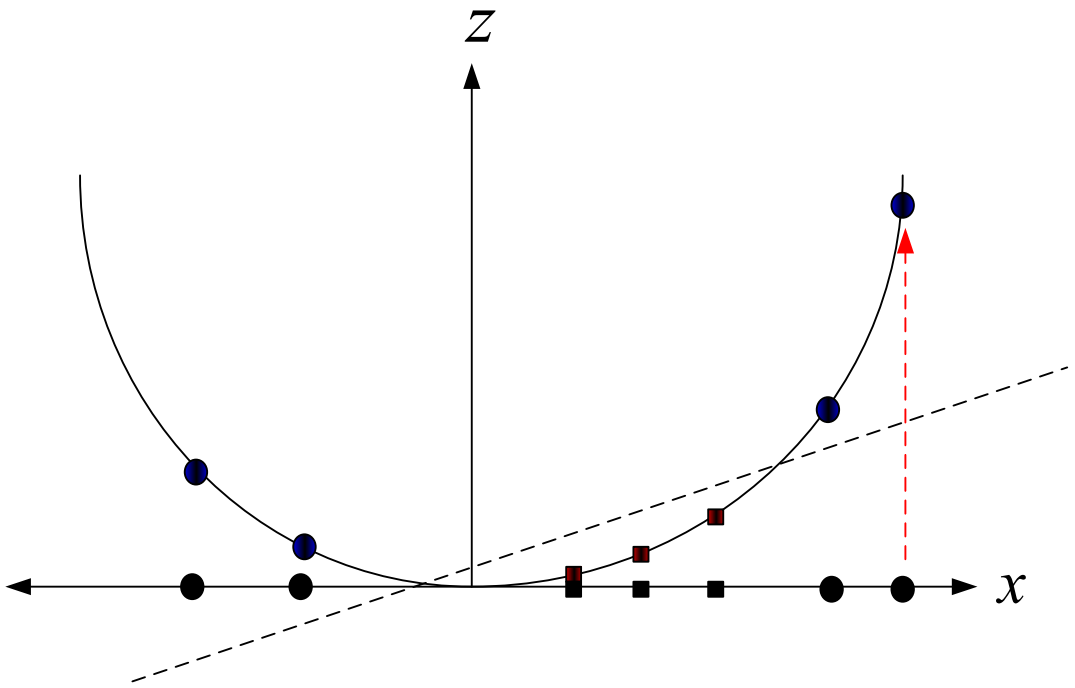
Şekil 2.3 : Destek vektör sınıflandırıcının ağ yapısı.

2.3 Çekirdek Yaklaşımı

Doğrusal bir sınıflandırmanın mümkün olmadığı durumda, giriş vektörü *x*, yüksek dereceden, doğrusal sınıflandırmanın gerçekleştirilebileceği bir öznitelik uzayına adreslenir. Şekil 2.4-2.5 den görüldüğü gibi doğrusal olarak ayrıştırılamayan veriler çekirdek fonksiyonu yardımıyla daha yüksek dereceden bir uzaya taşınmıştır.



Şekil 2.4 : Doğrusal olarak ayrıştırılamayan veriler.



Şekil 2.5 : Doğrusal olarak ayrıştırılamayan verilerin çekirdek ile haritalanması.

Şekil 2.4'den görüldüğü gibi çekirdek yaklaşımı verilerin doğrusal olarak ayrıştırılabilecekleri bir uzaya haritalanmalarına olanak sağlamaktadır. Çekirdek yaklaşımı doğrusal sınıflandırma için geçerli olan formüllerin, doğrusal olmayan sınıflandırma için de kullanılmalarına olanak tanımaktadır. Bu noktada, belirlenecek doğru çekirdek fonksiyonu ile yüksek boyutlu öznitelik uzayına geçilerek giriş uzayında yapılacak işlemlere bu yeni uzayda olanak verilir ve iç çarpımların öznitelik uzayında hesaplanması gerekmez [45]. Bu teori, "Çekirdek Hilbert Uzayının yeniden türetimine (Reproducing Kernel Hilber Spaces(RKHS)) dayanır [45]. Çekirdek fonksiyonuna dayanan, öznitelik uzayına adreslenmeyi daha iyi açıklamak için iki boyutlu verileri 3 boyutlu öznitelik uzayına taşıyan Φ dönüşümünü aşağıdaki gibi tanımlayalım;

$$\Phi : R^2 \longrightarrow R^3 ; \quad z = \Phi\left(\begin{bmatrix} x_1 \\ x_2 \end{bmatrix}\right) = [z_1 \;\; z_2 \;\; z_3]^T = [x_1^2, \sqrt{2}x_1x_2, x_2^2]^T \qquad \textbf{(2.10)}$$

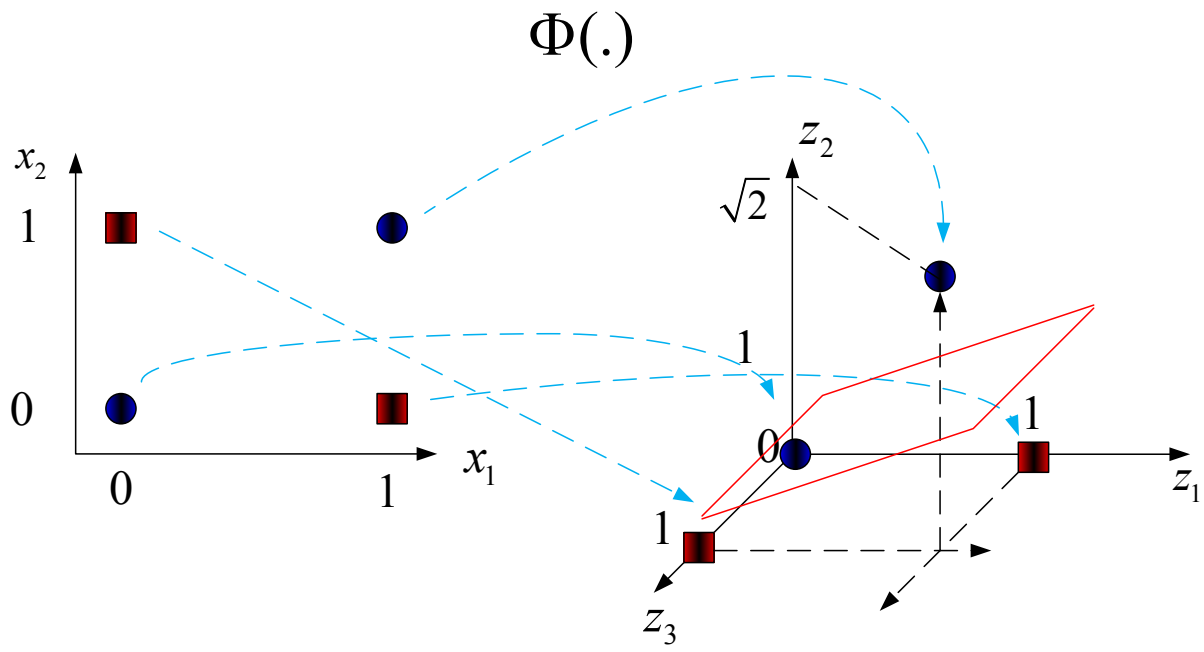
(2.10)'daki öznitelik uzayına taşınmış veriyi doğrusal bir sınıflandırıcı ile ayırmak istersek R^3 de $\underline{w}^T \underline{z} + b = 0$ biçiminde olan hiperdüzlem olacaktır. Bu hiperdüzlem x cinsinden;

$$w^T z + b = w_1 z_1 + w_2 z_2 + w_3 z_3 + b = w_1 x_1^2 + w_2 \sqrt{2} x_1 x_2 + w_3 x_2^2 + b = 0 \qquad \textbf{(2.11)}$$

şeklinde yazılır. Örnek olarak XOR problemini ele alalım. (2.11) yardımı ile giriş uzayındaki veriler ve giriş verilerinin öznitelik uzayındaki lokasyonları aşağıdaki gibidir.

x_1	x_2	C		z_1	z_2	z_3	C
0	0	0		0	0	0	0
0	1	1	$\xrightarrow{\Phi(.)}$	0	0	1	1
1	0	1		1	0	0	1
1	1	0		1	$\sqrt{2}$	1	0

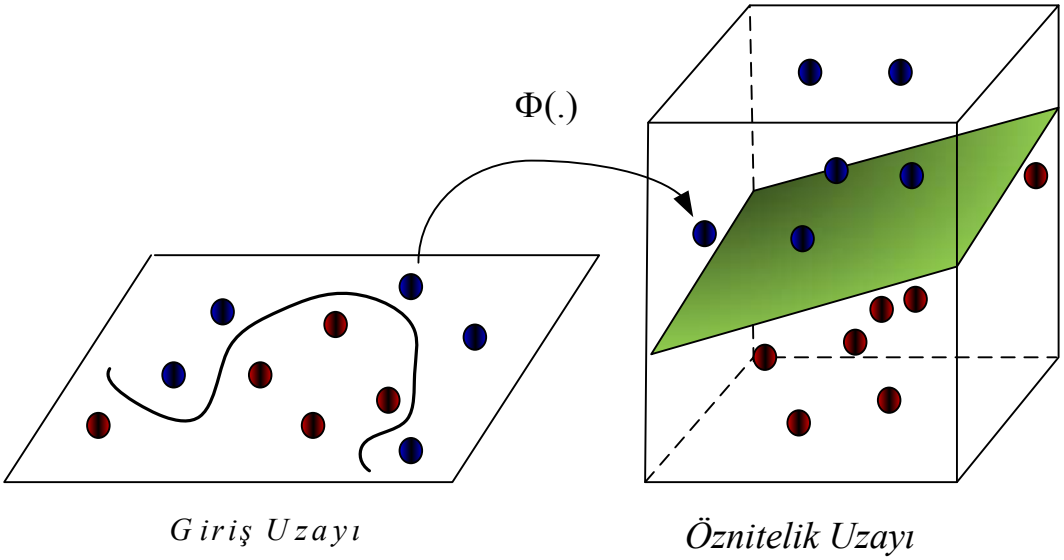
Verilerin giriş ve öznitelik uzayındaki lokasyonları şekil 2.6'da görselleştirilmiştir.



Şekil 2.6 : Doğrusal olarak ayrıştırılamayan verilerin haritalanması.

Şekil 2.6 ve (2.11)' den görülebileceği gibi, çekirdek yaklaşımı 2 boyutlu giriş uzayında doğrusal olarak ayrıştıralamayan verinin 3 boyutlu öznitelik uzayında doğrusal olarak ayrıştırılmasına olanak tanımaktadır.

2.4 Doğrusal Olmayan Sınıflandırma



Şekil 2.7 : Doğrusal olarak ayrıştırılamayan verilerin haritalanması.

Doğrusal olmayan sınıflandırmada, verilerin doğrusal olarak sınıflandırılabilecekleri öznitelik uzayına boyutsal adreslenmelerinde çekirdek yaklaşımı kullanılır. Veriler doğrusal sınıflandırmanın yapılabileceği uzaya taşındıktan sonra doğrusal sınıflandırmada kullanılan formülasyonlar bu uzayda geçerliliğini korumaktadır. Şekil 2.7'de verilerin çekirdek fonksiyonu ile öznitelik uzayına taşınmaları gösterilmiştir. Çekirdek fonksiyonu ile veriler öznitelik uzayına taşınır ve iç çarpım bu uzayda gerçekleştirilir. Doğrusal formülasyonlarda $\langle \mathbf{x}_i, \mathbf{x}_j \rangle$ iç çarpımı yerine $K(\mathbf{x}_i, \mathbf{x}_j)$ kullanılacaktır. $K(\mathbf{x}_i, \mathbf{x}_j)$ çekirdek fonksiyonunu göstermektedir. Böylece primal problem aşağıdaki gibi elde edilir.

$$\max_{\alpha} \quad \sum_{i=1}^{N} \alpha_i - \frac{1}{2} \sum_{i=1}^{N} \sum_{j=1}^{N} y_i y_j \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j)$$

Kısıtlamalar: **(2.12)**

$$\sum_{i=1}^{N} y_i \alpha_i = 0, \alpha_i \geq 0$$

2.5 Doğrusal Regresyon

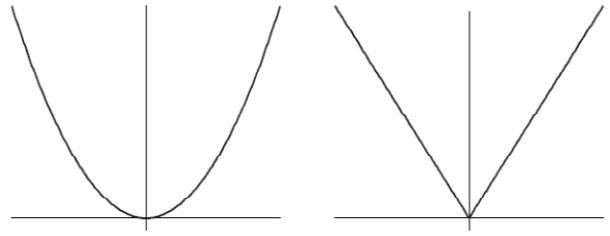
Regresyon problemi, istenilen çıkış değişkenleri ile giriş değişkenleri arasındaki f(x) haritalama fonksiyonunun bulunması problemidir. Giriş ve çıkış verilerinin

$$(y_{1,}\underline{x}_1).....(y_n\underline{x}_n)\ ,\ \ \underline{x}\in R^n, y\in R$$
$$n=1,2,\cdots,n \qquad \textbf{(2.13)}$$

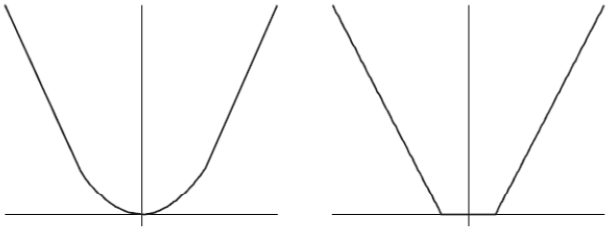
şeklinde verildiğini düşünelim. Burada $\underline{x}$ n boyutlu uzayın elemanı olan giriş vektörünü, y ise bu giriş vektörlerine karşı düşen çıkış değerini ifade eder. Ayrıca n giriş verisinin boyutudur.

Sınıflandırma problemlerinde başarıyla uygulanan DVM, alternatif bir kayıp fonksiyonunun verilmesiyle regresyon problemlerine uygulanabilmektedir [20]. Şekil 2.8'de olası 4 kayıp fonksiyonu verilmiştir [20].

2.8 a'da gösterilen kayıp fonksiyonu geleneksel en küçük kareler hata kriterini temsil etmektedir [20]. Şekil 2.8 b'de ise hatalı verilere karasel kayıp fonksiyonundan daha az duyarlı olan laplasyan kayıp fonksiyonu betimlenmiştir [20].
Huber, verilerin temel dağılımı bilinmediğinde optimal özelliklere sahip olan güçlü(kaba) bir kayıp fonksiyonuna benzer bir fonksiyon olarak önerdi (Şekil 2.8 c) [20].



(a)Karasel (b) En Küçük Kareler



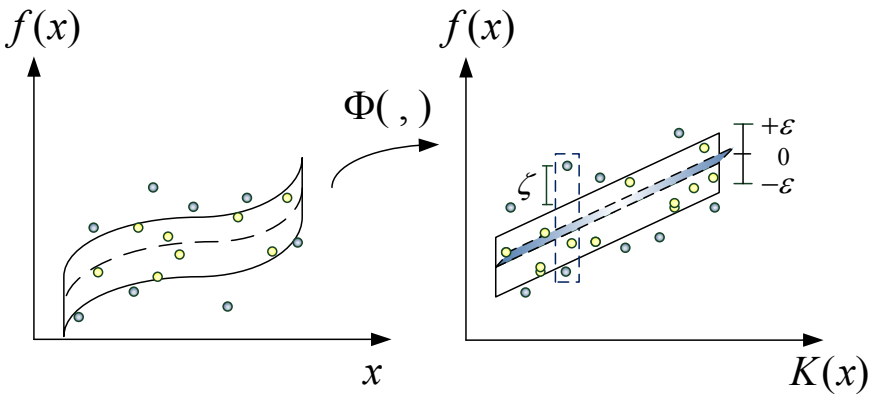
(c) Huber (d) ε-toleranslı

Şekil 2.8 : Kayıp fonksiyonları.

. Şekil 2.8 a,b,c'deki kayıp fonksiyonları destek vektörü olarak bütün verilerini kullanma ihtimallerinin olmasıdır nedeniyle pek kullanılmazlar. Bu nedenle daha çok ε-toleranslı kayıp fonksiyonu kullanılır. ε-toleranslı kayıp fonksiyonunun

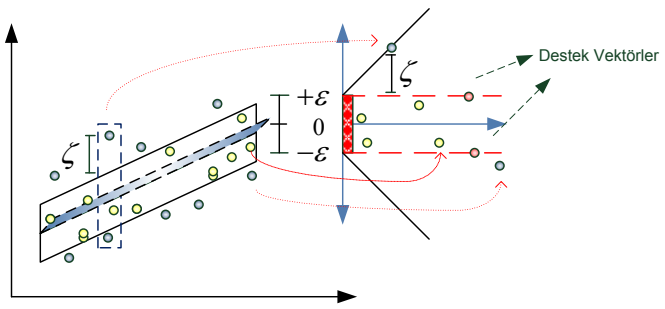
kullanılması sonucu regresyon probleminde bazı verilerin ε-toleransla hatalı temsil edilmelerine izin verilmektedir. Diğer bir değişle hatası ε a eşit veya daha küçük veriler hatasız olarak temsil edilmektedirler. ε-toleranslı kayıp fonksiyonu sayesinde optimizasyon probleminin başında regresyon problemindeki maksimum eğitim hatası belirlenebilmektedir. Maksimum eğitim hatasının ε gibi bir parametreyle baştan belirlenebilmesi, DVM'nin YSA'ya göre en önemli üstünlüklerinden bir tanesidir.

2.6 Doğrusal Olmayan Regresyon



Şekil 2.9 : Çekirdek yaklaşımı.

Sınıflandırma problemlerine benzer biçimde doğrusal olmayan bir model genellikle yeterli model verisine ihtiyaç gösterir. Doğrusal olmayan sınıflandırmada olduğu gibi, doğrusal olmayan regresyonda da doğrusal modellemenin gerçekleştirilebildiği yüksek dereceden öznitelik uzayına haritalama yapılır. Boyutsal adresleme için çekirdek yaklaşımı tekrar kullanılır.



Şekil 2.10 : Kayıp fonksiyonları.

Sıklıkla kullanılan çekirdek fonksiyonları aşağıdaki gibidir [15,20]:

d. dereceden polinom çekirdek fonksiyonu:

$$K\left(\mathbf{x},\mathbf{y}\right)=\left(\mathbf{x}^{T}\mathbf{y}+\mathbf{1}\right)^{d} \tag{2.14}$$

σ genişlikli radyal tabanlı fonksiyonlu çekirdek fonksiyonu:

$$K\left(\mathbf{x},\mathbf{y}\right)=\exp\left(-\frac{\left\|\mathbf{x}\text{-}\mathbf{y}\right\|^{2}}{2\sigma^{2}}\right) \tag{2.15}$$

Parametreleri (κ,θ) çifti ile verilen sigmoid fonksiyonlu çekirdek fonksiyonu:

$$K\left(\mathbf{x},\mathbf{y}\right)=\tanh\left(\kappa\mathbf{x}^{T}\mathbf{y}+\theta\right)^{d} \tag{2.16}$$

Doğrusal regresyondaki formüllerde $\langle \underline{x}_i, \underline{x}_j \rangle$ şeklindeki iç çarpımların yerine $K(\underline{x}_i, \underline{x}_j)$ kullanılarak bütün formüller doğrusal olmayan regresyon durumu için uyarlanabilir.

ε-toleranslı kayıp fonksiyonu kullanılarak doğrusal olmayan regresyon çözümü

$$\min_{\alpha_i,\alpha_i^*} \frac{1}{2}\sum_{i=1}^{l}\ \sum_{j=1}^{l}(\alpha_i-\alpha_i^*)(\alpha_j-\alpha_j^*)K(\underline{x}_i,\underline{x}_j)-\sum_{i=1}^{l}[\alpha_i(y_i-\varepsilon)-\alpha_i^*(y_i+\varepsilon)] \tag{2.17}$$

$$0\le\alpha_i\le C \qquad i=1,2,3,,,,,,,,,,l \tag{2.18}$$

$$0\le\alpha_i^*\le C \qquad i=1,2,3,,,,,,,,,,l \tag{2.19}$$

$$\sum_{i=1}^{l}(\alpha_i-\alpha_i^*)=0 \tag{2.20}$$

şeklinde verilir. Bu karesel problemin çözümü ile α_i ve α_i^* Lagrange çarpanları belirlenir.

Böylece regresyon fonksiyonu

$$f(\underline{x})=\sum_{i\in DV}(\alpha_i-\alpha_i^*)K(\underline{x}_i,\underline{x})+b \tag{2.21}$$

şeklinde tanımlanır. Burada;

$$\langle \underline{w},\underline{x}\rangle=\sum_{i\in DV}(\alpha_i-\alpha_i^*)K(\underline{x}_i,\underline{x}) \tag{2.22}$$

$$b=\frac{1}{l}\sum_{i=1}^{l}(y_i-\langle \underline{w},\underline{x}\rangle) \tag{2.23}$$

dir. Diğer kayıp fonksiyonlarında $\langle x_i, x_j \rangle$ şeklindeki iç çarpımların yerine $K(x_i, x_j)$ kullanılarak bütün formüller doğrusal olmayan regresyona çevrilebilir. Karesel ve

Huber kayıp fonksiyonunda bütün veriler destek vektörü olabilir ve destek vektör çözümü dağınık olabilir.

ε-toleranslı kayıp fonksiyonu karesel ve Huber kayıp fonksiyonlarına benzemediği için daha kullanışlıdır.

3. DESTEK VEKTÖR MAKİNALARININ SİSTEM TANIMA VE KONTROLÖR TASARIMINDA KULLANIMI

3.1 Giriş

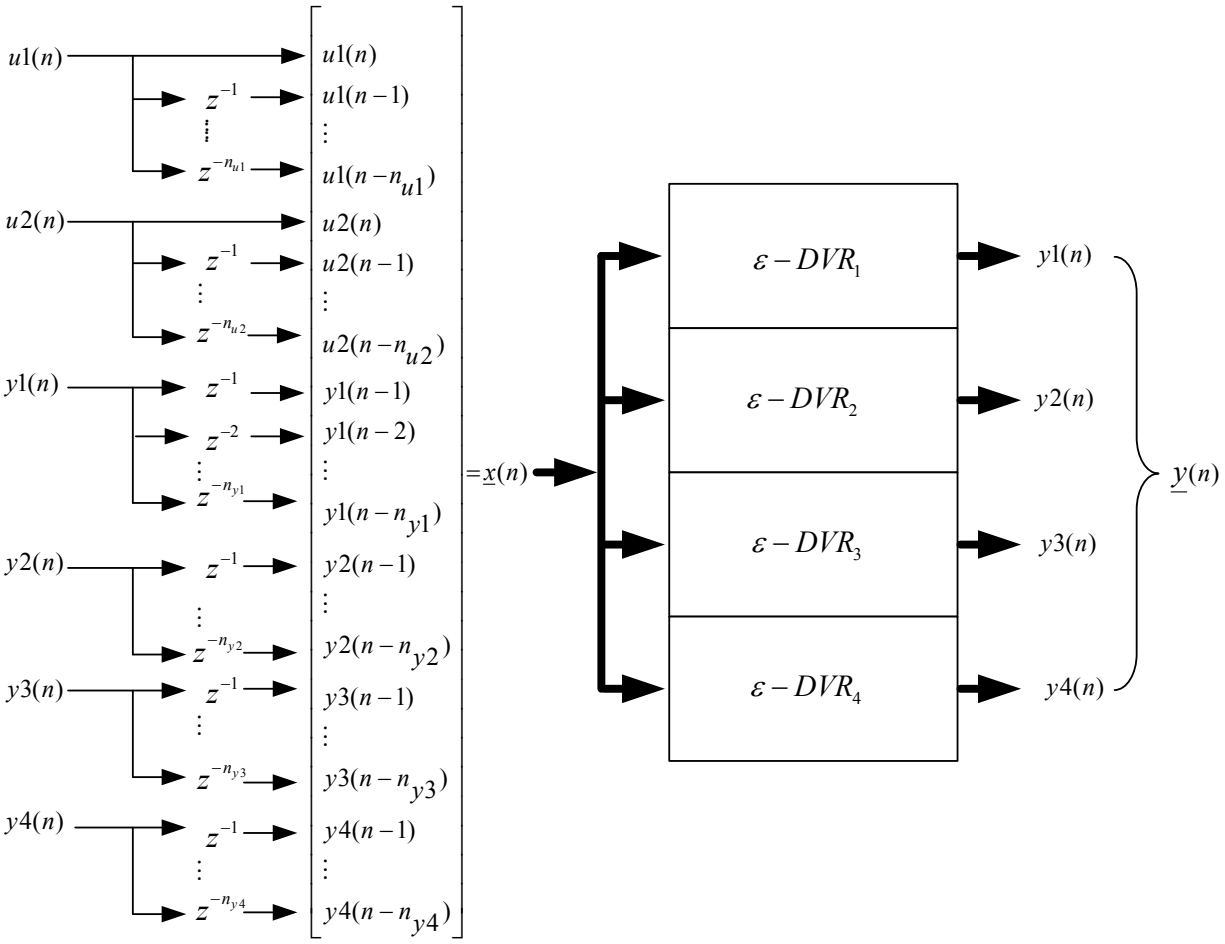
Sistem tanıma problemi, sistemin girişi ile çıkışı arasındaki haritalama fonksiyonunun bulunması problemidir. Sistem tanıma problemlerinin özelliği tanılama probleminin regresyon problemine dönüştürülmesidir. YSA, bulanık mantık(BM) ve USBÇS temelli modeller sistem dinamiklerinin kestirimi için başarılı modeller elde edilmesine olanak sağlamaktadır. Son yıllarda global minimumu garanti ettikleri için DVM temelli modeller sıklıkla kullanılmaktadır.

YSA, BM ve USBÇS'nin ortak özelliği, öğrenme algoritmaları ve konveks olmayan amaç fonksiyonlarından dolayı lokal minimuma takılmaları sonucunda lokal model oluşmasına neden olmalarıdır. DVM'de amaç fonksiyonu konveks, optimizasyon problemi kısıtlı optimizasyon problemidir. Bu nedenle sistem dinamiklerinin kestirimi için çok iyi bir tanılama aracı olarak kullanılabilmektedirler. Model tabanlı uyarlamalı kontrolörlerin başarısı doğrudan modelin başarısına bağlıdır. Bu nedenle, DVM'nin sistem tanımadaki başarısından yararlanarak, DVM temelli kontrolör yapıları son zamanlarda sıklıkla kullanılmaktadır.

Veri örneklemeye dayalı sistem tanıma problemlerinde amaç öncelikli olarak sistemin mümkün olan bütün dinamiklerinin ortaya çıkarılmasıdır. Doğrusal olmayan sistemlerde sistemin dinamiklerinin ortaya çıkarılması için farklı genlik ve genişliklere sahip, sistemin giriş işaretinin sınırları içinde rastgele değişen basamak işaretleri kullanılmaktadır. Amaç iyi bir modelleme için sistemin mümkün olduğunca bütün frekans bileşenlerinde uyarılmasıdır. Bölüm 3.2'de DVM ile sistem modelleme ele alınmıştır. Çevrimdışı model tabanlı kontrolör tasarımı bölüm 3.3'de sunulmuştur. ÇEK-DVM ile sistem modelleme ve kontrolör tasarımı sırasıyla, Bölüm 3.4 ve 3.5'de verilmiştir.

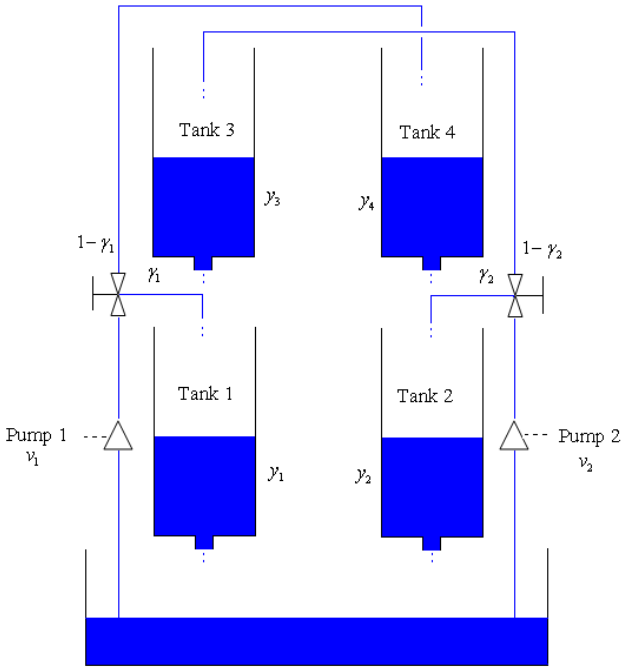
3.2 Destek Vektör Makineleri ile Sistem Tanıma

DVM ile sistem modellemede amaç öncelikli olarak sistemin bütün frekanslarda uyarılarak yeterli model verisi ile eğitilmesidir. Bundan sonra NARX modeli kullanılarak sistem modellenebilmektedir. Eğitim verileri NARX modele göre düzenlendiği zaman tanılama problemi regresyon probleminin çözümüne dönüşmektedir. Sistemin NARX modeli şekil 3.1'de verilmiştir.



Şekil 3.1 : NARX modeli.

Sistemin çok giriş çok çıkışa sahip olması durumunda çıkış sayısı kadar çoklu DVR yapısı kullanılarak sistem modellenebilmektedir. Çoklu sistem modelleme problemine örnek olarak 4'lü su tankı sisteminin dinamiklerinin kestirimi sunulmuştur. Şekil 3.2'de gösterilen 4'lü tank sisteminde, pompaların sağladığı su miktarı, bir valf vasıtasıyla 2 tanka ayrıştırılmaktadır. Böylece 1. pompa 1. tankı ve valf vasıtasıyla belli miktarda suyla 4. tankı doldurmaktadır.



Şekil 3.2 : Dörtlü su tankı sistemi.

Benzer şekilde 2. pompa 2. ve 3. tankı doldurmaktadır. Suyun akış oranı valflerin pozisyonu ile kontrol edilmektedir. Sistemi tanımlayan diferansiyel denklem aşağıdaki gibidir [46]:

$$\begin{aligned}
\frac{d\,h_1}{d\,t} &= -\frac{a_1}{A_1}\sqrt{2gh_1} + \frac{a_3}{A_1}\sqrt{2gh_3} + \frac{\gamma_1 k_1}{A_1} v_1 \\
\frac{d\,h_2}{d\,t} &= -\frac{a_2}{A_2}\sqrt{2gh_2} + \frac{a_1}{A_2}\sqrt{2gh_4} + \frac{\gamma_2 k_2}{A_2} v_2 \\
\frac{d\,h_3}{d\,t} &= -\frac{a_3}{A_3}\sqrt{2gh_3} + \frac{(1-\gamma_2) k_2}{A_3} v_2 \\
\frac{d\,h_4}{d\,t} &= -\frac{a_4}{A_4}\sqrt{2gh_4} + \frac{(1-\gamma_1) k_1}{A_4} v_1
\end{aligned} \qquad \textbf{(3.1)}$$

Bu denklemlerdeki değişkenler aşağıda verilmiştir :

A_i Tank i nin alanı

a_i Tank i nin çıkış deliğinin alanı

h_i Tank i deki su seviyesi

γ_i Tank i için akış oranı

Sistemin kontrol girişleri v_1 ve v_2 (pompaların giriş voltajları) ve kontrol edilen

çıkışlar ise y_1 ve y_2 (sensörlerden okunan voltaj değeri) dir [47]. Literatürde, pompalar doğrudan tank 1 ve tank 2'ye sıvı akışı sağladığı için genellikle y_1 ve y_2 sistemin çıkışları olarak seçilmektedir [46-48]. γ_i , pompa *i* den tank *i (i=1,2)* ye akan sıvı miktarını kontrol eden bir parametredir. Eğer γ_1 1. pompadan 1. tanka aktarılan sıvı oranı olarak alınırsa, 4. tank için sıvı oranı $1-\gamma_1$ ile gösterilir. Benzer şekilde, γ_2 ve $1-\gamma_2$, sırasıyla, 2. pompadan 2. ve 3. tanka aktarılan sıvı akış oranını göstermektedir.

4'lü tank sistemi doğasında 2 tane valf vasıtasıyla ayarlanabilen bir sıfır içermektedir. Sistem, ayarlanabilir sıfırın değişen değerine bağlı olarak minimum ve minimum olmayan faz karakteristiği göstermektedir.

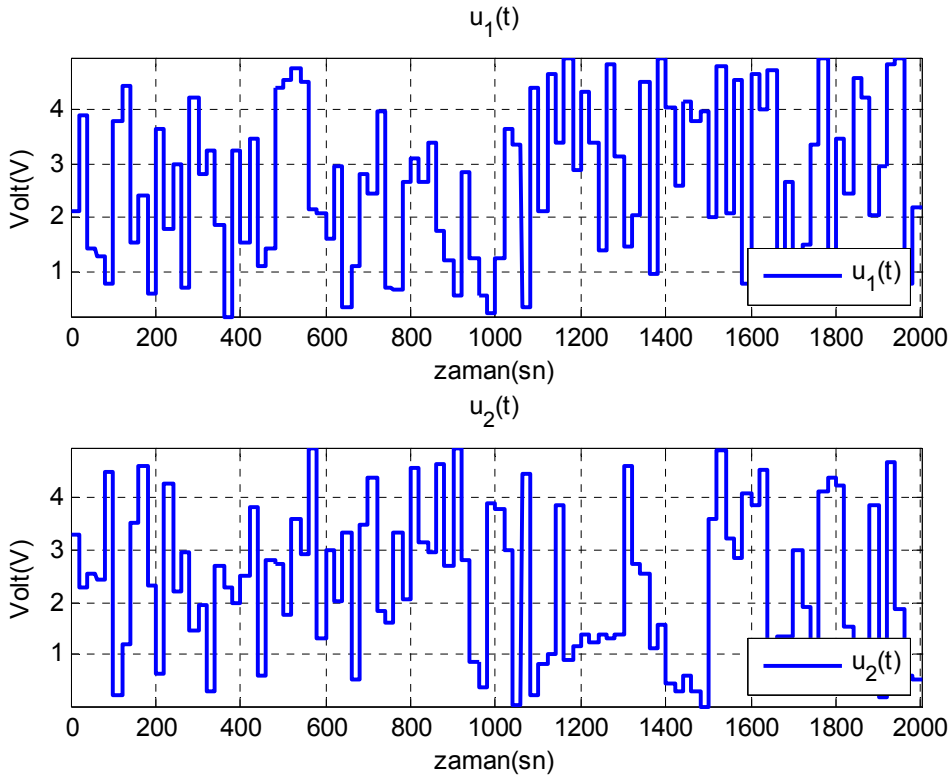
Bu bölümde amacımız sistemin modellenmesi olduğu için sistemin bütün durumlarının kestirimi denenmiştir.

Çizelge 3.1 : Sistemin parametreleri.

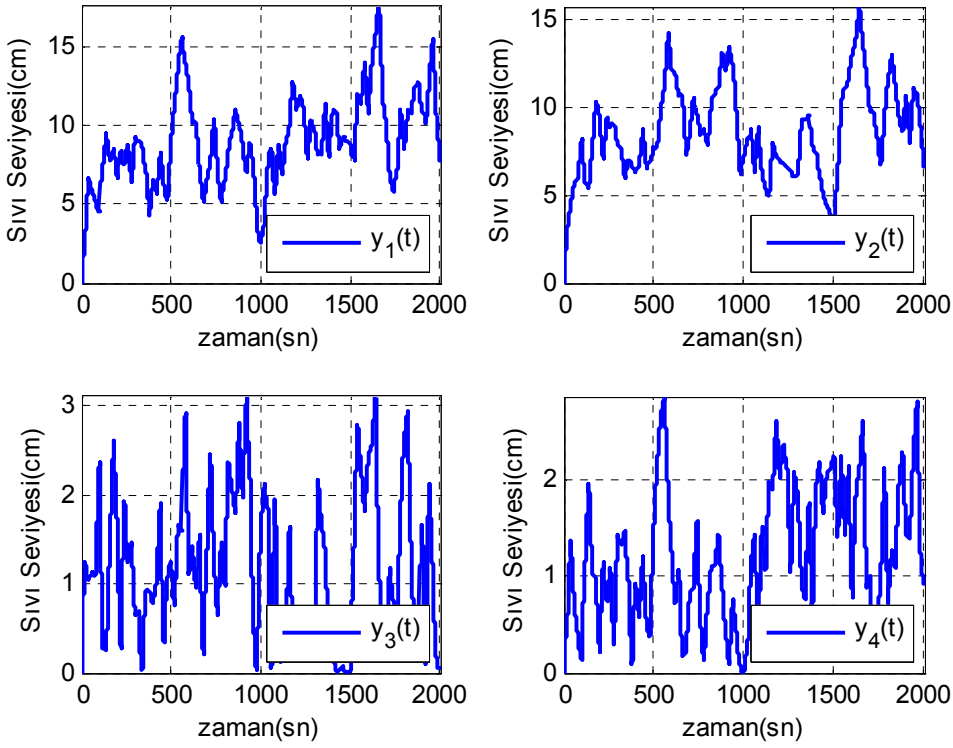
Sembol	Açıklama	Değer
A_1, A_3	Tankların taban alanı	$28 cm^2$
A_2, A_4	Tankların taban alanı	$32 cm^2$
$a_1\ a_3$	Boşaltma borularının alanı	$0.071 cm^2$
$a_2\ a_4$	Boşaltma borularının alanı	$0.057 cm^2$
k	Kalibrasyon Parametresi	$0.5\ V/cm$
g	Yer çekimi sabiti	$981 cm/s^2$

Bu nedenle, modelimizde v_1 ve v_2 sistemin girişi ve tanklardaki sıvı miktarları y_1, y_2 y_3 ve y_4 ise sistemin çıkısı olarak ele alınmıştır. Sisteme ait fiziksel parametreler çizelge 3.1'de listelenmiştir.

Sistem modelleme için öncelikli olarak yeterli ve iyi bir modelleme verisi toplamak gereklidir. Bu amaçla sistem mümkün olan bütün frekanslarda sarsılır. Şekil 3.3'de sistemin sarsılması için kullanılan giriş işaretleri ve buna karşılık sistemin cevabı verilmiştir.

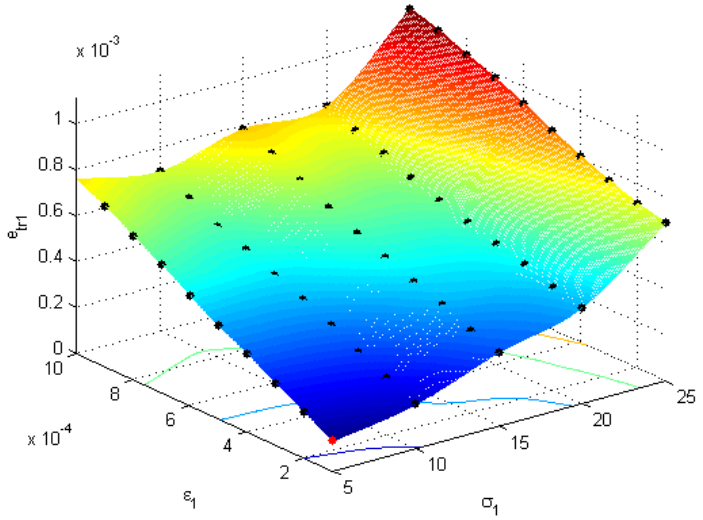


Şekil 3.3 : Giriş işaretleri.

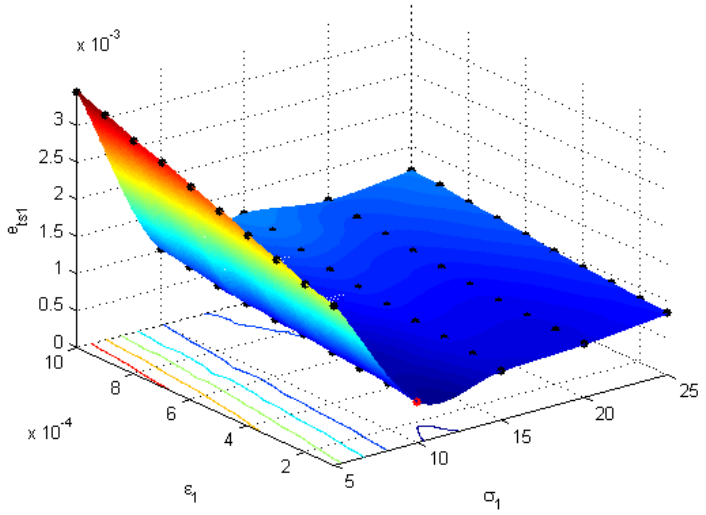


Şekil 3.4 : Sistemin çıkışları.

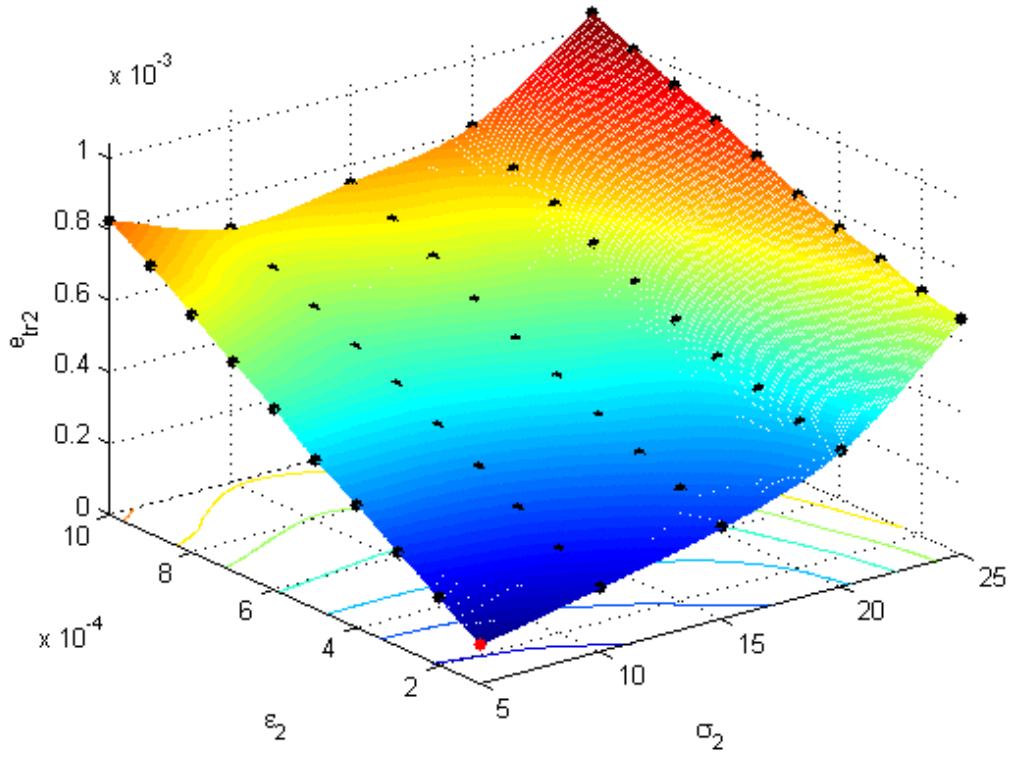
Şekil 3.3 ve şekil 3.4'den görüldüğü üzere sistem mümkün olan bütün frekanslarda uyarılmıştır. Tanılama problemi için şekil 3.4'deki sistemin cevabından rastgele 300 tane eğitim ve 300 tane test verisi toplanmıştır. Eğitim ve test verileri şekil 3.1'deki gibi NARX modeline göre düzenlendiğinde sistem dinamiklerinin öğrenilmesi problemi, regresyon problemine dönüşmektedir. (2.21)'deki regresyon modelinin oluşturulması için eşik değeri ve Lagrange çarpanlarının belirlenmesi gerekmektedir. Problemin çözümü için karesel problem çözücü olarak matlab optimizasyon araç kutusundaki "quadprog" programı kullanılmıştır. En iyi çekirdek parametrelerinin belirlenmesi için ızgara arama algoritmasından yaralanılmıştır. Sistemin en iyi çekirdek parametresi araştırması şekil 3.5-3.12'de verilmiştir.



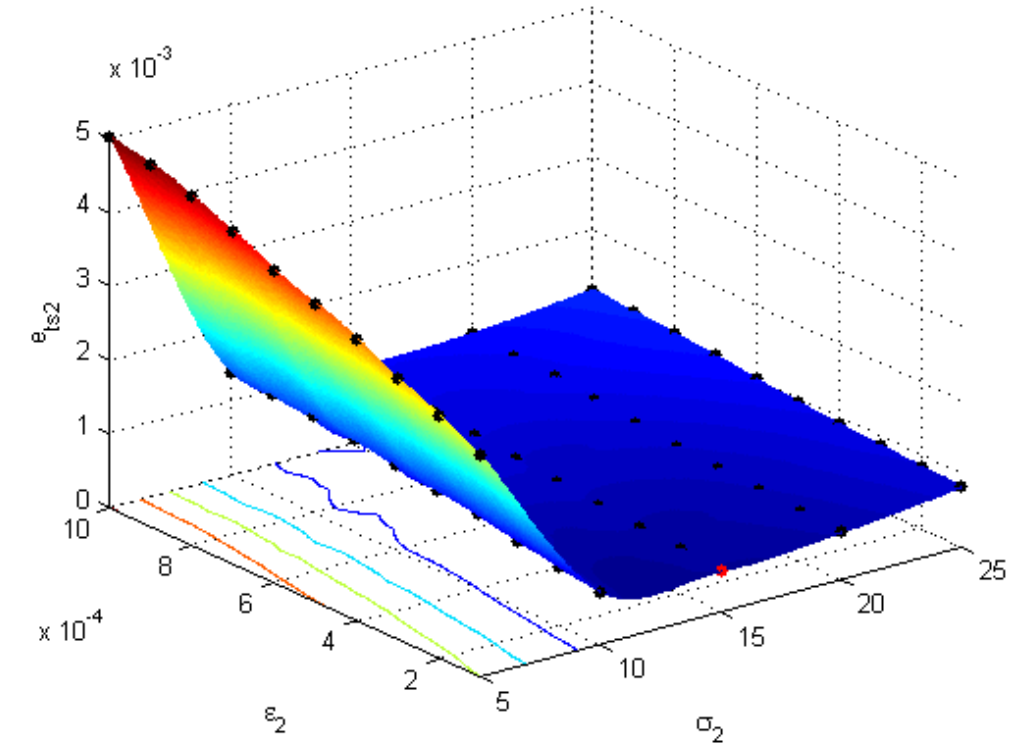
Şekil 3.5 : DVR 1 eğitim hatası yüzeyi.



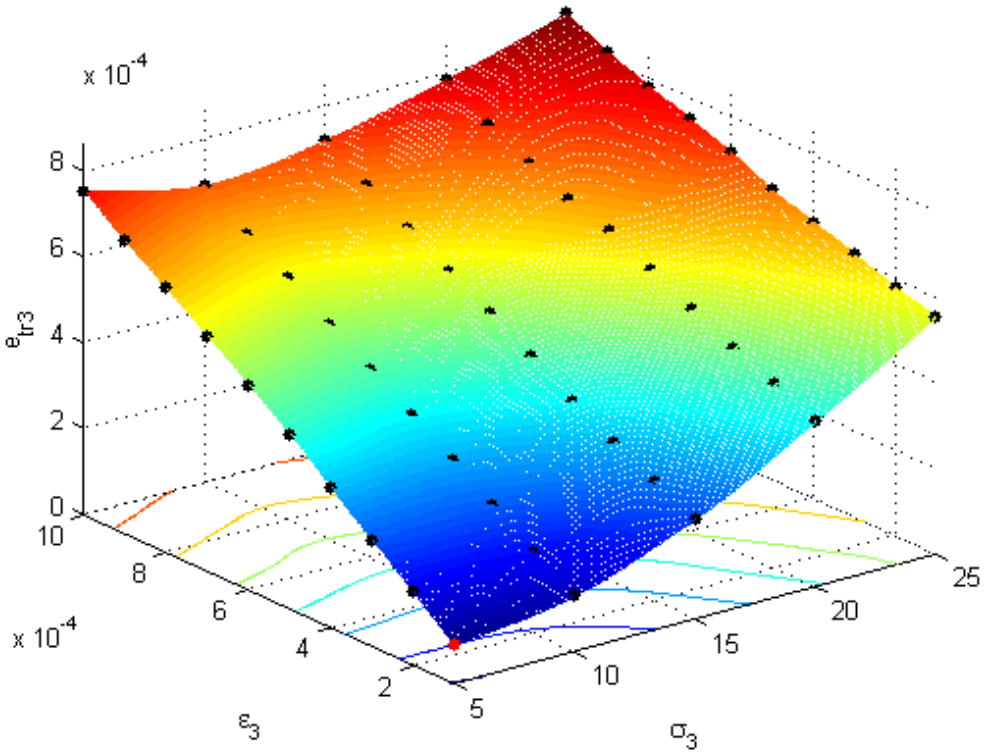
Şekil 3.6 : DVR 1 test hatası yüzeyi.



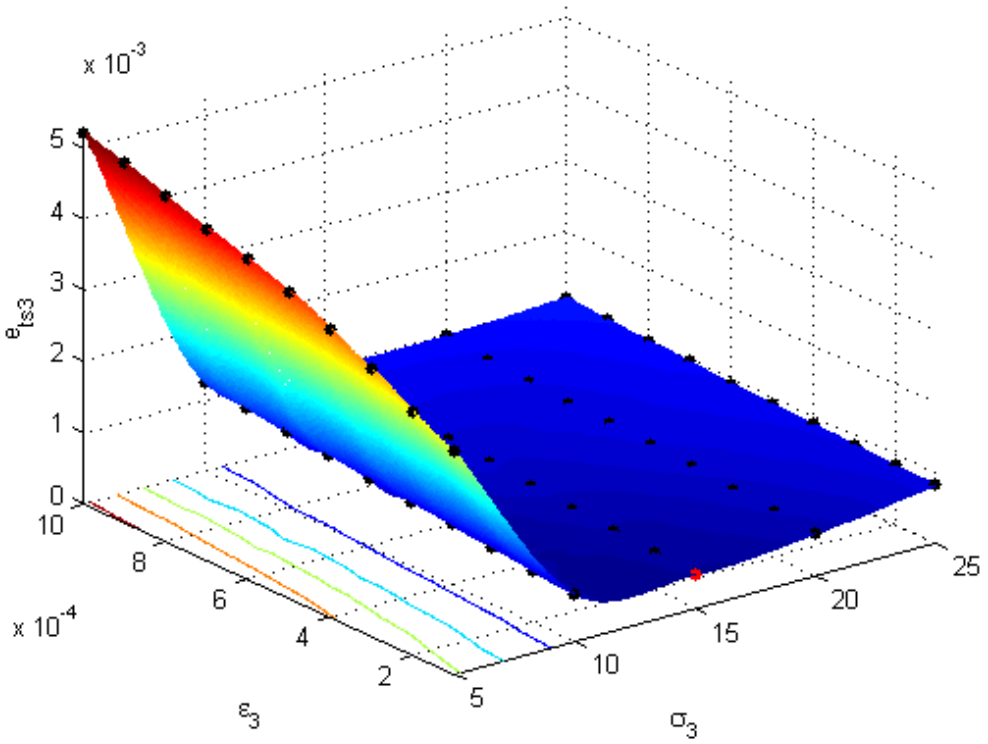
Şekil 3.7 : DVR 2 eğitim hatası yüzeyi.



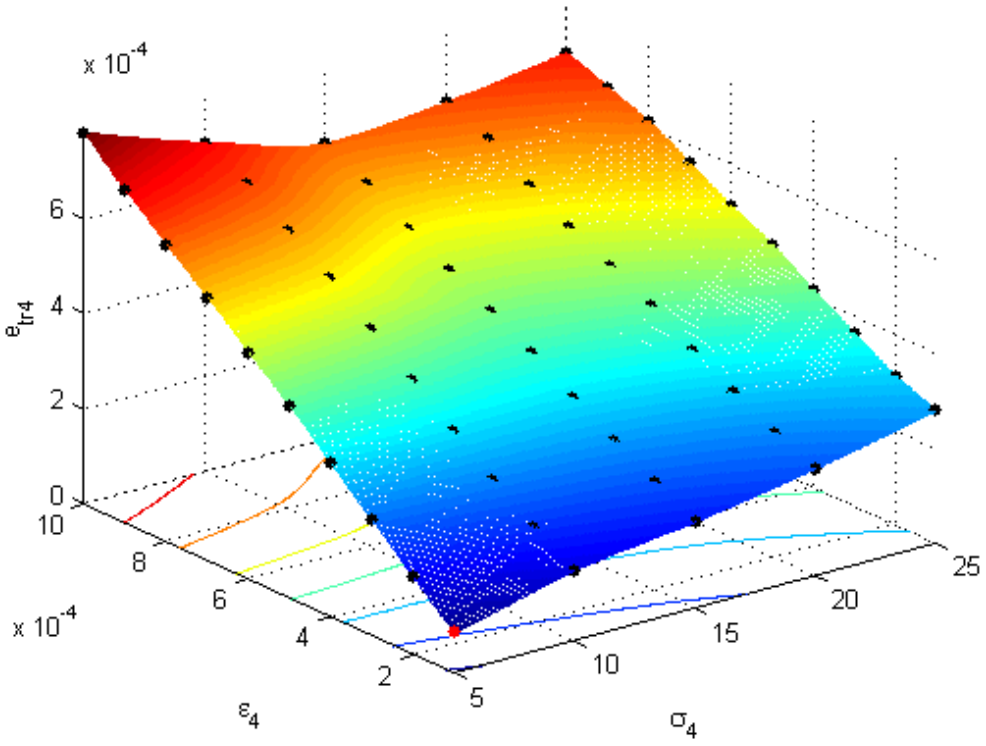
Şekil 3.8 : DVR 2 test hatası yüzeyi.



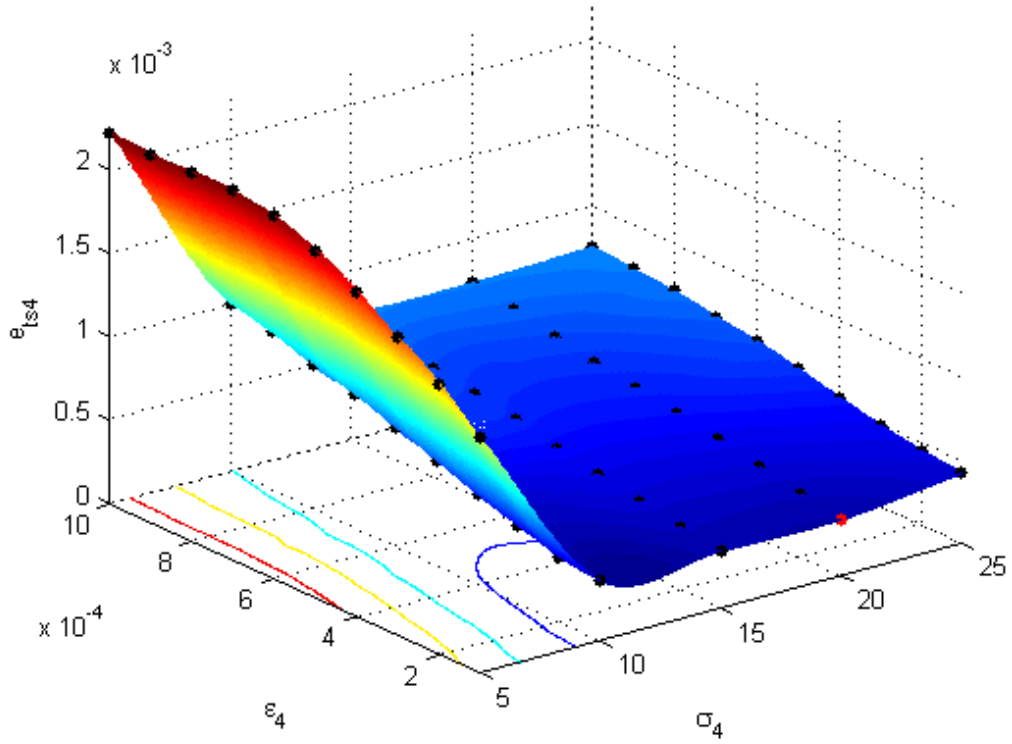
Şekil 3.9 : DVR 3 eğitim hatası yüzeyi.



Şekil 3.10 : DVR 3 test hatası yüzeyi.



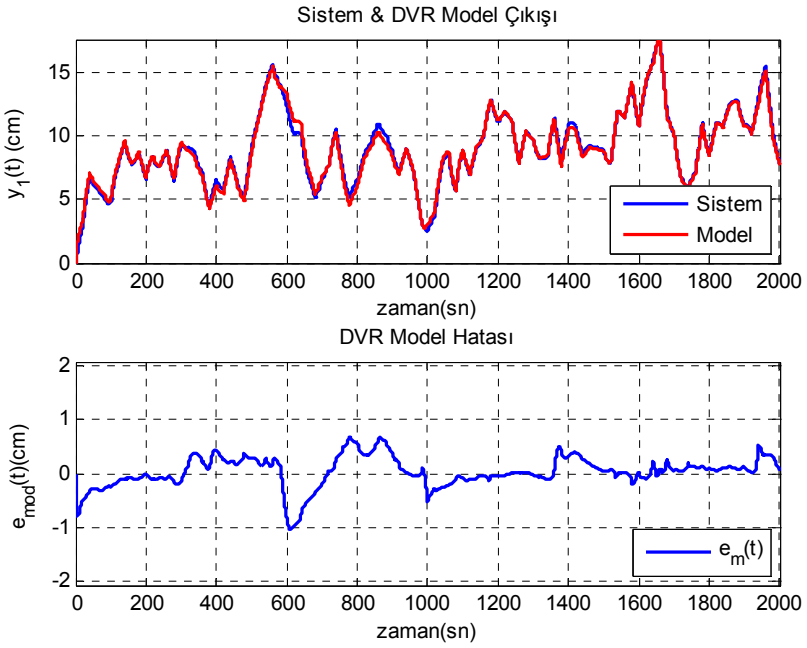
Şekil 3.11 : DVR 4 eğitim hatası yüzeyi.



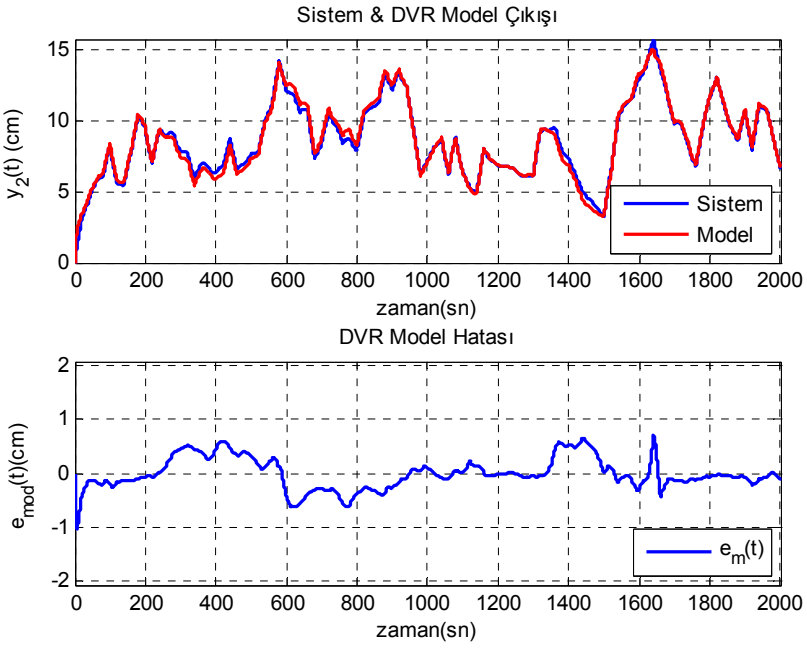
Şekil 3.12 : DVR 4 test hatası yüzeyi.

Bu araştırma sonucunda en iyi model parametreleri ε-hata tüpü için $\varepsilon_1 = \varepsilon_2 = \varepsilon_3 = \varepsilon_4 = 10^{-4}$ ve çekirdek parametreleri(σ) için $\sigma_1 = 10$, $\sigma_2 = \sigma_3 = 15$ $\sigma_4 = 20$ olarak seçilmiştir.

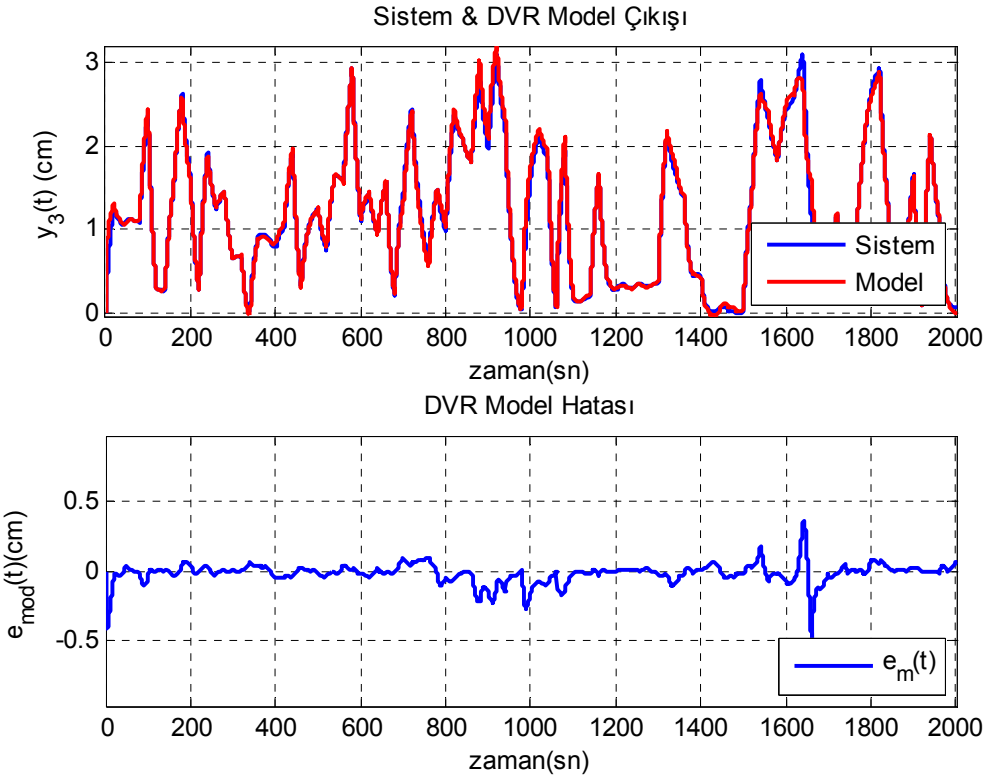
Modelin ve sistemin 4 çıkışının cevabı şekil 3.13- 3.16'da verilmiştir.



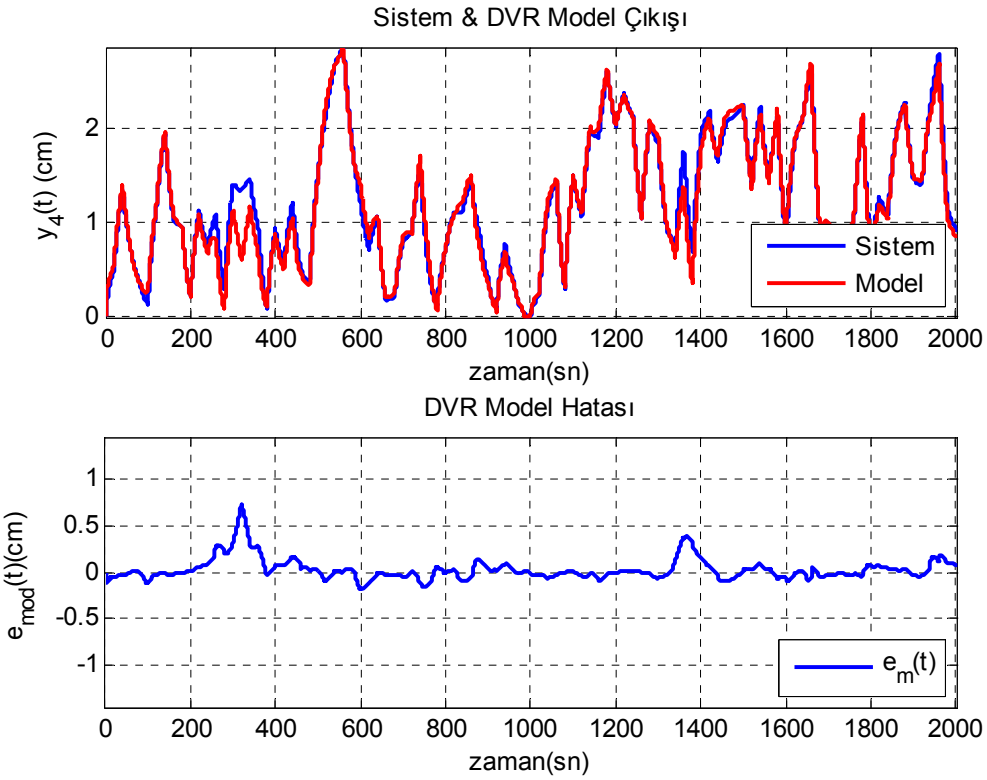
Şekil 3.13 : Tank 1'in sıvı seviyesi.



Şekil 3.14 : Tank 2'nin sıvı seviyesi.



Şekil 3.15 : Tank 3'ün sıvı seviyesi.



Şekil 3.16 : Tank 4'ün sıvı seviyesi.

Şekil 3.13- 3.16'dan görüldüğü üzere model yeterince başarılı bir şekilde sistemin dinamiklerini temsil edebilmektedir.

3.3 Model Tabanlı Uyarlamalı PID Kontrolör Tasarımı

Tezin bu bölümünde, model tabanlı, uyarlamalı bir PID kontrolör tasarlanmış, model kestirimi için DVR'den faydalanılmıştır. Model tabanlı kontrolör tasarımında sistemin dinamiklerinin kestirimi ile elde edilen model ile sistemin jakobiyen bilgisi kullanılır. Bu bölümde kontrolör parametrelerinin kestirimi için [10]'da önerilen uyarlamalı PID kontrolörden faydalanılmıştır. Kontrolör parametrelerinin uyarlanması için birinci dereceden kestirim için eğim düşümü ve 2. dereceden kestirim için Levenberg Marquard algoritması kullanılmaktadır. [10]'da önerilen kontrolör şekil 3.17'den görüldüğü gibi 5 parçadan oluşmaktadır. Bunlar;

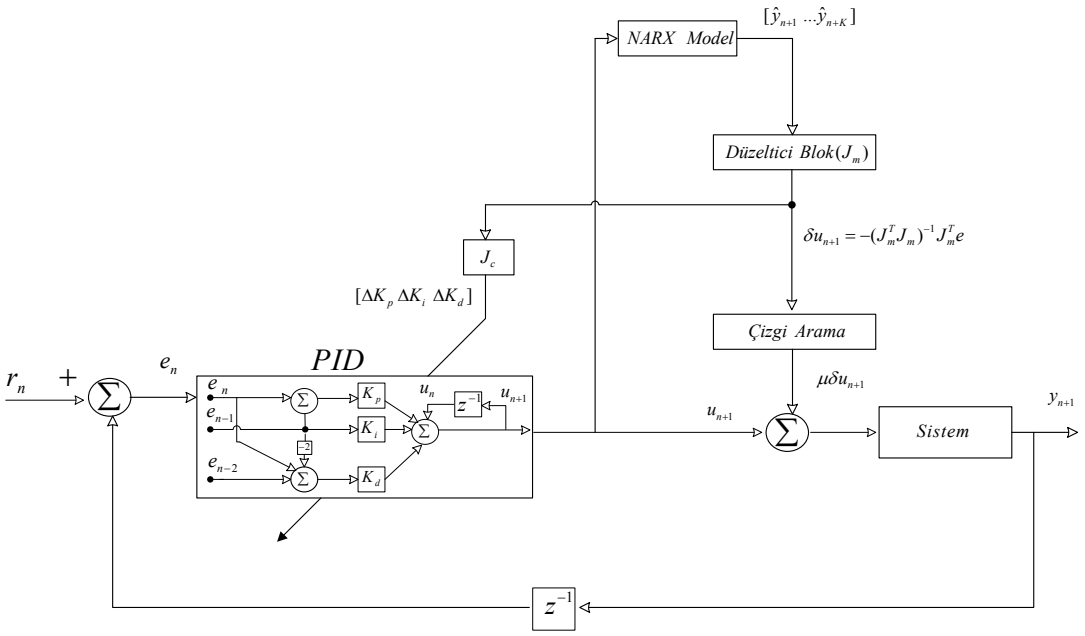
1-Klasik PID Kontrolör

2-Sistemin DVR Modeli

3-Çizgi arama Bloğu(Altın Bölme vb.)

4-Kontrol İşareti düzeltme bloğu

5-Kontrolör Parametresi ayarlama bloğu



Şekil 3.17 : Uyarlamalı öngörülü model tabanlı PID kontrolör.

Şekilden görüldüğü gibi öncelikli olarak doğrusal olmayan sistemin dinamikleri DVR ile modellenmektedir. Daha sonra bu model, kontrolör parametrelerinin ayarlanması için gereken jakobiyen bilgisinin kestirimi için kullanılmaktadır. Buradaki amaç başlangıçta optimal değerlere sahip olmayan kontrolör parametrelerinin zamanla optimal değerlerine yakınsayarak sistemin kontrolü için gerekli olan doğru kontrol işaretinin üretilmesini sağlamaktır. Yakınsaklık hızı eğim düşümüne göre daha iyi olduğu için Levenberg Marquard algoritması tercih edilmiştir. Sistemin modeli, sisteme ait jakobiyen bilgisinin kestirimi için kullanılmıştır.

PID Kontrolör , izleme hata işareti e_n olduğunda, aşağıdaki kontrol kuralı ile u_{n+1} kontrol işaretini üretir.

$$u_{n+1} = u_n + K_p(e_n - e_{n-1}) + K_i e_n + K_d(e_n - 2e_{n-1} + e_{n-2}) \quad \textbf{(3.2)}$$

Başlangıçta PID parametreleri sıfır olarak atanır. PID parametreleri optimal olmadığından dolayı uygun bir şekilde ayarlanması gerekmektedir. Bu amaçla sistemin NARX Modeli kullanılır. Kontrol işareti u_{n+1} modele *K* kez uygulandığında, model sistemin *K* adım gelecekteki davranışlarını içeren yörünge vektörünü oluşturur. Bu tahminlere dayanarak, PID katsayıları *K* adım tahmin hatalarının karelerinin toplamını ve kontrol işaretinin değişimini minimize edecek şekilde güncellenir. Yani (3.3)'deki amaç fonksiyonu minimize edilmeye çalışılır.

$$J(u_{n+1}) = \frac{1}{2}\sum_{k=1}^{K}(\tilde{y}_{n+k} - \hat{y}_{n+k})^2 + \frac{1}{2}\lambda(u_{n+1} - u_n)^2 \quad \textbf{(3.3)}$$

Burada *K* tahmin ufkunu ve λ penaltı terimini belirtmektedir.

Minimizasyon algoritması olarak Levenberg-Marquardt algoritması uygulanmıştır.

$$\begin{bmatrix} K_p^{new} \\ K_i^{new} \\ K_d^{new} \end{bmatrix} = \begin{bmatrix} K_p^{old} \\ K_i^{old} \\ K_d^{old} \end{bmatrix} - (J^T J + \mu I)^{-1} J^T \underline{\hat{e}} \quad \textbf{(3.4)}$$

Kontrolör parametreleri (3.4)'deki optimizasyon kuralı ile güncellenmektedir. μ artıkça ilerleme yönü yavaş ama güvenilir olan eğim düşümü, azaldıkça hızlı ama az güvenilir olan Gauss Newton yönüne dönüşmektedir. Parametrelerin iyi bir şekilde güncellenebilmesi için sistemin jakobiyen matrisinin bilinmesi gerekmektedir.

Parametrelerin doğru bir şekilde güncellenmesi ve kontrol işaretinin değişiminin minimize edilmesi için kullanılması gereken jakobiyen (3.5)'deki gibidir.

$$J = \begin{bmatrix} \frac{\partial \hat{e}_{n+1}}{\partial K_p} & \frac{\partial \hat{e}_{n+1}}{\partial K_i} & \frac{\partial \hat{e}_{n+1}}{\partial K_d} \\ \frac{\partial \hat{e}_{n+2}}{\partial K_p} & \frac{\partial \hat{e}_{n+2}}{\partial K_i} & \frac{\partial \hat{e}_{n+2}}{\partial K_d} \\ \vdots & \vdots & \vdots \\ \frac{\partial \hat{e}_{n+K}}{\partial K_p} & \frac{\partial \hat{e}_{n+K}}{\partial K_i} & \frac{\partial \hat{e}_{n+K}}{\partial K_d} \\ \frac{\partial \sqrt{\lambda}(u_{n+1}-u_n)}{\partial K_p} & \frac{\partial \sqrt{\lambda}(u_{n+1}-u_n)}{\partial K_i} & \frac{\partial \sqrt{\lambda}(u_{n+1}-u_n)}{\partial K_d} \end{bmatrix}$$

$$= - \begin{bmatrix} \frac{\partial \hat{y}_{n+1}}{\partial K_p} & \frac{\partial \hat{y}_{n+1}}{\partial K_i} & \frac{\partial \hat{y}_{n+1}}{\partial K_d} \\ \frac{\partial \hat{y}_{n+2}}{\partial K_p} & \frac{\partial \hat{y}_{n+2}}{\partial K_i} & \frac{\partial \hat{y}_{n+2}}{\partial K_d} \\ \vdots & \vdots & \vdots \\ \frac{\partial \hat{y}_{n+K}}{\partial K_p} & \frac{\partial \hat{y}_{n+K}}{\partial K_i} & \frac{\partial \hat{y}_{n+K}}{\partial K_d} \\ \frac{\partial \sqrt{\lambda}(u_{n+1}-u_n)}{\partial K_p} & \frac{\partial \sqrt{\lambda}(u_{n+1}-u_n)}{\partial K_i} & \frac{\partial \sqrt{\lambda}(u_{n+1}-u_n)}{\partial K_d} \end{bmatrix} \quad \textbf{(3.5)}$$

Sistemin K adım sonraki davranışının kestirimi sonucunda oluşan model hatası (3.6)'daki vektörle verilmiştir.

$$\underline{\hat{e}} = \begin{bmatrix} \hat{e}_{n+1} \\ \vdots \\ \hat{e}_{n+K} \\ \sqrt{\lambda}\Delta u_{n+1} \end{bmatrix} = \begin{bmatrix} \tilde{y}_{n+1} - \hat{y}_{n+1} \\ \vdots \\ \tilde{y}_{n+K} - \hat{y}_{n+K} \\ \sqrt{\lambda}(u_{n+1} - u_n) \end{bmatrix} \quad \textbf{(3.6)}$$

Sonuç olarak PID parametreleri her iterasyonda (3.4)'e göre Levenberg Marquard algoritması kullanılarak güncellenir, böylece uzun süreçte parametrelerin optimal değerlerine yakınsaması beklenir. Fakat, genellikle geçici ve sürekli halde belli bir aşamaya kadar güncellenen bu kontrolör parametreleri, sistemi istenilen referansa taşıyabilecek kadar yeterince optimal bir kontrol işareti oluşturmayabilirler. Kontrol işareti, model hataları ve dış bozuculardan dolayı, sistemi istenilen çıkışa taşımak için yeterli olmayabilir. Bu yüzden düzeltici terim gerekmektedir. Düzeltici bloğun

amacı optimal altı (suboptimal) düzeltici terim (δu_{n+1}) üreterek (3.3)'deki amaç fonksiyonunu minimize etmektir. Düzeltici terim ikinci dereceden Taylor açılımına dayanarak amaç fonksiyonunu δu_{n+1} cinsinden minimize eder.

$$J(u_{n+1}+\delta u_{n+1}) \cong J(u_{n+1}) + \frac{\partial J(u_{n+1})}{\partial u_{n+1}}\delta u_{n+1} + \frac{1}{2}\frac{\partial^2 J(u_{n+1})}{\partial u_{n+1}^{\ 2}}(\delta u_{n+1})^2 \qquad \textbf{(3.7)}$$

(3.7)'de ki amaç fonksiyonunun δu_{n+1} cinsinden türevi alınıp sıfıra eşitlenirse kontrol işaretini düzeltici terim (3.8) yardımıyla (3.9)'daki gibi elde edilir.

$$\frac{\partial J(u_{n+1})}{\partial u_{n+1}} + \frac{1}{2}\frac{\partial^2 J(u_{n+1})}{\partial u_{n+1}^{\ 2}}(\delta u_{n+1}) = 0 \qquad \textbf{(3.8)}$$

$$\delta u_{n+1} = -\frac{\dfrac{\partial J(u_{n+1})}{\partial u_{n+1}}}{\dfrac{\partial^2 J(u_{n+1})}{\partial u_{n+1}^{\ 2}}} \qquad \textbf{(3.9)}$$

Eğer Taylor açılımındaki ikinci dereceden terimler (Hessian) pozitif ve yüksek dereceden terimler ihmal edilirse bu Newton yönü local minimuma karesel bir yakınsama gösterir. Bu noktada gradient ve Hessian terimleri hesaplanmalıdır. İkinci dereceden türevlerin hesaplanmasında Jakobiyen yaklaşımı kullanılmaktadır.

Sisteme ait eğim bilgisi (3.10)'daki gibidir. Bu bilgi için modelden yararlanılmaktadır.

$$J_m = -\left[\frac{\partial \hat{y}_{n+1}}{\partial u_{n+1}} \quad \frac{\partial \hat{y}_{n+2}}{\partial u_{n+1}} \quad \ldots \frac{\partial \hat{y}_{n+K}}{\partial u_{n+1}} \quad \sqrt{\lambda} \quad \right]^T \qquad \textbf{(3.10)}$$

Hessian matrisi yaklaşık olarak (3.11)'deki gibi elde edilmektedir.

$$\frac{\partial J(u_{n+1})}{\partial u_{n+1}} = J_m^{\ T}\underline{\hat{e}} \ , \ \frac{\partial^2 J(u_{n+1})}{\partial u^2_{\ n+1}} \cong J_m^{\ T} J_m \qquad \textbf{(3.11)}$$

Yaklaşık Hessian bilgisi kullanılarak düzeltme terimi (3.12)'deki gibi elde edilebilir.

$$\delta u_{n+1} = -(J_m^{\ T}\underline{\hat{e}})/(J_m^{\ T} J_m) \qquad \textbf{(3.12)}$$

Böylece sadece birinci dereceden türevlerin hesaplanması yeterlidir. Bu durumda jakobiyen matrisi zincir kuralı kullanılarak (3.13)'deki gibi iki parçaya ayrılabilir.

Jakobiyen matrisi, sistemin eğim bilgisi(J_m) ve kontrolörün çıkışları(J_c) olarak iki parçaya ayrıştırılır.

$$J = -\begin{bmatrix} \frac{\partial \hat{y}_{n+1}}{\partial u_{n+1}} \\ \frac{\partial \hat{y}_{n+2}}{\partial u_{n+1}} \\ \vdots \\ \frac{\partial \hat{y}_{n+K}}{\partial u_{n+1}} \\ \sqrt{\lambda} \\ \end{bmatrix} \begin{bmatrix} \frac{\partial u_{n+1}}{\partial K_p} & \frac{\partial u_{n+1}}{\partial K_i} & \frac{\partial u_{n+1}}{\partial K_d} \end{bmatrix} = J_m J_c \,,\; J_c = \begin{bmatrix} e_n - e_{n-1} \\ e_n \\ e_n - 2e_{n-1} + e_{n-2} \end{bmatrix}^T \qquad \textbf{(3.13)}$$

3.3.1 Öngörü ve jakobiyen matrisinin hesaplanması

NARX Modeline göre sistemin şu anki durum vektörü (3.14)'de verilmiştir.

$$c_n = \begin{bmatrix} u_n \\ u_{n-1} \\ \vdots \\ u_{n-n_u} \\ y_{n-1} \\ y_{n-2} \\ \vdots \\ y_{n-n_y} \end{bmatrix} \qquad \textbf{(3.14)}$$

Şu anki durum vektörüne karşın DVM modelin çıkışı

$$\hat{y}_n = \sum_{j=1}^{\#SV} \alpha_j K(c_n, x_j) + b \qquad \textbf{(3.15)}$$

gibidir.

Boyutsal adresleme için kullanılan çekirdek fonksiyonu, radyal tabanlı fonksiyon seçilmiştir. Buna bağlı olarak oluşan çekirdek (3.16)'da verilmiştir.

$$K_{i,j} = K(x_i, x_j) = \exp(-\frac{(x_i - x_j)^T (x_i - x_j)}{2\sigma^2}) \qquad \textbf{(3.16)}$$

Modele giriş yapacak şu anki test noktası ile destek vektörü arasındaki uzaklık, öklit uzaklığı olarak (3.17)'deki gibi tanımlanır.

$$d_{j,n} = (c_n - x_j)^T (c_n - x_j) \qquad \textbf{(3.17)}$$

Burada j destek vektörünün n ise şu anki durum vektörünün indis değerlerini göstermektedir. Sistemin K adım sonraki davranışının kestirimi için modele u_{n+1}

kontrol işareti K kez arka arkaya uygulanır. Bu durumda modelin içinde sisteme ait durum vektörünün değişimi (3.18) ve (3.19)'daki gibi olur.

$$\hat{c}_{n+1} = \begin{bmatrix} u_{n+1} \\ u_n \\ \vdots \\ u_{n-n_u+1} \\ y_n \\ y_{n-1} \\ \vdots \\ y_{n-n_y+1} \end{bmatrix} \begin{matrix} \left.\begin{matrix} \\ \\ \\ \\ \end{matrix}\right\} n_{u+1} \\ \left.\begin{matrix} \\ \\ \\ \\ \end{matrix}\right\} n_y \end{matrix} \left.\begin{matrix} \\ \\ \\ \\ \\ \\ \\ \\ \end{matrix}\right\} n_u + n_y + 1 \qquad ====>> \hat{y}_{n+1}$$

$$\hat{c}_{n+2} = \begin{bmatrix} u_{n+1} \\ u_{n+1} \\ u_n \\ \vdots \\ u_{n-n_u+2} \\ \hat{y}_{n+1} \\ y_n \\ \vdots \\ y_{n-n_y+1} \end{bmatrix} \begin{matrix} \left.\begin{matrix} \\ \\ \\ \\ \\ \end{matrix}\right\} n_{u+1} \\ \left.\begin{matrix} \\ \\ \\ \\ \end{matrix}\right\} n_y \end{matrix} \left.\begin{matrix} \\ \\ \\ \\ \\ \\ \\ \\ \\ \end{matrix}\right\} n_u + n_y + 1 \qquad ====>> \hat{y}_{n+2}$$

(3.18)

Aşağıdaki durum vektörlerinde, kontrol işaretine bağlı olarak modelin girişine uygulanan durum vektörü ve modelin çıkışının değişimi verilmiştir. Durum vektörünün değişimi aslında verilerin benzerliği için ölçüt olarak kullanılan öklit uzaklığını etkilemektedir. Bu değişimden yararlanılarak K adım boyunca öklit uzaklığının değişimi bulunursa, sistemin K adım boyunca davranışı da kestirilebilir. Sistemin K adım boyunca öklit uzaklığı değişimi (3.20)'deki gibidir.

$$\hat{c}_{n+3} = \begin{bmatrix} u_{n+1} \\ u_{n+1} \\ u_{n+1} \\ u_n \\ \vdots \\ u_{n-n_u+3} \\ \hat{y}_{n+2} \\ \hat{y}_{n+1} \\ y_n \\ \vdots \\ y_{n-n_y+3} \end{bmatrix} \begin{matrix} \} 3 \\ \\ \\ \} n_u - 2 \\ \\ \\ \} 3 \\ \\ \\ \} n_y - 3 \end{matrix} \} n_u + n_y + 1 \qquad ====>> \hat{y}_{n+3}$$

$$\hat{c}_{n+k} = \begin{bmatrix} u_{n+1} \\ \vdots \\ u_{n+1} \\ u_n \\ \vdots \\ u_{n-n_u+k} \\ \hat{y}_{n+k-1} \\ \vdots \\ y_n \\ \vdots \\ y_{n-n_y+k} \end{bmatrix} \begin{matrix} \} k \\ \\ \\ \} n_u - k + 1 \\ \\ \\ \} k \\ \\ \\ \} n_y - k \end{matrix} \} n_u + n_y + 1 =>> \hat{y}_{n+k} \qquad \textbf{(3.19)}$$

$$d_{j(n+k)} = \sum_{i=0}^{n_u} \begin{cases} (x_{j,i+1} - u_{n+1})^2 & k-i \geq 1 \\ (x_{j,i+1} - u_{n+k-i})^2 & k-i < 1 \end{cases} + \sum_{i=1}^{\min(k,n_y)} (x_{j,n_u+i+1} - \hat{y}_{n+k-i})^2 + \sum_{i=k+1}^{n_y} (x_{j,n_u+i+1} - y_{n+k-i})^2 \qquad \textbf{(3.20)}$$

Buna bağlı olarak sistemin *K* adım boyunca değişimi modele bağlı olarak:

$$\hat{y}_{n+k} = \sum_{j=1}^{\#SV} \alpha_j \exp\left(\frac{-d_{j(n+k)}}{2\sigma^2}\right) + b \qquad , \; k = 1, 2, \ldots\ldots K \qquad \textbf{(3.21)}$$

şeklinde tahmin edilir. Jakobiyen matrisinin oluşturulabilmesi için model kullanılarak sisteme ait birinci dereceden türev bilgisinin bilinmesi yeterlidir. Buna bağlı olarak sisteme ait birinci dereceden kısmı türevler, model kullanılarak (3.22)'deki gibi tahmin edilir.

$$\frac{\partial \hat{y}_{n+k}}{\partial u_{n+1}} = \sum_{j=1}^{\#SV} \alpha_j \frac{\partial \exp(\frac{-d_{j(n+k)}}{2\sigma^2})}{\partial u_{n+1}}$$

$$\frac{\partial \exp(\frac{-d_{j(n+k)}}{2\sigma^2})}{\partial u_{n+1}} = \frac{\partial \exp(\frac{-d_{j(n+k)}}{2\sigma^2})}{\partial d_{j(n+k)}} \frac{\partial d_{j(n+k)}}{\partial u_{n+1}} \quad \textbf{(3.22)}$$

$$\frac{\partial d_{j(n+k)}}{\partial u_{n+1}} = \sum_{i=1}^{\min(k,n_y)} [(-2)(x_{j,n_u+i+1} - \hat{y}_{n+k-i})(\frac{\partial \hat{y}_{n+k-i}}{\partial u_{n+1}} \delta_1(k-i-1))] + \sum_{i=0}^{n_u} [(-2)(x_{j,i+1} - u_{n+1})\delta_1(k-i-1)]$$

δ_1 : Birim basamak fonksiyonu

Bu bilgi hem düzeltici terimin hesaplanmasında hem de PID katsayılarının parametrelerinin ayarlanmasında kullanılabilir. Aşağıdaki kontrol algoritması her iterasyon da uygulanarak sistemin kontrolü sağlanır.

Kontrol Algoritması

Adım 0: Kontrolör parametrelerini 0 a ayarlayın.

Adım 1: Döngüyü bitirme koşullarının sağlanıp sağlanmadığını kontrol edin.

Adım 2: e_n 'i bul.

Adım 3: u_{n+1} 'i bul.

Adım 4: $[\hat{y}_{n+1}, \hat{y}_{n+2}, ..., \hat{y}_{n+K}]$ 'i bul.

Adım 5: J_m 'i bul.

Adım 6: δu_{n+1} 'i bul.

Adım 7: Çizgi arama metodu ile μ ' yı bul.

Adım 8: Sisteme uygulanacak düzeltilmiş kontrol işareti bul.

$u_{plant_n+1} = u_{n+1} + \mu \delta u_{n+1}$

Adım 9: Sistemin çıkışını bul.

$y_s(n+1) = ?$

Adım 10: Jakobiyen matrisini bul ve kontrolör parametrelerini güncelle.

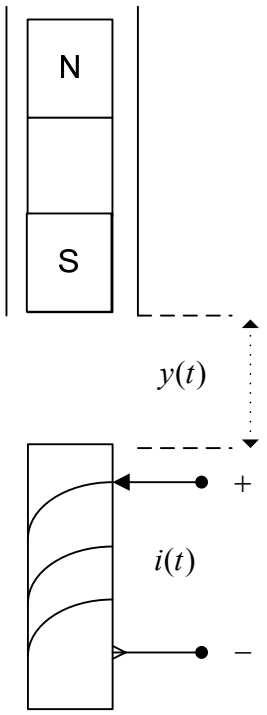
$J = J_m J_c$

$$\begin{bmatrix} K_p^{new} \\ K_i^{new} \\ K_d^{new} \end{bmatrix} = \begin{bmatrix} K_p^{old} \\ K_i^{old} \\ K_d^{old} \end{bmatrix} - (J^T J + \mu I)^{-1} J^T \underline{\hat{e}} \qquad \textbf{(3.23)}$$

Adım 11: Adım 1'e gidip, döngüyü bitirme koşullarının sağlanıp sağlanmadığını kontrol ediniz.

3.3.2 Manyetik askı sisteminin kontrolü

Önerilen kontrol yapısının başarımını incelemek için sistem olarak, kararsız ve doğrusal olmayan bir sistem olan şekil 3.18 'deki manyetik askı sistemi seçilmiştir.



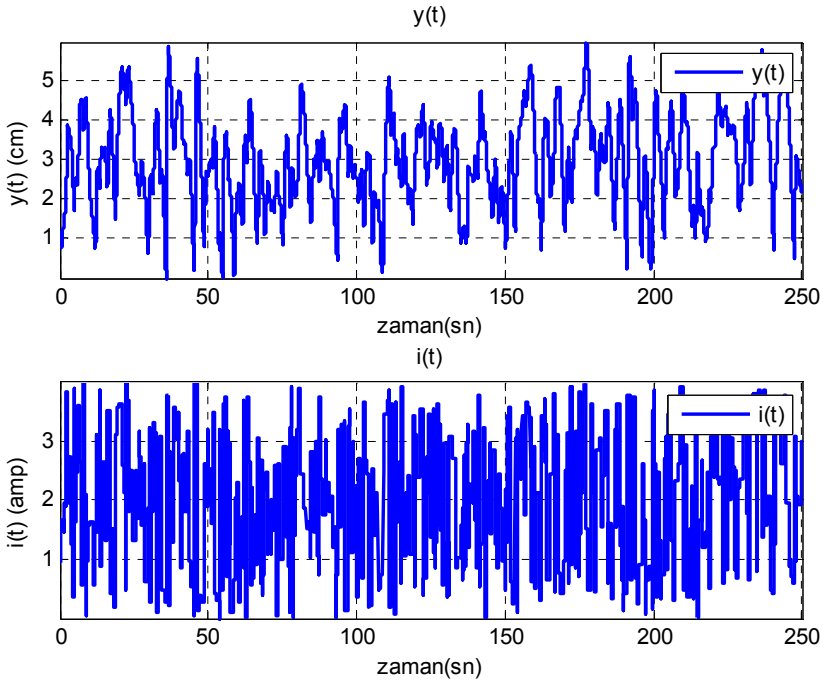
Şekil 3.18 : Manyetik askı sistemi.

Manyetik askı sisteminin hareket denklemi

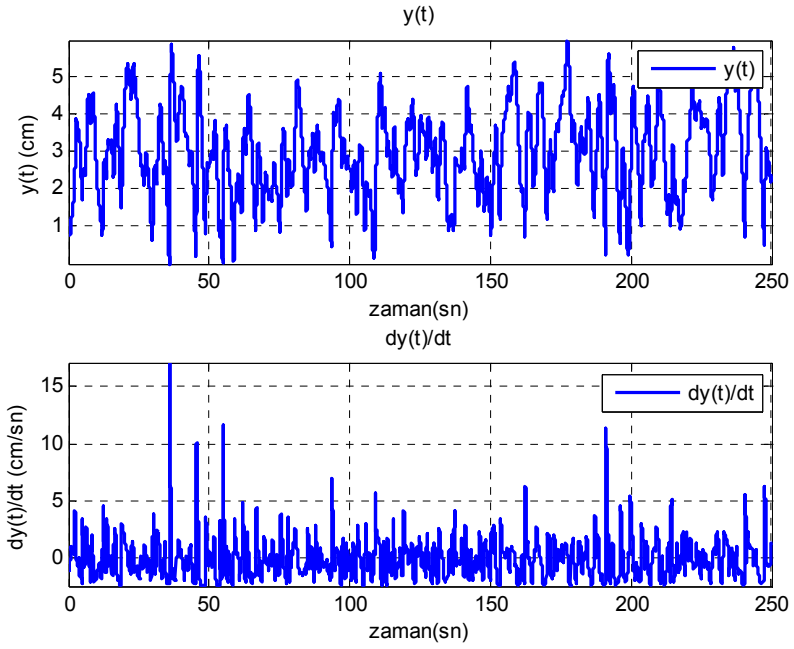
$$\frac{d^2 y(t)}{dt^2} = -g + \frac{a}{M}\frac{i^2(t)\ sign(i(t))}{y(t)} - \frac{\beta}{M}\frac{dy(t)}{dt} \qquad \textbf{(3.24)}$$

gibidir. Burada, $y(t)$ mıknatıstan uzaklığı, $i(t)$ bobin üzerinden akan akımı, M mıknatısın ağırlığını, g yerçekimi sabitini vermektedir. β mıknatısın içinde hareket ettiği materyalin sürtünme katsayısı ve a ise sarım sayısı ve mıknatısın gücüne bağlı olarak belirlenen alan güç sabitidir. Kontrol işareti ($i(t)$) *0-4* amper arasında kısıtlanmış ve örnekleme zamanı (T_s) 0.01 sn alınmıştır. Parametre değerleri, $\beta = 12$, $a = 15$, $g = 9.8$ ve $M = 3$ olarak seçilmiştir.

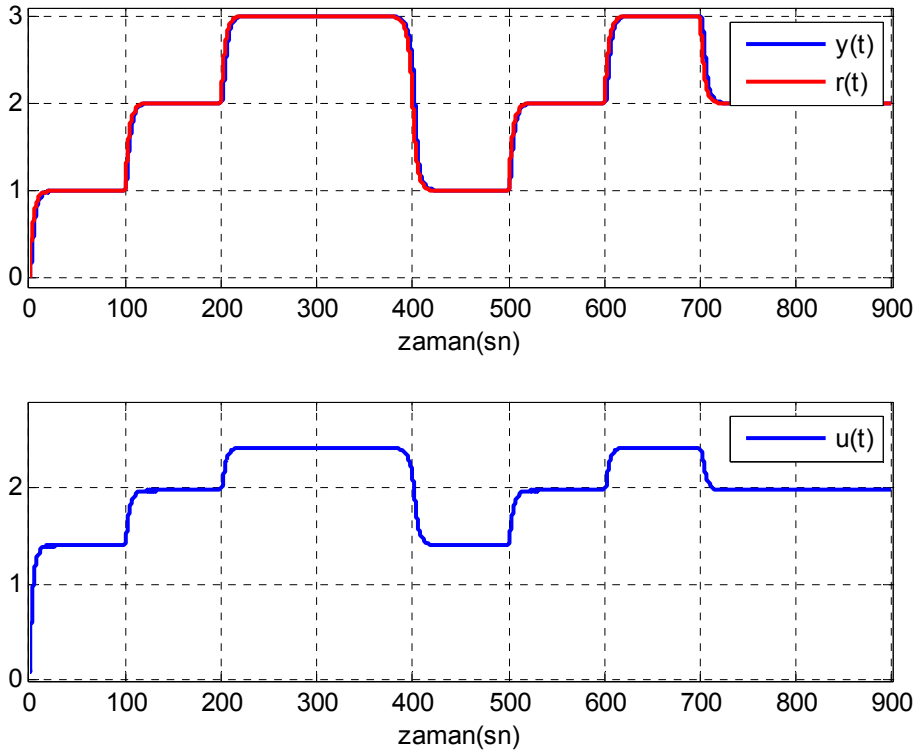
Kontrolör tasarım sürecinde ilk adım olarak sistemin dinamikleri çıkarıldıktan sonra bu dinamiklerden iyi bir model elde etmek gereklidir. Sistemin dinamiklerini ortaya çıkarmak için ilk olarak şekil 3.19'daki gibi kontrol işareti sisteme uygulanır. Sistem kararsız bir sistem olduğu için, model verileri şekil 3.19'daki gibi sistemin kararlı davrandığı bölgeden seçilir. Mıknatısın konumu ve hızı şekil 3.20'de verilmiştir.



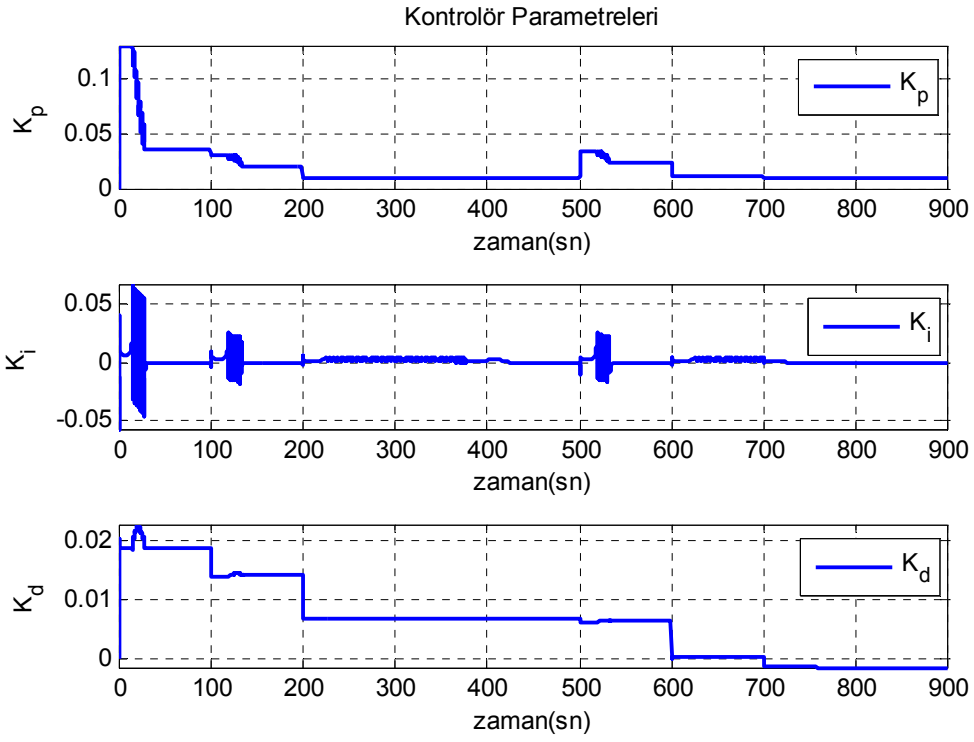
Şekil 3.19 : Giriş işareti ve sistemin cevabı.



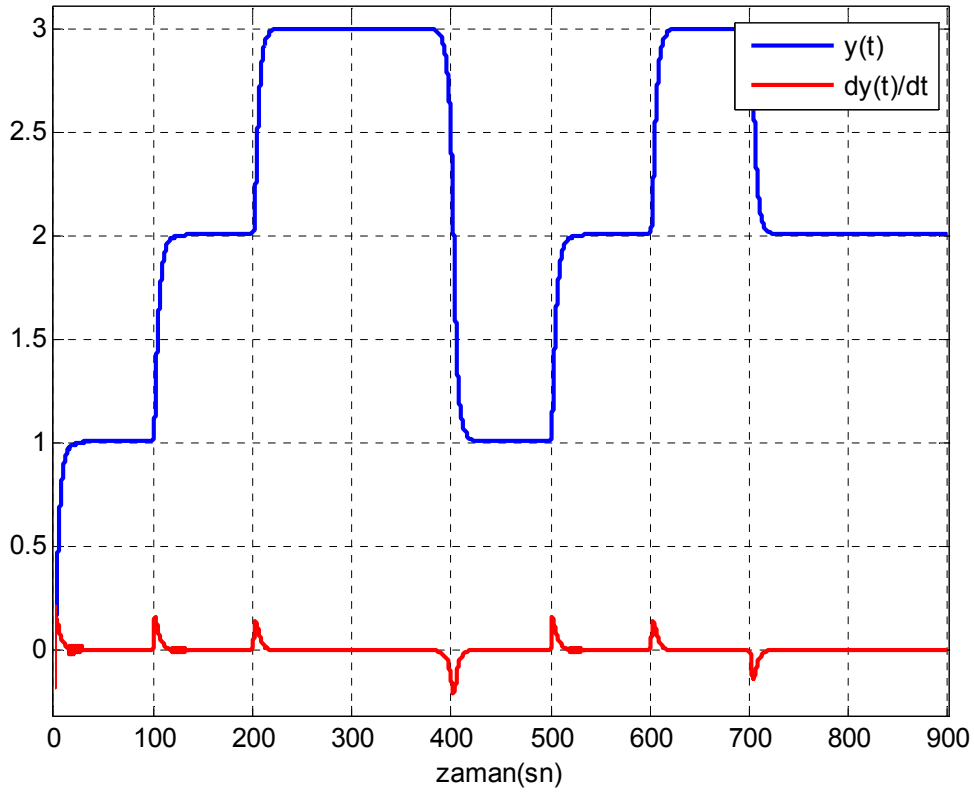
Şekil 3.20 : Mıknatısın konumu ve hızı.



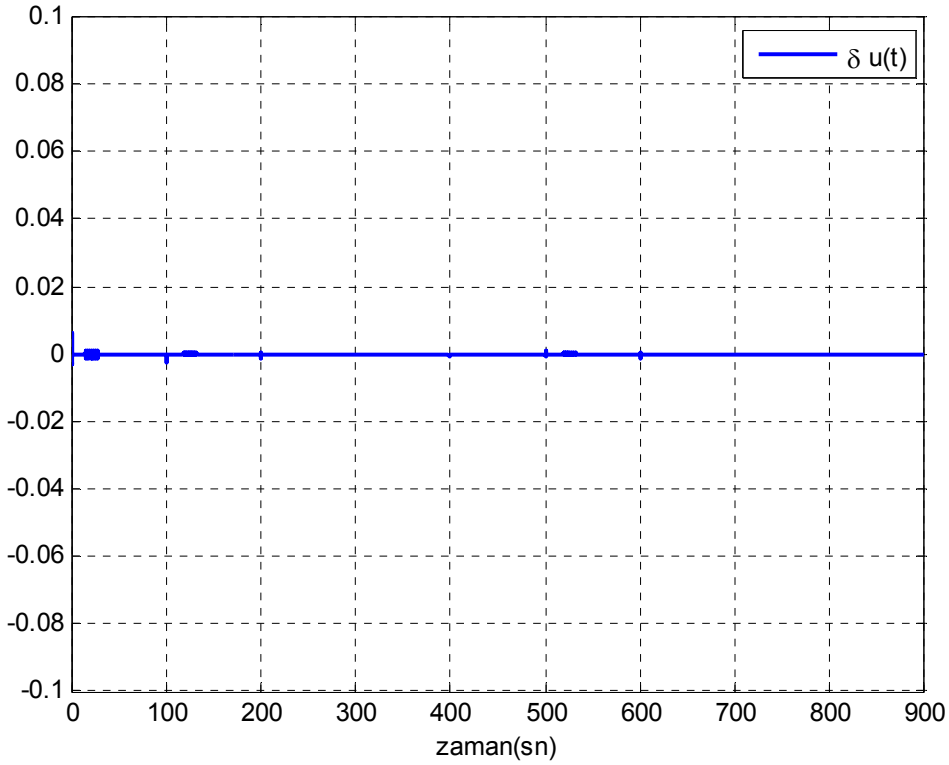
Şekil 3.21 : Sistemin cevabı ve kontrol işareti.



Şekil 3.22 : Uyarlamalı PID kontrolörün parametreleri.



Şekil 3.23 : Mıknatısın konumu ve hızı.



Şekil 3.24 : Kontrol işaretini düzeltme terimi.

Sistemin uyarlamalı PID kontrolör ile kontrolü şekil 3.21'de simüle edilmiştir. Kontrol işaretinin değişiminin minimize edilmesi gerçeklenebilir bir işaretin elde edilmesini sağlamıştır. Kontrolör parametrelerinin değişimi şekil 3.22'de verilmiştir. Şekil 3.23'de mıknatısın kontrol edilmesi sonucu konumu ve hızını göstermektedir.

3.4 Çevrimiçi En Küçük Kareler Destek Vektör Makinaları

EK-DVM'de optimizasyon problemi, geleneksel DVM ile benzerdir [49]. Aşağıdaki gibi bir eğitim verisi kümesi verilsin

$$(y_{1,}\underline{x}_1).....(y_k\,\underline{x}_k)\ ,\ x\in R^n, y\in R\quad k=1,2,,,,N \tag{3.25}$$

burada N veri sayısını, n ise giriş vektörünün boyutunu yani imleç sayısını verir. Optimizasyon problemi verilen kısıtlar altında aşağıdaki gibi formüle edilmiştir [50]. Amaç Fonksiyonu:

$$\min_{(w,b,e)} \frac{1}{2}w^T w+\frac{1}{2}C\sum_{k=1}^{N}e_k^2 \tag{3.26}$$

Kısıtlar:

$$y_k - w^T\varphi(x_k)-b-e_k=0\ ,\ k=1,2,....,N \tag{3.27}$$

(3.26) ve (3.27)'de sunulan minimizasyon problemi, birincil amaç fonksiyonu olarak tanımlanmıştır [51]. DVM'de ana amaç birincil amaç fonksiyonu ve buna karşılık gelen kısıtlara dual değişken kümesi katarak Lagrange fonksiyonu oluşturmaktır [1]. Birincil amaç fonksiyonu ve kısıtlar kullanılarak Lagrange fonksiyonu (3.28)'deki gibi elde edilir :

$$L(w,b,e,a)=\frac{1}{2}w^T w+\frac{1}{2}C\sum_{k=1}^{N}e_k^2-\sum_{k=1}^{N}\alpha_k(w^T\varphi(x_k)+b+e_k-y_k) \tag{3.28}$$

(3.28)'de L Lagrange fonksiyonunu, a_k lagrange çarpanlarını göstermektedir [15,20,52]. Optimallik için gerekli koşullar aşağıdaki gibidir:

$$\frac{\partial L}{\partial b}=\sum_{k=1}^{N}\alpha_k=0$$

$$\frac{\partial L}{\partial w}=\underline{w}-\sum_{k=1}^{N}\alpha_k\varphi(x_k)=0\longrightarrow\ \underline{w}=\sum_{k=1}^{N}\alpha_k\varphi(x_k) \tag{3.29}$$

$$\frac{\partial L}{\partial e_k}=C\sum_{k=1}^{N}e_k-\sum_{k=1}^{N}\alpha_k=0\quad\longrightarrow\quad\alpha_k=Ce_k$$

$$\frac{\partial L}{\partial a_k} = 0 \longrightarrow y_k = w^T \varphi(x_k) + b + e_k$$
$$k = 1, 2, ..., N$$

Bu koşullar kullanılarak optimizasyon probleminin çözümü (3.30) ve (3.31)'de verilmiştir.

$$\begin{bmatrix} 0 & \underline{1} \\ \underline{1}^T & \Omega + \frac{I}{C} \end{bmatrix} \begin{bmatrix} b \\ \underline{a}^T \end{bmatrix} = \begin{bmatrix} 0 \\ \underline{y}^T \end{bmatrix} \quad \textbf{(3.30)}$$

$$\underline{y} = [y_1, y_2, .., y_N] \ , \ \underline{a} = [a_1, a_2, .., a_N] \ , \ \underline{1} = [1, 1, .., 1]$$
$$\Omega_{km} = K(x_k, x_m) \ , \ k, m = 1, 2, ..., N \quad \textbf{(3.31)}$$

Bu matris eşitliği kullanılarak regresyon probleminin Lagrange çarpanları ve eşik değeri (3.32) yardımıyla bulunur.

$$\begin{bmatrix} b \\ \underline{a}^T \end{bmatrix} = \begin{bmatrix} 0 & \underline{1} \\ \underline{1}^T & \Omega + \frac{I}{C} \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ \underline{y}^T \end{bmatrix} \quad \textbf{(3.32)}$$

Böylece, doğrusal olmayan regresyon fonksiyonu destek vektörleri cinsinden (3.33)'deki gibi ifade edilir:

$$f(\underline{x}) = \sum_{k \in SV} a_k K(\underline{x}_k, \underline{x}) + b \quad \textbf{(3.33)}$$

EK-DVR'de kayıp fonksiyonu kullanılmadığı için bütün eğitim verileri destek vektör olarak seçilmektedir. Bütün verilerin Lagrange çarpanları sıfırdan farklı değerlere sahiptir. (3.30)'da verilen çözüm çevrimdışı bir çözümdür. Çözümü çevrimiçi haline dönüştürmek için (3.34)' deki gibi değişkenlere zaman eklenir.

$$\begin{bmatrix} b(n) \\ \underline{a}^T(n) \end{bmatrix} = \begin{bmatrix} 0 & \underline{1} \\ \underline{1}^T & \Omega(n) + \frac{I}{C} \end{bmatrix}^{-1} \begin{bmatrix} 0 \\ \underline{y}^T(n) \end{bmatrix} \quad \textbf{(3.34)}$$

Doğrusal olmayan bir sistemin dinamikleri NARX Modeli kullanılarak (3.35)'deki gibi temsil edilebilir.

$$y(n+1) = f(u(n), .., u(n - n_u), y(n-1), .., y(n - n_y)) \quad \textbf{(3.35)}$$

Burada $u(n)$ sisteme uygulanan kontrol işaretini, $y(n+1)$ sistemin cevabını göstermektedir. n_u ve n_y sırasıyla modelin içerdiği geçmiş kontrol işareti ve geçmişteki sistem çıkışlarının sayısını belirtmektedir. Diğer bir değişle n_u ve n_y NARX modelinin derecesini göstermektedir.

Zaman indeksi n de NARX modelin girişini oluşturcak olan sisteme ait durum vektörü (3.36)'daki gibidir.

$$\underline{x}(n) = [u(n),..,u(n-n_u),y(n-1),..,y(n-n_y)] \tag{3.36}$$

(3.33), (3.34) ve (3.35) kullanılarak çevrimiçi modelin çıkışı

$$\hat{y}(n+1) = \sum_{i=n-L}^{n-1} a_i(n) K\langle \underline{x}(n), \underline{x}(i)\rangle + b(n) \tag{3.37}$$

olarak elde edilir. $\underline{X}(n) = [\underline{x}(n-1),....\underline{x}(n-L)]$ giriş vektör veri kümesini ve bu durumlara karşılık olan $\underline{Y}(n) = [y(n),..,y(n-L+1)]$ sistemi cevabını kullanılarak, $\underline{X}(n), \underline{Y}(n)$ şeklinde eğitim veri kümesi oluşturulur. $\underline{U}(n) = [\underline{\Omega}(n) + \frac{I}{C}]^{-1}$ kabul edip (3.37) kullanılarak $\alpha(n)$ ve $b(n)$ aşağıdaki gibi belirlenir.

$$\underline{Y}(n) = [\underline{U}(n)]^{-1}\underline{\alpha}^T(n) + \underline{1}^T b(n) \tag{3.38}$$

$$\underline{1}\underline{\alpha}^T(n) = 0 \tag{3.39}$$

$$\underline{U}(n)\underline{Y}(n) = \underline{U}(n)[\underline{U}(n)]^{-1}\underline{\alpha}^T(n) + \underline{U}(n)\underline{1}^T b(n) \tag{3.40}$$

$$\underline{\alpha}^T(n) = \underline{U}(n)[\underline{Y}(n) - \underline{1}^T b(n)] \tag{3.41}$$

(3.39) kullanılarak problemin eşik değeri

$$\underline{1}\underline{\alpha}^T(n) = \underline{1}\underline{U}(n)[\underline{Y}(n) - \underline{1}^T b(n)] = 0$$

$$b(n) = \frac{\underline{1}\underline{U}(n)\underline{Y}(n)}{\underline{1}\underline{U}(n)\underline{1}^T} \tag{3.42}$$

olarak belirlenir.

Zaman indeksi n'de eğitim veri kümesi aşağıdaki gibidir.

$$\begin{aligned}\underline{X}(n) &= [\underline{x}(n-1),....\underline{x}(n-L)]\\ \underline{Y}(n) &= [y(n),..,y(n-L+1)]\end{aligned} \tag{3.43}$$

Zaman indeksi $n+1$'de eğitim veri kümesi aşağıdaki gibidir.

$$\begin{aligned}\underline{X}(n+1) &= [\underline{x}(n),\underline{x}(n-1),....\underline{x}(n-L+1)]\\ \underline{Y}(n+1) &= [y(n+1),y(n),..,(n-L+2)]\end{aligned} \tag{3.44}$$

Eğitim verilerinden görüldüğü üzere zaman indeksi $n+1$'de $\underline{x}(n), y(n)$ eğitim verisi eklenirken, $\underline{x}(n-L), y(n-L+1)$ eğitim veri kümesinden atılmaktadır. Eğitim veri kümesinden verilerin atılması ve eklenmesi, benzerlik matrisi olan çekirdeği etkilemektedir. Bu nedenle çekirdekteki değişimi incelemek gerekmektedir. $\underline{U}(n) = [\underline{\Omega}(n) + \frac{I}{C}]^{-1}$ matrisinin değişimi aşağıdaki gibi verilmiştir.

Zaman indeksi *n*'de çekirdek matrisi aşağıdaki gibidir.

$$\begin{aligned}\underline{U}(n) &= [\underline{\Omega}(n) + \frac{I}{C}]^{-1} \\ &= \begin{bmatrix} K(\underline{x}(n-1), \underline{x}(n-1),) + C^{-1} \dots K(\underline{x}(n-L), \underline{x}(n-1)) \\ \vdots \qquad\qquad\qquad\qquad \ddots \\ K(\underline{x}(n-1), \underline{x}(n-L)) \dots K(\underline{x}(n-L), \underline{x}(n-L)) + C^{-1} \end{bmatrix}^{-1} \\ &= \begin{bmatrix} A(n) & H \\ H^T & h \end{bmatrix}^{-1}\end{aligned} \tag{3.45}$$

burada

$$\begin{aligned} H &= \left[K(\underline{x}(n-L), \underline{x}(n-1)) \dots K(\underline{x}(n-L), \underline{x}(n-L+1)) \right] \\ h &= K(\underline{x}(n-L), \underline{x}(n-L)) + C^{-1} \end{aligned} \tag{3.46}$$

$$A(n) = \begin{bmatrix} K(\underline{x}(n-1), \underline{x}(n-1)) + C^{-1} .. K(\underline{x}(n-L+1), \underline{x}(n-1)) \\ \vdots \qquad\qquad\qquad\qquad \ddots \\ K(\underline{x}(n-1), \underline{x}(n-L+1)) .. K(\underline{x}(n-L+1), \underline{x}(n-L+1)) + C^{-1} \end{bmatrix} \tag{3.47}$$

Zaman indeksi $n+1$'e geldiğinde yeni eğitim veri çiftinin eklenmesi ve eski veri çiftinin atılmasıyla çekirdek matrisi aşağıdaki formu almaktadır.

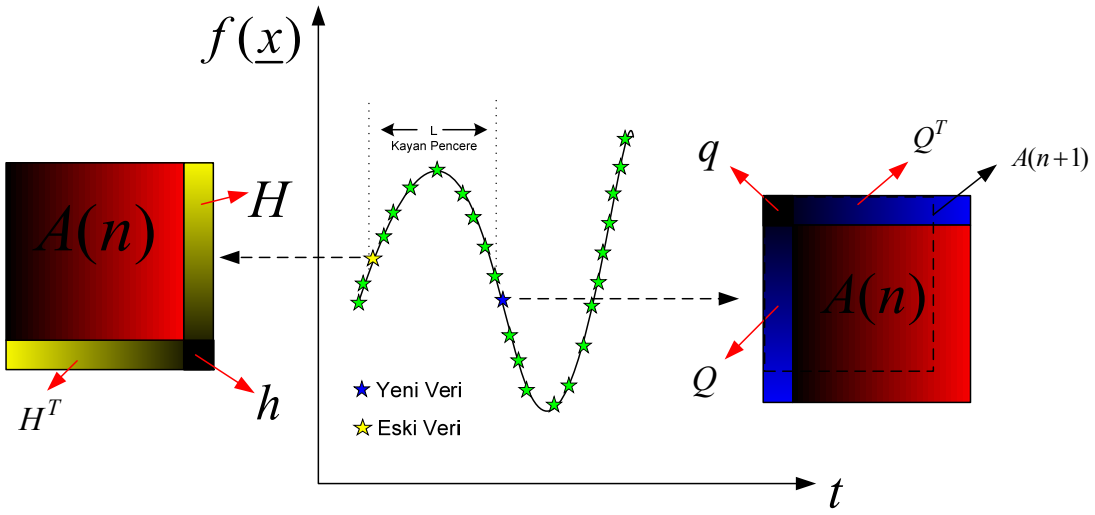
$$\begin{aligned} U(n+1) &= [\Omega(n+1) + I / C]^{-1} \\ &= \begin{bmatrix} K(\underline{x}(n), \underline{x}(n),) + C^{-1} \dots\dots\dots\dots\dots K(\underline{x}(n-L+1), \underline{x}(n)) \\ \vdots \qquad\qquad\qquad\qquad \ddots \\ K(\underline{x}(n), \underline{x}(n-L+1)) \dots K(\underline{x}(n-L+1), \underline{x}(n-L+1)) + C^{-1} \end{bmatrix}^{-1} \\ &= \begin{bmatrix} q & Q^T \\ Q & A(n) \end{bmatrix}^{-1} \end{aligned} \tag{3.48}$$

burada

$$\begin{aligned} q &= K(\underline{x}(n), \underline{x}(n)) + C^{-1}, \\ Q &= \left[K(\underline{x}(n), \underline{x}(n-1)) \dots K(\underline{x}(n), \underline{x}(n-L+1)) \right]^T \end{aligned} \tag{3.49}$$

Çekirdek matrisinden ve eğitim verilerinden görüleceği gibi, $A(n)$ matrisi bir önceki iterasyonda hesaplandığı için, her iterasyonda q ve Q vektörlerinin hesaplanması regresyon probleminin çözümü için yeterlidir. Çekirdek matrisinden farkedileceği

üzere zamanla $A(n)$ matrisi sağ alt köşegene doğru kaymaktadır. q vektörü yeni eklenen verinin kendisiyle, Q ise yeni eklenen verinin önceki verilerle benzerliğini içeren vektörlerdir. Çekirdek matrisinde meydana gelen bu değişiklikler şekil 3.25'de görselleştirilmiştir. Yeni eğitim verisi çifti eğitim kümesine eklenmeden önce eğitim kümesinden atılacak olan verinin kendisiyle ve diğer verilerle benzerliğini gösteren h ve H blokları çekirdek matrisinden atılıp, yeni eğitim verisinin, kendisiyle ve eğitim setinde kalan diğer verilerle ilişkisini temsil eden q ve Q blokları çekirdek matrisine eklenmektedir. Çekirdek matrisinin büyük bir bölümünü oluşturan ve eğitim kümesinde kalan verilerin benzerliği bilgisini içeren $A(n)$ matrisi her iterasyonda çekirdek matrisinden kolay bir şekilde belirlenebilmektedir. Bu sayede, ÇEK-DVR'de, ε-DVR ve EK-DVR'nin getirdiği işlemsel yükten kaçınılmış olur.



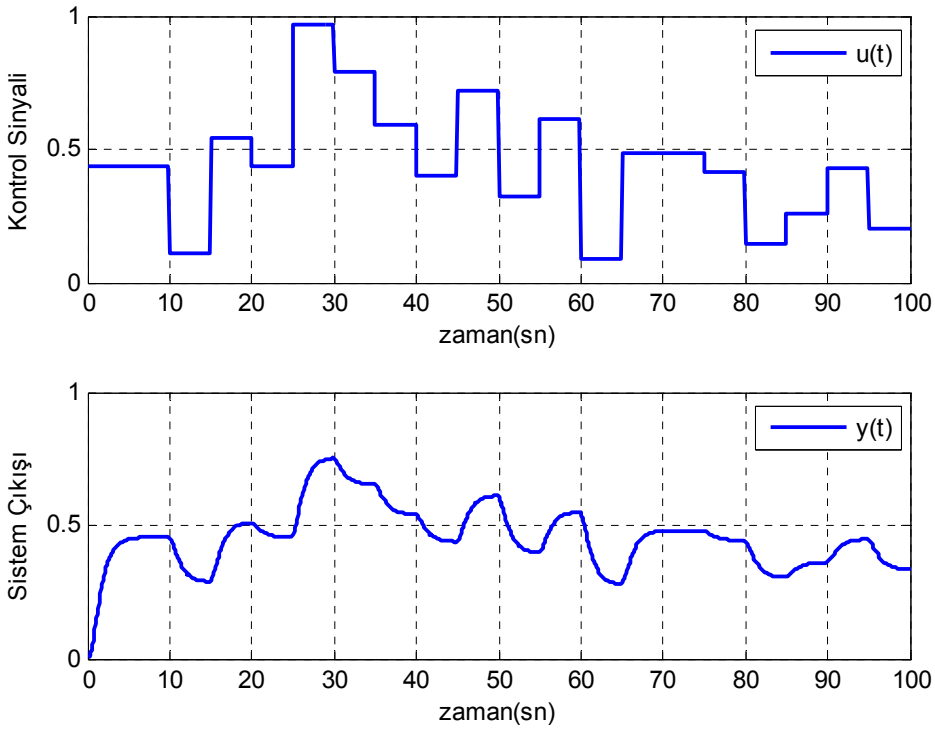
Şekil 3.25 : Çevrimiçi süreçte çekirdek matrisinin değişimi.

ÇEK-DVM'nin tanılama probleminin çözümündeki başarımını değerlendirmek için SKTR sistemi üzerinde benzetimler yapılmıştır. Sistemin dinamik denklemleri (3.50)'de verilmiştir [10,53,54].

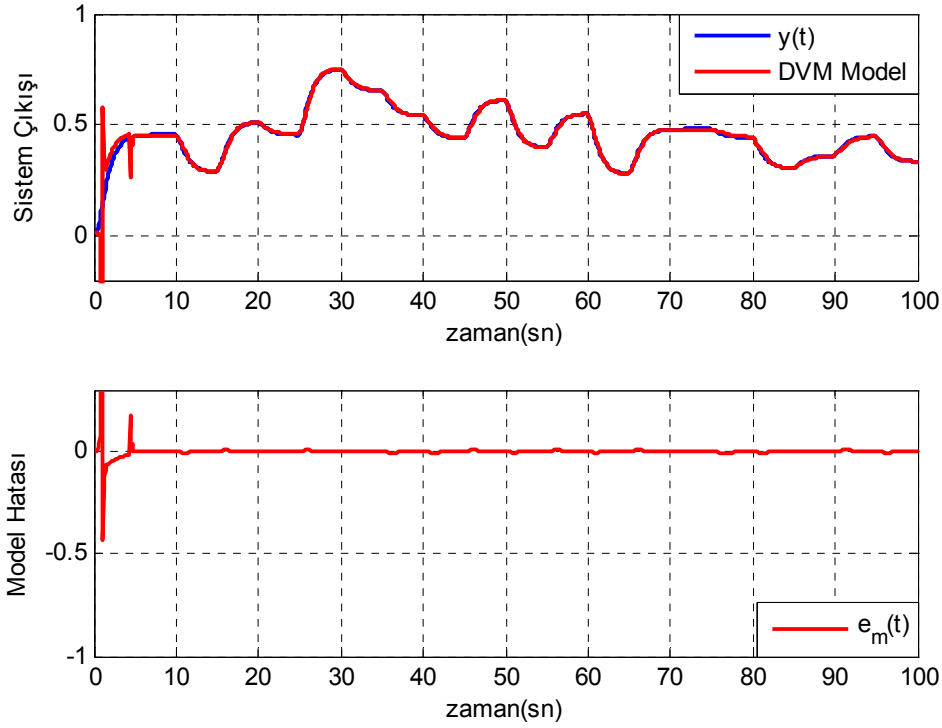
$$\begin{aligned}\dot{x}_1(t) &= 1 - x_1(t) - Da_1 x_1(t) + Da_2 x_2^{\,2}(t) \\ \dot{x}_2(t) &= -x_2(t) + Da_1 x_1(t) - Da_2 x_2^{\,2}(t) - Da_3 d_2 x_2^{\,2}(t) + u(t) \\ \dot{x}_3(t) &= -x_3(t) + Da_3 d_2 x_2^{\,2}(t)\end{aligned} \qquad \textbf{(3.50)}$$

burada $Da_1 = 3$, $Da_2 = 0.5$, $Da_3 = 1$, $d_2 = 1$ dir. $u(t)$ sisteme uygulana kontrol girişi ve $x_3(t)$ sistemin çıkışıdır [10,53,54]. Sistemin dinamiklerini ortaya çıkarmak için şekil 3.26'deki gibi bir kontrol işareti sisteme uygulanmıştır. Kontrol işareti ve

sistemin cevabı şekil 3.26'de ki gibidir. Sistemin çevrimiçi tanılanması sonucu modelin ve sistemin cevabı aşağıdaki gibi verilmiştir



Şekil 3.26 : Sistemin dinamiklerinin uyarılması.



Şekil 3.27 : Çevrimiçi DVM modelin cevabı ve modelleme hatası.

Şekil 3.27'den görüldüğü gibi model ilk etapta çok iyi modelleme yapamazken zamanla modelleme hatasının azaldığı gözlenmektedir. Şekillerden görülebileceği gibi Çevrimiçi DVM kullanılarak doğrusal olmayan bir sistemin dinamikleri başarılı bir şekilde modellenebilmektedir.

3.5 Model Tabanlı Uyarlamalı PID Kontrolör Tasarımı

Bu bölümde çevrim içi modelleme tekniği kullanılarak model tabanlı kontrolör tasarımı yapılmıştır. Çevrimiçi DVM ile oluşturulan sistem modeli kontrolör parametrelerinin uyarlanması için kullanılmaktadır. Kontrolör yapısı olarak [9]'da verilen ve şekil 3.28'de gösterilen yapı temel alınmıştır. Burada n zaman indeksinde sırasıyla, $y(n)$ sistemin çıkışını, $u(n)$ kontrol işareti, $r(n)$ referans işareti, $e(n)$ izleme hatasını, $\hat{e}(n)$ modelleme hatasını göstermektedir. Modelleme ve izleme hataları (3.51)'de verilmiştir.

$$e(n) = r(n) - y(n)\,,\, \hat{e}(n) = y(n) - \hat{y}(n) \tag{3.51}$$

Uyarlamalı PID Kontrolör, sistemin çevrimiçi modeli, klasik PID kontolör ve PID kontrolör parametre uyarlayıcısı olmak üzere 3 kısımdan oluşmaktadır. Klasik PID kontrolör :

$$\begin{aligned} u(n) &= u(n-1) + K_p(n)(e(n) - e(n)) \\ &\quad + K_i(n)(e(n)) + K_d(n)(e(n) - 2e(n-1) + e(n-1)) \end{aligned} \tag{3.52}$$

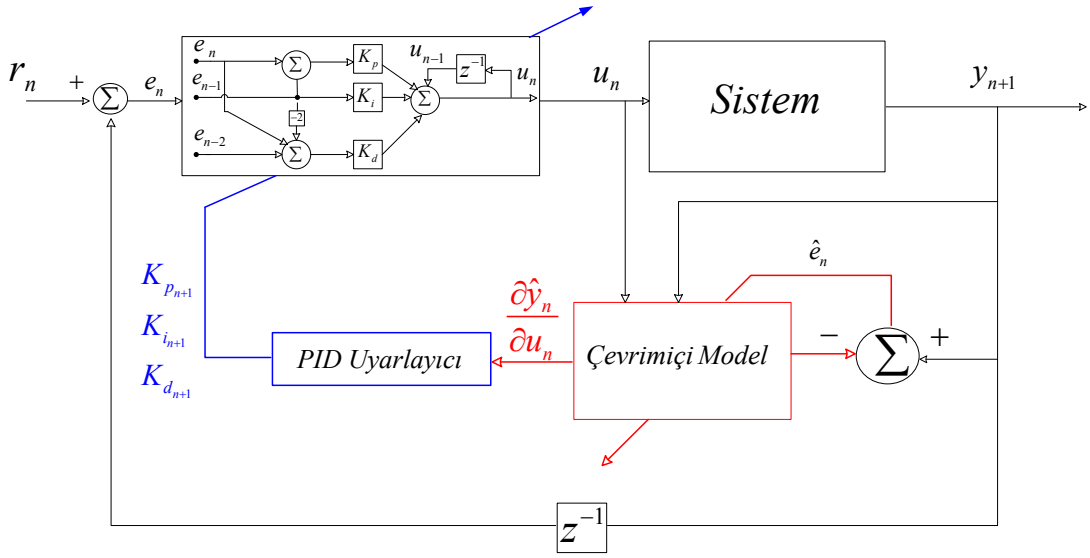
gibi bir kontrol işareti üretmektedir [9,10,55]. Burada K_p, K_i ve K_d sistemin davranışına bağlı olarak uyarlanması gereken kontrolör parametreleridir.

Kontrol sürecinin başında, kontrolör parametreleri optimal değere sahip değillerdir [10]. Bu nedenle optimizasyon teorisi kullanılarak uygun bir şekilde uyarlanmaları gerekmektedir [10,56]. İzleme hatası optimal değere sahip olmayan kontrolör parametrelerinden dolayı kaynaklanmaktadır. Bu nedenle izleme hatası (3.53)'deki gibi kontrolör parametrelerinin fonksiyonu olarak yazılabilir.

$$e(n) = f(K_i(n), K_d(n), K_p(n)) \tag{3.53}$$

Kontrolör parametrelerinin optimal değerlerine yakınsaması için eğim düşümü metodu kullanılmıştır. PID kontrolörün girişleri aşağıdaki gibi tanımlanabilir.

$$\begin{aligned} xc(1) &= e(n) - e(n-1) \\ xc(2) &= e(n) \\ xc(3) &= e(n) - 2e(n-1) + e(n-2) \end{aligned} \tag{3.54}$$



Şekil 3.28 : Çevrimiçi model tabanlı uyarlamalı PID kontrolör.

Kontrolör parametrelerinin optimal değerlerine yakınsayabilmeleri için dik iniş metoduyla aşağıdaki amaç fonksiyonunun minimize edilmesi gerekmektedir.

$$J(n) = \frac{[r(n) - y(n)]^2}{2} = \frac{1}{2} e^2(n) \tag{3.55}$$

Eğim düşümü metoduyla kontrolör parametreleri aşağıdaki kurallar kullanılarak minimize edilebilir.

$$\begin{aligned}
\Delta K_p(n) &= -\eta(n) \frac{\partial J(n)}{\partial e(n)} \frac{\partial e(n)}{\partial y(n)} \frac{\partial y(n)}{\partial u(n)} \frac{\partial u(n)}{\partial K_p(n)} \\
\Delta K_i(n) &= -\eta(n) \frac{\partial J(n)}{\partial e(n)} \frac{\partial e(n)}{\partial y(n)} \frac{\partial y(n)}{\partial u(n)} \frac{\partial u(n)}{\partial K_i(n)} \\
\Delta K_d(n) &= -\eta(n) \frac{\partial J(n)}{\partial e(n)} \frac{\partial e(n)}{\partial y(n)} \frac{\partial y(n)}{\partial u(n)} \frac{\partial u(n)}{\partial K_d(n)}
\end{aligned} \tag{3.56}$$

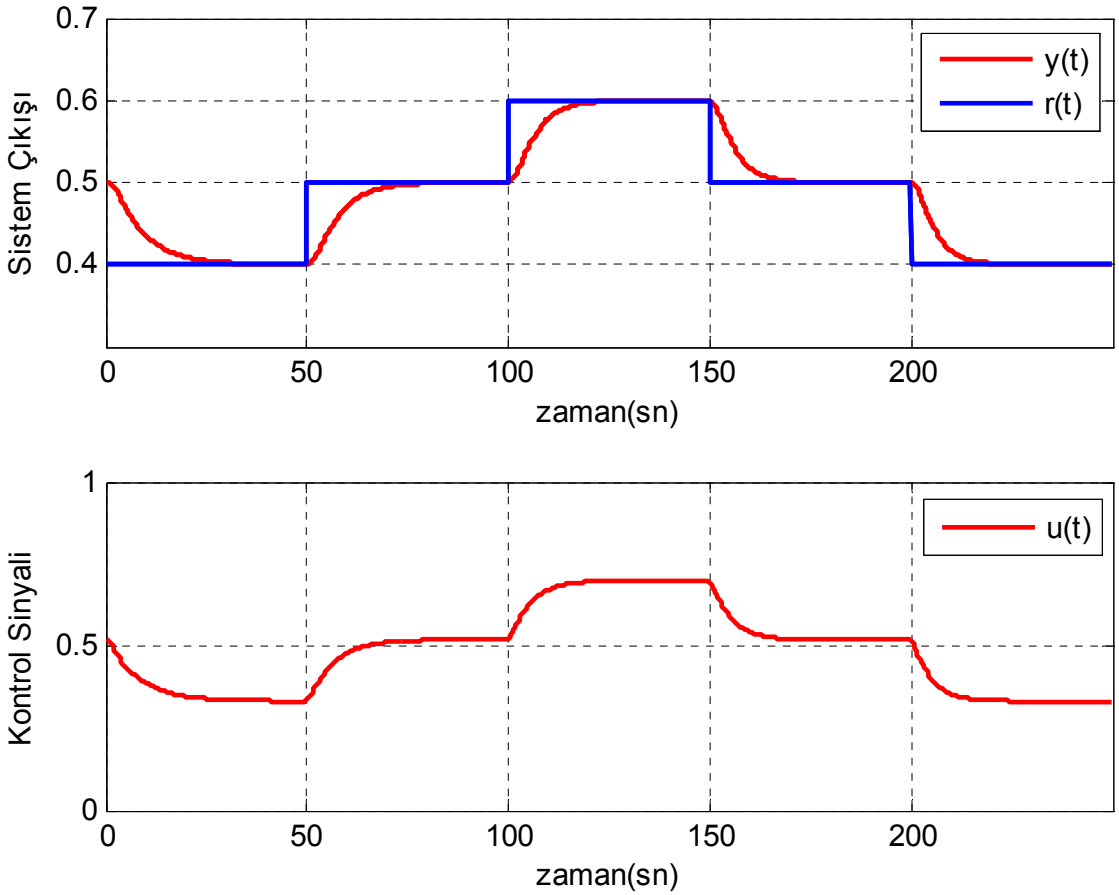
Burada $\eta(n)$ öğrenme oranıdır ve herhangi çizgi arama metodu kullanılarak belirlenebilir. Bu çalışmada öğrenme oranının belirlenmesi için altın bölme metodu kullanılmıştır. Kontrolör parametrelerinin güncellenebilmesi için sisteme ait jakobiyen bilgisinin bilinmesi gerekmektedir. Çevrimiçi model sisteme ait jakobiyen bilgisinin modele bağlı olarak kestirimini sağlamaktadır. Model kullanılarak sistemin jakobiyen bilgisi aşağıdaki gibi öngörülebilir.

$$\frac{\partial y(n)}{\partial u(n)} \cong \frac{\partial \hat{y}(n)}{\partial u(n)} = -\sum_{i=n-L}^{n-1} \frac{\alpha_i(n)(u(n) - x_{svi}(1)) K(\underline{x}_c(n), x_{svi}(n))}{\sigma(n)^2} \tag{3.57}$$

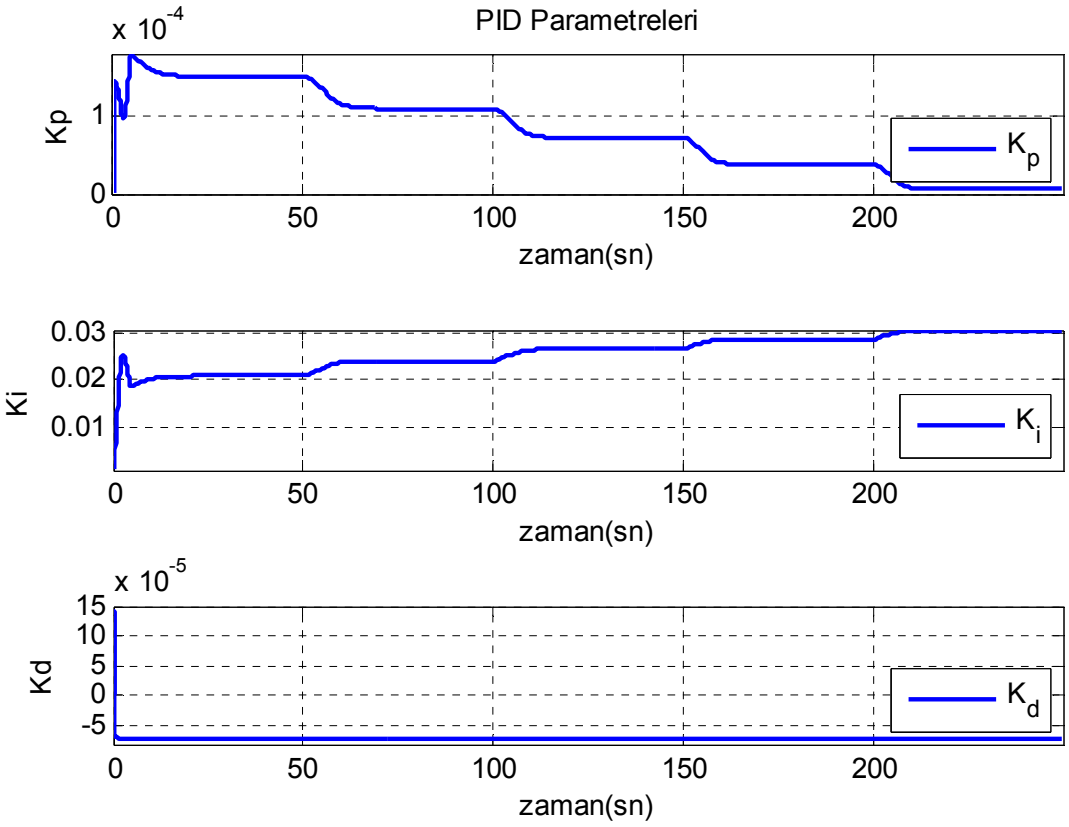
Sisteme ait jakobiyen bilgisi öngörüldükten sonra kontrolör parametreleri aşağıdaki gibi uyarlanabilir.

$$
\begin{aligned}
K_p(n+1) &= K_p(n) + \Delta K_p(n) \quad , \quad \Delta K_p(n) = -\eta(n)e(n)\frac{\partial y(n)}{\partial u(n)}\, xc(1) \\
K_i(n+1) &= K_i(n) + \Delta K_i(n) \quad , \Delta K_i(n) = -\eta(n)e(n)\frac{\partial y(n)}{\partial u(n)}\, xc(2) \\
K_d(n+1) &= K_d(n) + \Delta K_d(n) \quad , \Delta K_d(n) = -\eta(n)e(n)\frac{\partial y(n)}{\partial u(n)}\, xc(3)
\end{aligned}
\tag{3.58}
$$

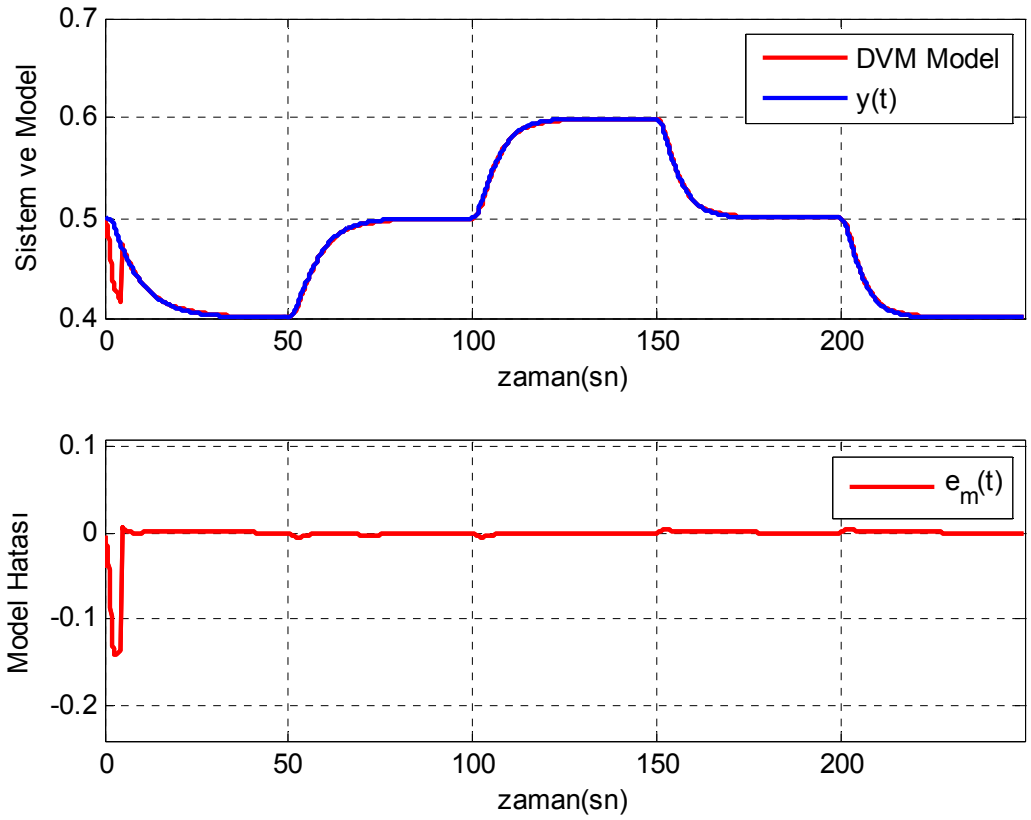
Önerilmiş olan kontrolörün başarımını test etmek için sürekli karıştırılan tank reaktörü sistem olarak kullanılmıştır. Sistemin diferansiyel denklemleri (3.50)'de verildiği gibidir. Modelin çıkışına bağlı olarak belirlenen jakobiyen bilgisi kontrolör parametrelerinin güncellenmesi için kullanılmıştır. Kontrolör parametrelerinin ilk değerleri sıfır olarak seçilmiştir. Sistemin uyarlamalı kontrolör ile kontrol edilmesi sonucu sistemin cevabı şekil 3.29'daki gibi elde edilmiştir.



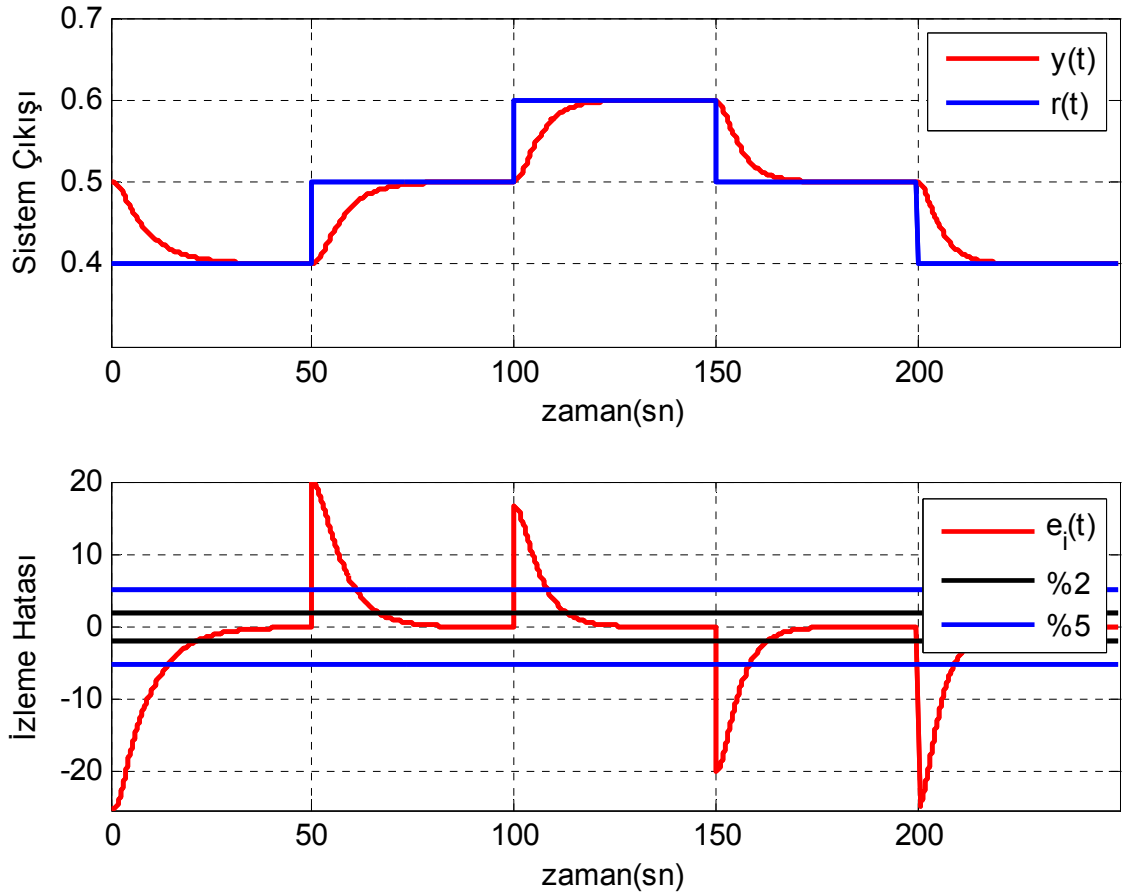
Şekil 3.29 : Sistemin cevabı ve kontrol işareti.



Şekil 3.30 : Kontrolör parametrelerinin değişimi.

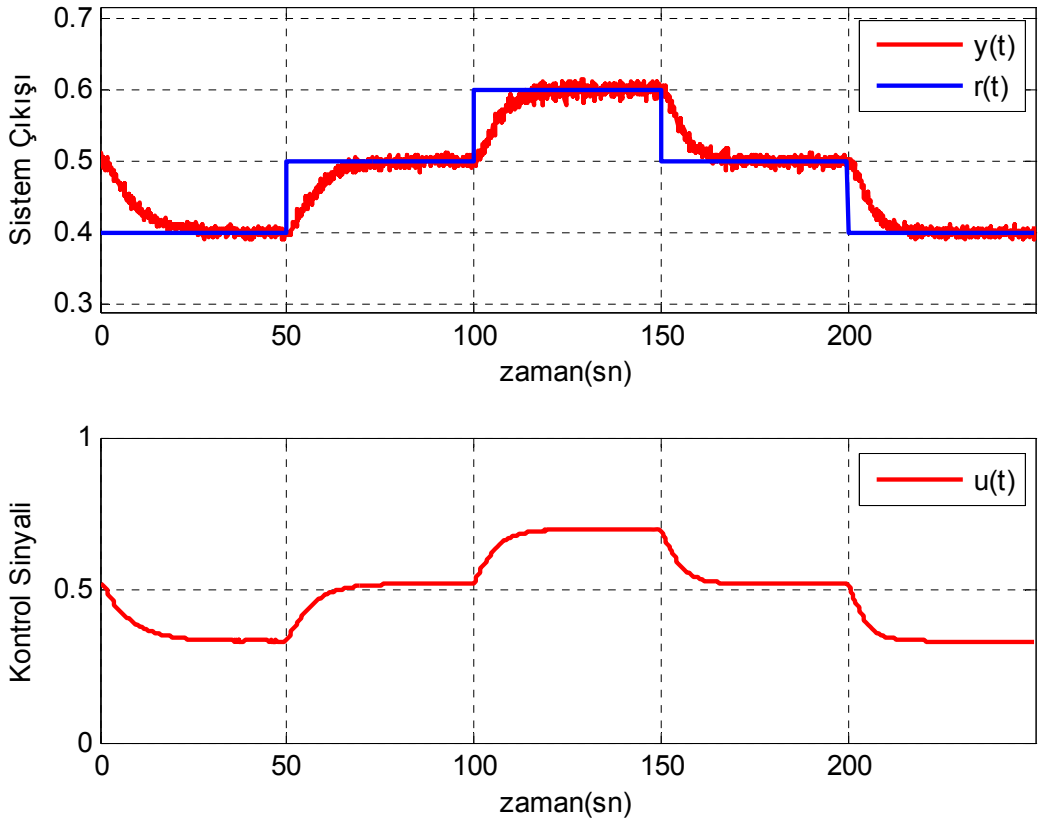


Şekil 3.31 : Çevrimiçi modelin ve sistemin cevabı.

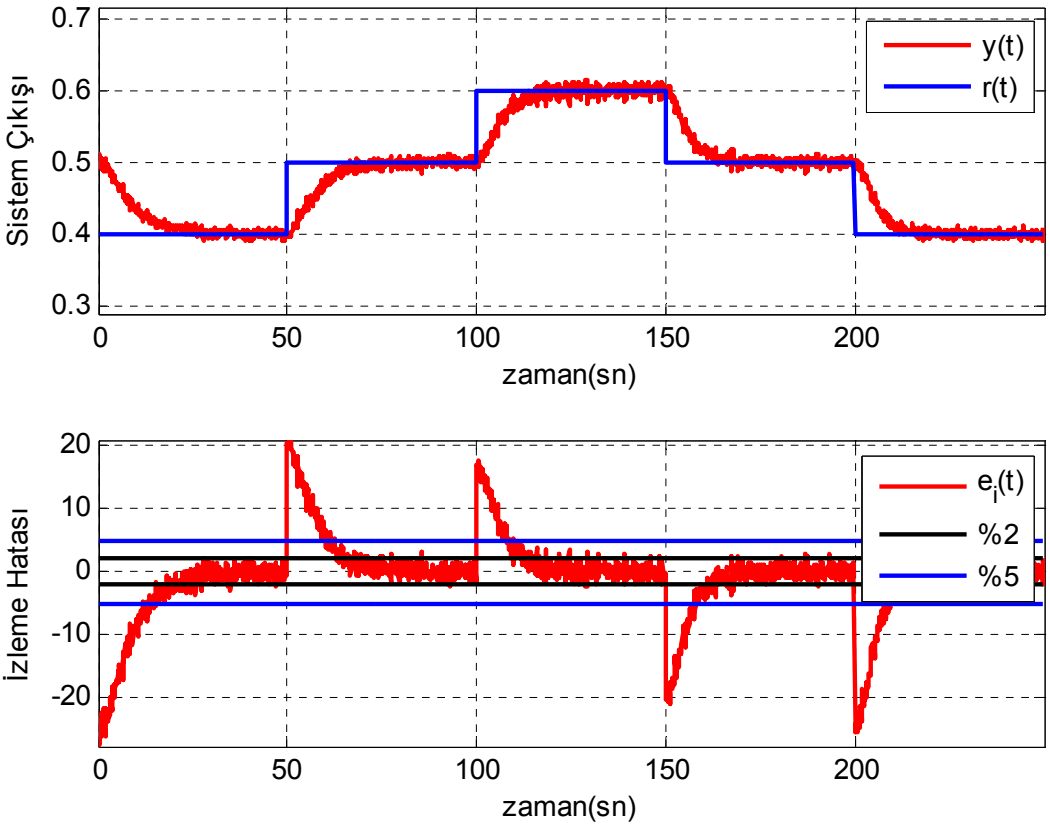


Şekil 3.32 : Sürekli hal hatası.

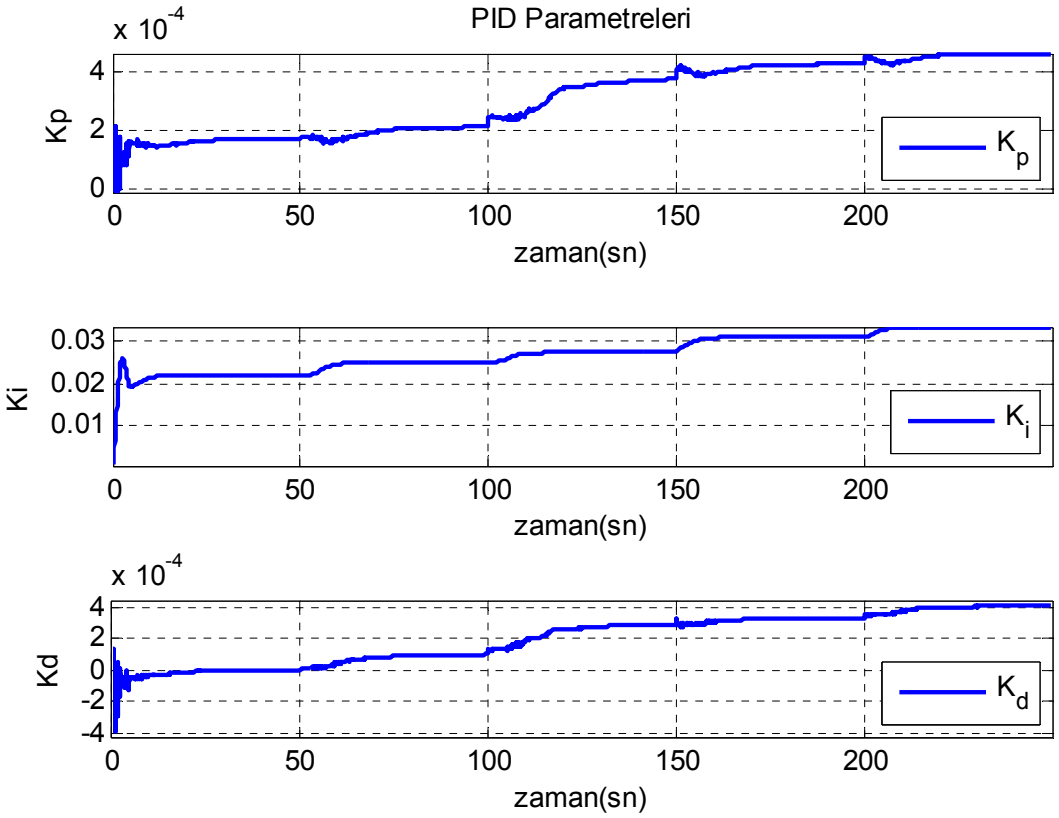
Kontrolör parametrelerinin eğim düşümü yöntemi ile referans işaretine bağlı olarak uyarlanması şekil 3.30'da gösterilmiştir. Jakobiyen bilgisinin kestirimini sağlayan modelin cevabı şekil 3.31' de verilmiştir. Sistemin sürekli hal hatası şekil 3.32'de verilmiştir. Şekil 3.32'den görüleceği üzere sistem sürekli halde %2'lik hata bandının dışına çıkmamaktadır. Kontrolörün uyarlamalı yapısı sistemin sürekli hal hatası yapmasını engellemektedir. Kontrolörün dayanıklılığını test etmek için sistemin çıkışına 40 dB değere sahip ölçme gürültüsü eklenmiştir. Sistemin, kontrolörün ve modelin ölçme gürültüsüne karşı davranışı şekil 3.33-3.36'da verilmiştir. Sistemin sürekli hal hatası şekil 3.34'de gösterilmiştir. Kontrolör parametrelerinin değişimi ise şekil 3.35'de verilmiştir. Gürültülü koşullarda kontrolör parametreleri optimal değerlerine yakınsayarak sistemin istenilen davranışı sergilemesini sağlamaktadır. Şekil 3.33'den görüleceği gibi gürültülü koşullarda kontrolör sistemi oldukca başarılı bir şekilde kontrol edebilmektedir. Modelin başarısı şekil 3.36'da verilmiştir. ÇEK-DVR yöntemi sistem parametrelerinin değişmesine ve gürültüye karşı başarılı bir model elde edilmesini sağlamaktadır.



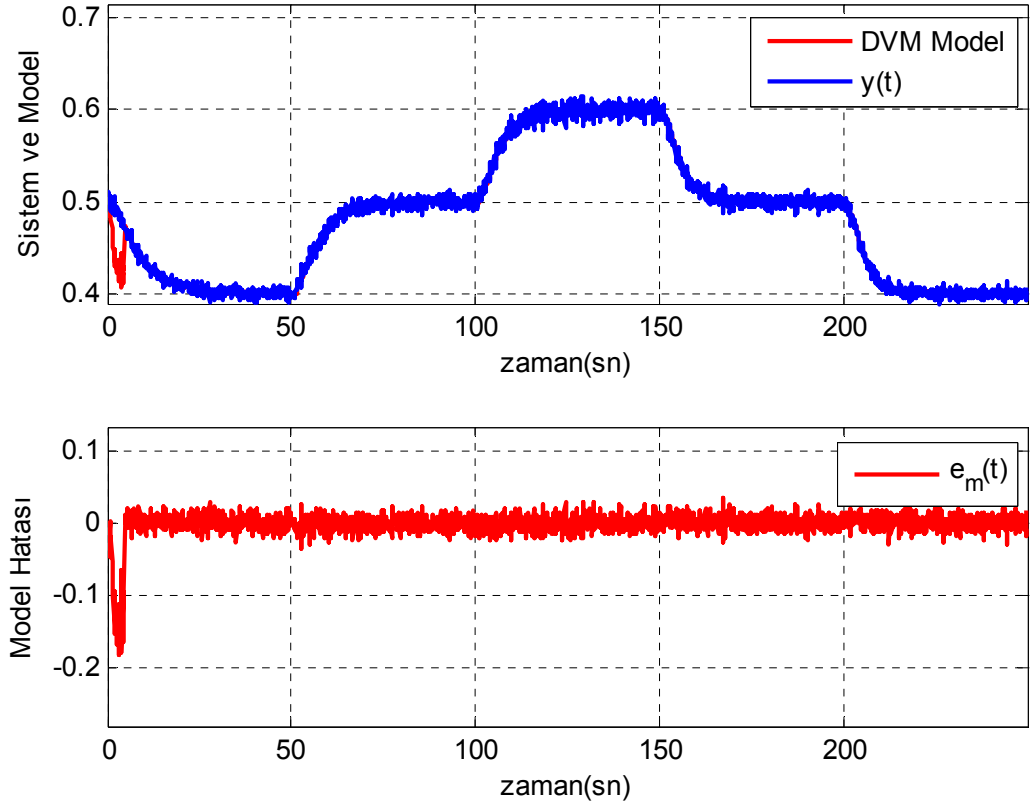
Şekil 3.33 : Sistemin cevabı ve kontrol işareti.



Şekil 3.34 : Sürekli hal hatası.



Şekil 3.35 : Kontrolör parametrelerinin değişimi.



Şekil 3.36 : Çevrimiçi modelin ve sistemin cevabı.

4. ÇEKİRDEK PARAMETRE UYARLAMASININ TANIMA VE KONTROLDEKİ ETKİLERİ

4.1 Giriş

DVM'de ana tasarım bileşeni, giriş uzayı ile öznitelik uzayı arasındaki doğrusal olmayan haritalama fonksiyonu olan çekirdektir [19]. Çekirdeğin ana fonksiyonu düşük dereceden giriş uzayında doğrusal olarak ayrıştırılamayan sınıflandırma problemini, doğrusal olarak sınıflandırmanın yapılabileceği daha yüksek dereceden öznitelik uzayına haritalamaktır. Haritalamada kullanılan çekirdek fonksiyonlarının numerik parametreleri regresyon ve sınıflandırma performasını doğrudan etkilemektedir. Bundan dolayı, çekirdek fonksiyonu ve ona ait parametrelerin seçimi modelleme ve kontrol performansı açısından büyük öneme sahiptir. Gauss çekirdek için, band genişliği ana numerik parametredir. Band genişliği çok küçük seçildiğinde, öznitelik uzayında benzer öznitelikler farklı lokasyonlara haritalanacak ve model için büyük bir öneme sahip öznitelikler, öznitelik uzayına aktarılamayabilecektir. Eğer çok büyük seçilirse, model için önemsiz farklı öznitelikler, öznitelik uzayında çok yakın lokasyonlara haritalanacaktır. Sonuç olarak, çekirdek parametresinin çok küçük veya çok büyük seçilmesi durumunda çekirdek doğrusal olmama özelliğini kaybedecektir [24]. En iyi regresyon performansı model için gereksiz özniteliklerin filtrelenmesi ile elde edilebilir. Bu gibi etkenlerden dolayı, optimal çekirdek parametresinin seçimi, çekirdek makinesinin eğitim ve test performansı açısından büyük bir öneme sahiptir.

Teknik literatürde, çekirdek parametresinin uyarlanması 'çekirdek polarizasyonu' olarak adlandırılmaktadır ve sınıflandırma problemlerinde optimal parametreyi belirlemek için çeşitli yaklaşımlar önerilmiştir. Eğim düşümü [25,26,27], ızgaralama, çapraz doğrulama [28], birini dışarıda bırakma [29] (leave one out [29]), logaritmik konveks konkav prosedür (LCCP (log convex concave procedure)) [30], ve evrimsel arama algoritmaları, optimal çekirdek parametresini aramak için kullanılmıştır. Genetik algoritmalar (genetic algorithms) [31], sürü optimizasyonu (swarm optimization) [32,33,34], benzetilmiş tavlama (simulated annealing) [35], kuantum-

esinlenmiş savunma sistemleri (quantum-inspired immune systems) [36] ve yapay savunma sistemleri (artificial immune systems) [37] çekirdek parametresinin hesaplanmasında kullanılmıştır. [38]'de, parametre kümesinin kararlılığını iyileştirmek için hibrit CLPSO-BFGS'den faydalanılmıştır. Regresyon problemleri için, çapraz doğrulama (Cross validation [39]), parçacık sürü optimizasyonu (particle swarm optimization) [40,41], örüntü arama (pattern search) [42], model tabanlı global optimizasyon metodu [43] ve ızgaralama-elmas (grid-diomand search) yöntemi [44], çekirdek parametresinin uyarlanmasında başarılı bir şekilde kullanılmıştır. Bu yaklaşımlardaki ortak özellik çekirdek parametresinin çevrimdışı uyarlanmasıdır. Bu çalışmada literatürdeki yaklaşımlardan farklı olarak çevrimiçi en küçük kareler destek vektör makinelerine ait çekirdek parametresi çevrimiçi uyarlanmıştır. Çekirdeğe katılan adaptasyon yeteneğinin sistem tanılama ve model tabanlı uyarlamalı kontrolör tasarımındaki başarımını değerlendirmek için sürekli karıştırmalı tank reaktör sistemi (CSTR) üzerinde benzetimler yapılmıştır. Uygulanan yöntemin tanılama problemi ve kontrolör tasarımındaki etkileri incelenmiş, ayrıca çekirdeğe katılan uyarlama özelliğinin gürültü olması durumunda ve sistemin değişen parametrelerine bağlı olarak kontrolör dayanıklılığı üzerindeki gösterilmiştir.

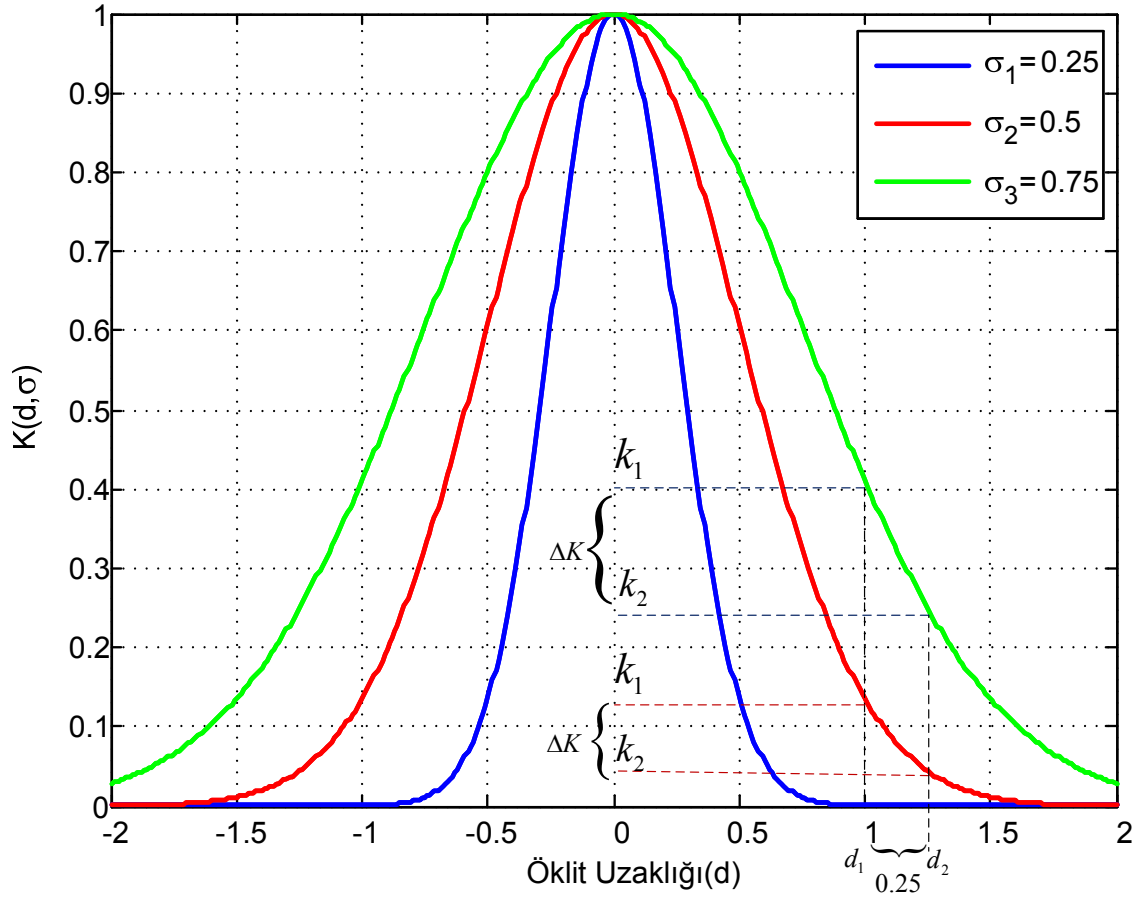
4.2 Çekirdek Parametresi

Çekirdek parametresinin öznitelik uzayındaki etkisinin incelenmesi için Gauss çekirdek fonksiyonu kullanılmıştır.

$$K(\underline{x}_i(n), \underline{x}_j(n)) = \exp(-(\frac{d_{i,j}(n)}{2\sigma(n)^2})) \tag{4.1}$$

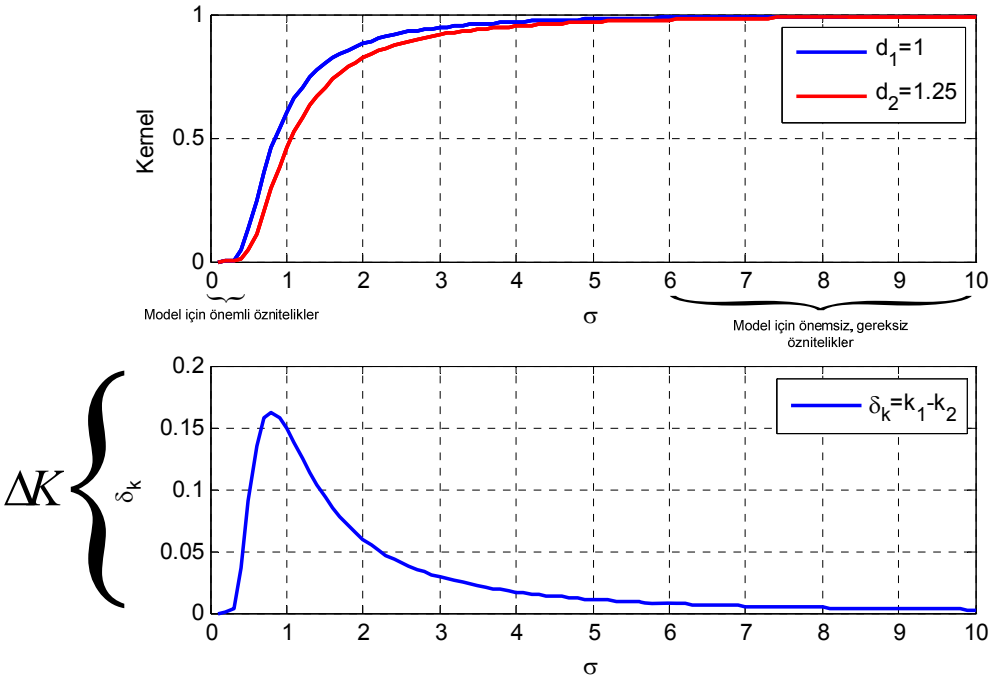
$$d_{i,j}(n) = (\underline{x}_i(n) - \underline{x}_j(n))^T (\underline{x}_i(n) - \underline{x}_j(n)) \tag{4.2}$$

Burada $\sigma(n)$, radyal tabanlı gauss çekirdek fonksiyonunun band genişliğini, $\underline{x}_i(n)$ sistemin şu anki durumlarını içeren durum vektörünü ve $d_{i,j}(n)$ ise şu anki durum vektörü ile j'ninci veri arasındaki öklit uzaklığını ifade eder. Çekirdek parametresinin etkisini incelemek için giriş uzayında bir tanesi çekirdeğin özünü oluşturacak olan destek vektör olmak üzere üç tane eğitim verisi şekil 4.1'deki gibi alınsın.



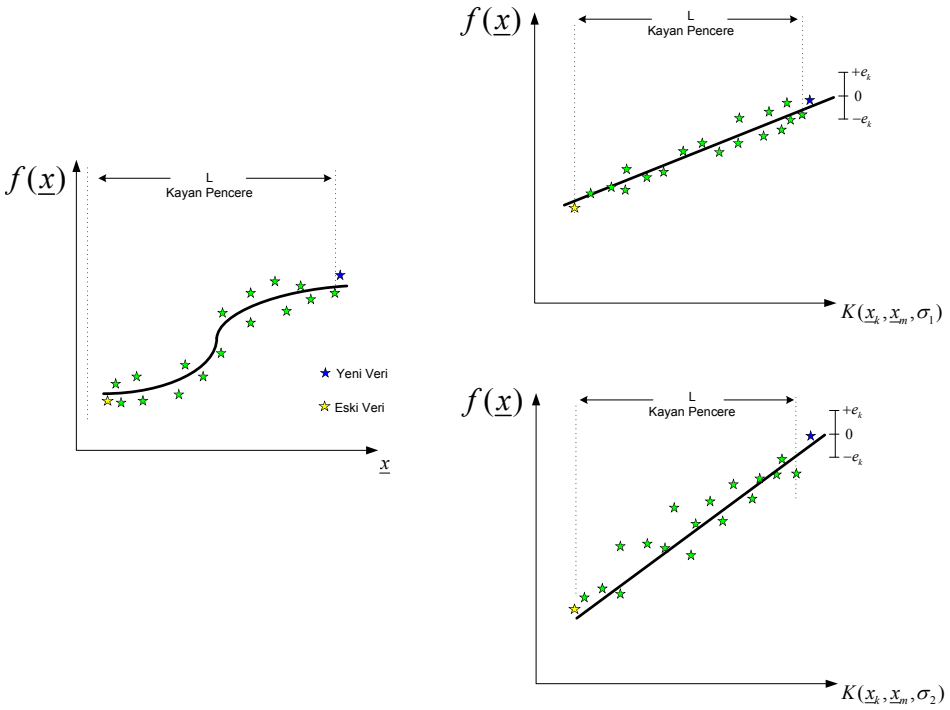
Şekil 4.1 : Çekirdek fonksiyonu.

Eğitim verilerinin destek vektöre öklit uzaklığı $d_1 = 1$ ve $d_2 = 1.25$ olarak verilsin. $K(d,\sigma)$ eğitim verilerinin öznitelik uzayındaki destek vektöre benzerliğini göstermektedir. Giriş uzayında sabit uzaklıklara sahip verilerin benzerliği çekirdek parametresine bağlı olarak değişmektedir. Çekirdek parametresinin 0-10 aralığındaki değişimi için giriş uzayındaki verilerin lokasyonları sabit olmasına rağmen destek vektöre benzerliği şekil 4.2'de gösterilmiştir. Buradan görüldüğü üzere çekirdek parametresinin büyük seçilmesi durumunda giriş uzayındaki farklı veriler öznitelik uzayında benzer veri olarak algılanacaktır. Bu nedenle model için gereksiz öznitelikler, öznitelik uzayına haritalanacaktır. Çekirdek parametresinin küçük seçilmesi durumunda ise model için önemli veriler filtrelenerek öznitelik uzayına haritalanmaları engellenecektir. Her iki durumda da çekirdek fonksiyonu doğrusal olmama özelliğini kaybedecektir.

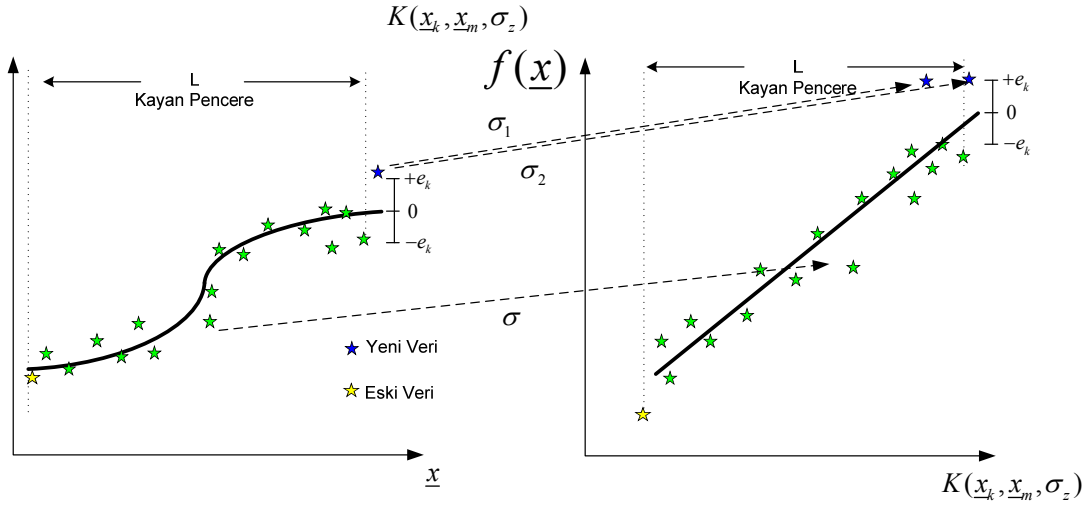


Şekil 4.2 : Verilerin destek vektöre benzerliği.

Farklı çekirdek parametreleri için regresyon problemindeki eğitim verilerinin dağılımı şekil 4.3'deki gibi olabilir. Çekirdek parametresine bağlı olarak regresyon problemi sonucu ve modelin performansı değişmektedir.

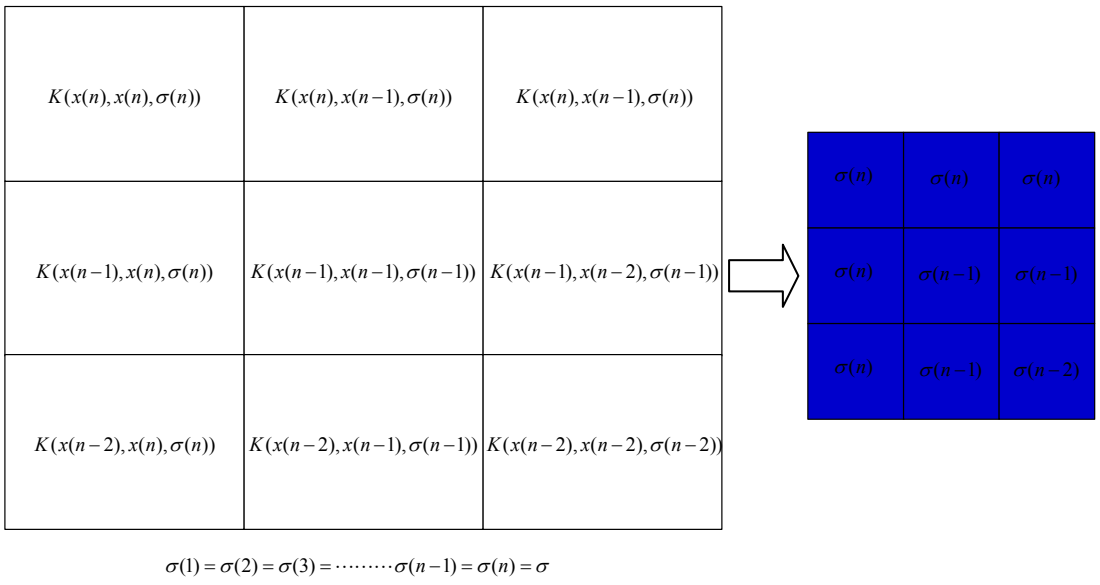


Şekil 4.3 : Regresyon problemi.



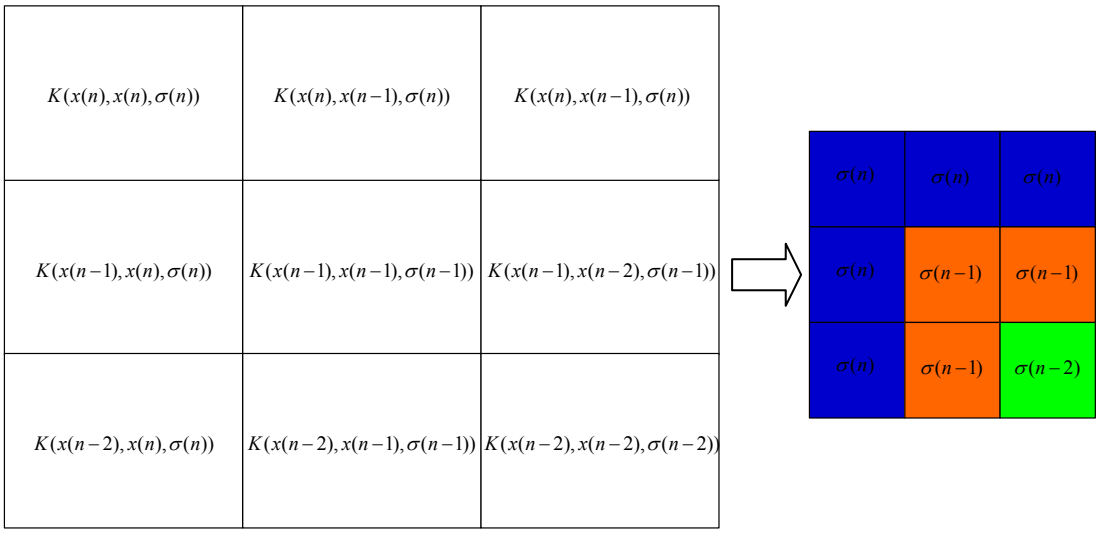
Şekil 4.4 : Çevrimiçi regresyon.

Bu çalışmadaki ana fikir eğitim kümesine eklenen yeni verinin regresyon performansını iyileştirecek şekilde öznitelik uzayına haritalanmasını sağlayacak çekirdek bant genişliğini bulmaktır. ÇEK-DVR'de uyarlamalı çekirdeğin çekirdek matrisi üzerindeki etkisini incelemek için şekil 4.5'deki şekil çizilmiştir. *L=3* (Kayan pencere boyutu) olarak alınan bu şekilde, parametresi sabit olan bir çekirdek kullanıldığında bütün veriler aynı bant genişliği ile çekirdek matrisine aktarılmaktadır.



Şekil 4.5 : Çekirdek matrisi(Sabit bant genişliği).

Çekirdek parametresinin uyarlamalı seçilmesi durumunda, veri kümesine eklenecek her yeni verinin diğer eğitim verileriyle ilişkilerini gösteren q ve Q blokları aynı bant genişliğine sahip çekirdeklerle kullanılarak haritalanmaktadır.



Şekil 4.6 : Çekirdek matrisi(Uyarlamalı bant genişliği).

Şekil 4.6'dan görüldüğü gibi, eğitim setine eklenen veriler farklı bant genişlikleri ile haritalanırlar.

4.3 Eğim Düşümü Yöntemi ile Uyarlamalı Çekirdek

Çekirdek fonksiyonunda sabit parametre kullanmak yerine, eğim düşümü yöntemi kullanılarak her iterasyonda, çekirdek parametresinden kaynaklanan modelleme hatasının minimize edilmesi için, bu parametrenin uyarlanması önerilmiştir. Optimize edilecek amaç fonksiyonu, model hatasına bağlı olarak (4.3)'deki gibi seçilmiştir:

$$J_{\mathrm{m}}(n)=\frac{1}{2}[\,y(n)-\hat{y}(n)\,]^2=\frac{1}{2}[e_m(n)^2] \tag{4.3}$$

Burada e_m modelleme hatasıdır. $\hat{y}(n)$ çekirdek parametresinin bir fonksiyonu olduğu için, çekirdek band genişliği, yukarıdaki amaç fonksiyonuna eğim düşümü yöntemi uygulanarak, aşağıdaki gibi uyarlanabilir [50,56].

$$\begin{aligned}\Delta\sigma(n)&=-\eta(n)\,\frac{\partial J_m(n)}{\partial\sigma(n)}\\&=-\eta(n)e_m(n)(-1)\frac{\partial\hat{y}(n)}{\partial\sigma(n)}\end{aligned} \tag{4.4}$$

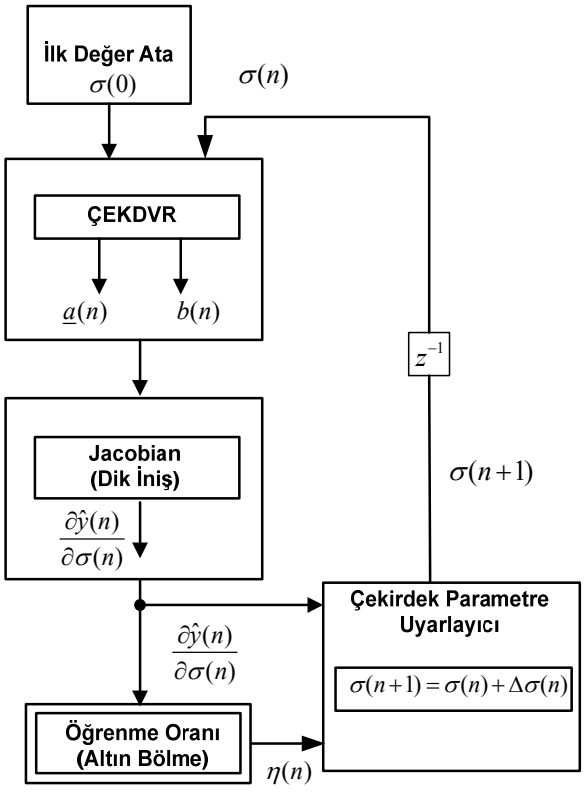
Burada $\eta(n)$ öğrenme oranıdır ($0<\eta(n)<1$). Öğrenme oranı herhangi bir çizgi arama metodu kullanılarak belirlenebilir. Bu çalışmada altın bölme metodu kullanılmıştır. (4.5)'de verilen $\frac{\partial \hat{y}(n)}{\partial \sigma(n)}$ ise model çıkışının band genişliğine bağlı olarak kısmi türevidir.

$$\frac{\partial \hat{y}(n)}{\partial \sigma(n)} = \sum_{i=n-L}^{n-1} [\ \frac{\alpha_i(n)\, K(\underline{x}_c(n), x_{svi}(n))}{\sigma(n)^3} d_{c,svi}(n)] \qquad \textbf{(4.5)}$$

Böylece çekirdek parametresi aşağıdaki gibi güncellenebilir.

$$\sigma(n+1) = \sigma(n) + \Delta\sigma(n) \qquad \textbf{(4.6)}$$

Eğim düşümü yöntemi ile çekirdek parametresinin uyarlanmasının akış diyagramı aşağıdaki gibidir.



Şekil 4.7 : Akış diyagramı.

4.4 Çekirdek Uyarlamasının Tanılama ve Kontroldeki Etkileri

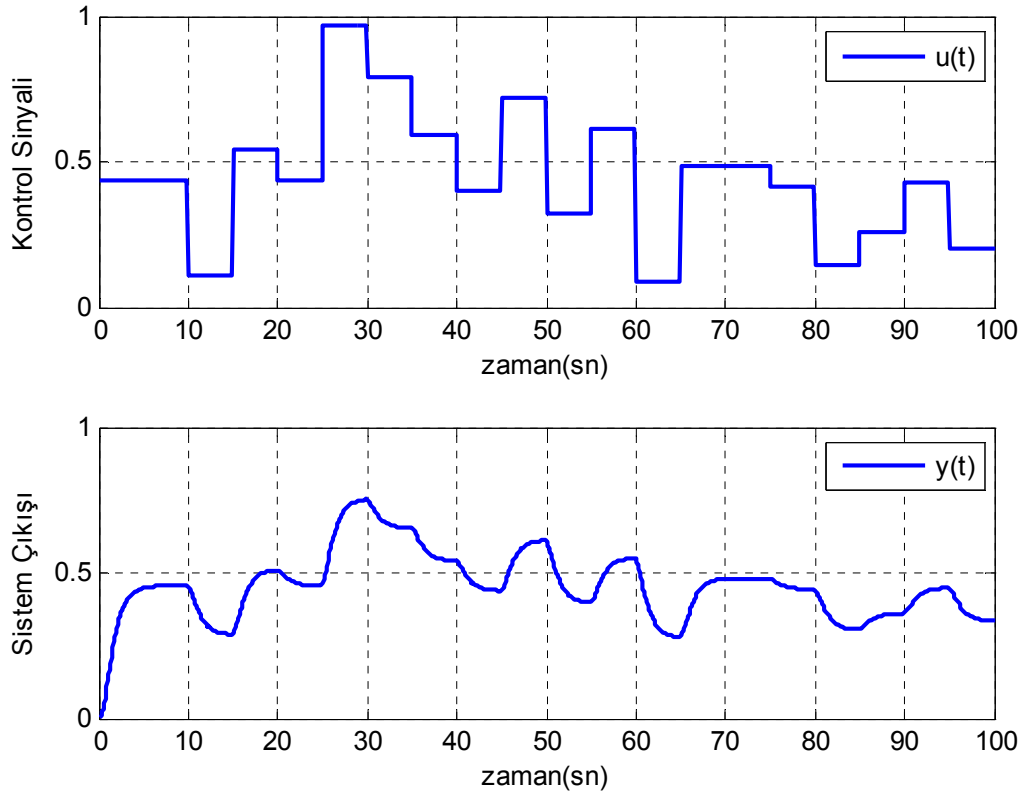
Önerilen çekirdek parametresi adaptasyonunun modelleme ve kontroldeki başarımı, doğrusal olmayan bir sistem olan, sürekli karıştırmalı tank reaktöründe (SKTR)

denenmiştir. SKTR sisteminin dinamikleri (3.50)'deki diferansiyel denklem kümesiyle verilmiştir. Kontrol işaretinin genliği 0 ve 1 arasında kısıtlanmıştır. Şekil 4.8'de görüldüğü gibi, sistemin dinamiklerini ortaya çıkarmak için 0-1 aralığında değişen kontrol işareti sisteme 100 sn süresince, $\tau_{\min} = \tau_{\max} = 5$ sn olacak şekilde uygulanmıştır. Örnekleme periyodu 0.1 sn seçilmiştir. Sistem benzetiminde 4. dereceden Runga Kutta metodu kullanılmıştır. NARX Modelinin geçmiş giriş derecesi (n_u) ve geçmiş sistem çıkışı derecesi (n_y), 3 olarak seçilmiştir.

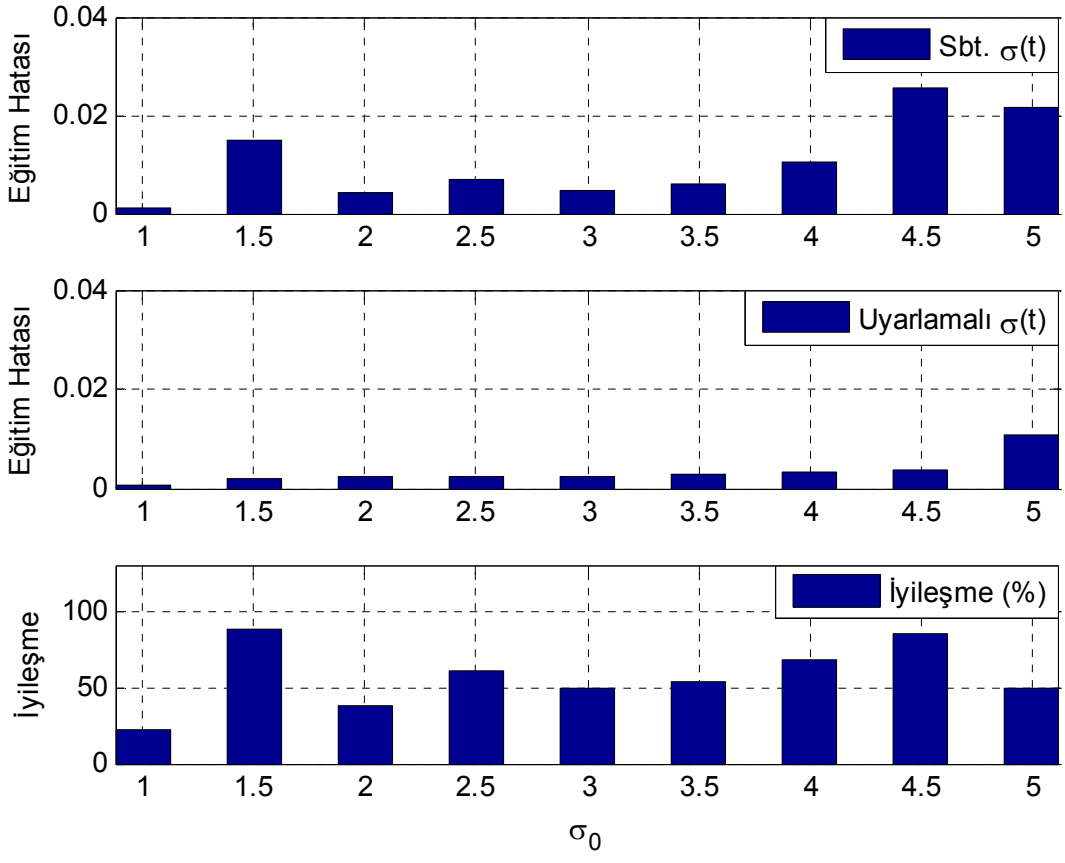
4.4.1 Çekirdek uyarlamasının tanılamadaki etkileri

Çekirdek parametresine katılan uyarlanma yeteneğinin tanılama problemine etkisini test etmek için, uyarlamalı çekirdek ile elde edilen sonuçlar, sabit çekirdek parametresi kullanılarak elde edilen sonuçlar ile karşılaştırılmıştır. Bunun için farklı ilk koşullara sahip çekirdekler için çeşitli simülasyonlar yapılmıştır. Şekil 4.8'de görüldüğü gibi, sistemin dinamiklerini ortaya çıkarmak için 0-1 aralığında değişen kontrol işareti sisteme 100 sn süresince, $\tau_{\min} = \tau_{\max} = 5$ sn olacak şekilde uygulanmıştır. Çekirdek parametresinin ilk değerleri 1-5 arasında 0.5'lik aralıklarla değiştirilerek modelin performansı farklı ilk değerler için incelenmiştir. Sabit ve uyarlamalı çekirdek için eğitim hataları (MAE) ve model performansındaki iyileşmeler verilmiştir. Şekil 4.10'da çekirdek parametresinin yakınsadığı değerler verilmiştir. Şekil 4.9 ve şekil 4.11'den görüldüğü gibi minimum eğitim hatası $\sigma(0) = 1$ ve maksimum performans iyileşmesi $\sigma(0) = 1.5$ iken elde edilmiştir. Sonuçlar modelin performansının % 87.505'e kadar iyileştirilebileceğini göstermektedir. En küçük eğitim hatası $\sigma(0) = 1$ iken elde edildiği için, bu değer kontrol sürecinde çekirdek parametresinin ilk değeri olarak kullanılmıştır. $\sigma(0) = 1.5$ için çekirdek parametresinde adaptasyon olmaması durumunda modelin çıkışı şekil 4.13'deki gibidir.

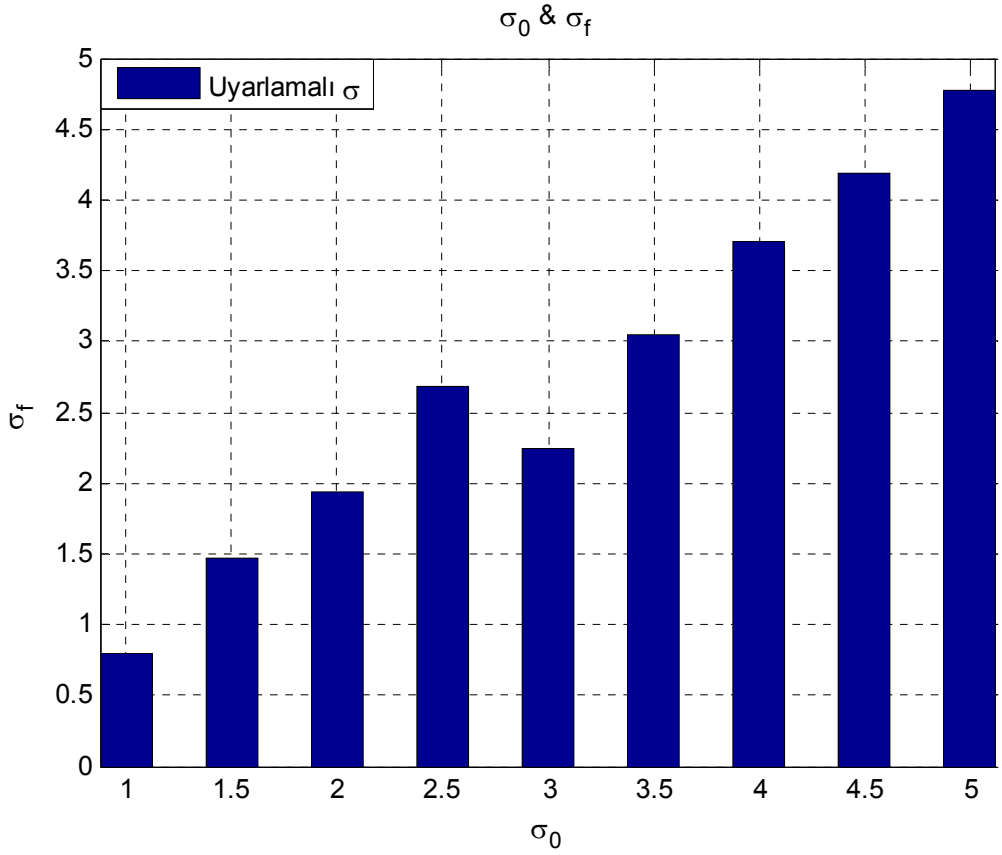
Çekirdek parametresine uyarlama katılmasıyla birlikte modelin cevabı şekil 4.14'deki gibi olmaktadır. Çekirdek parametresinin optimal değerine yakınsaması şekil 4.15'de verilmiştir. Performanstaki bu iyileşme, hem modelleme hem de izleme hatasını minimize etmek için çekirdek parametresinin kontrol sürecinde uyarlanabileceği fikrinin doğmasına yol açmıştır.



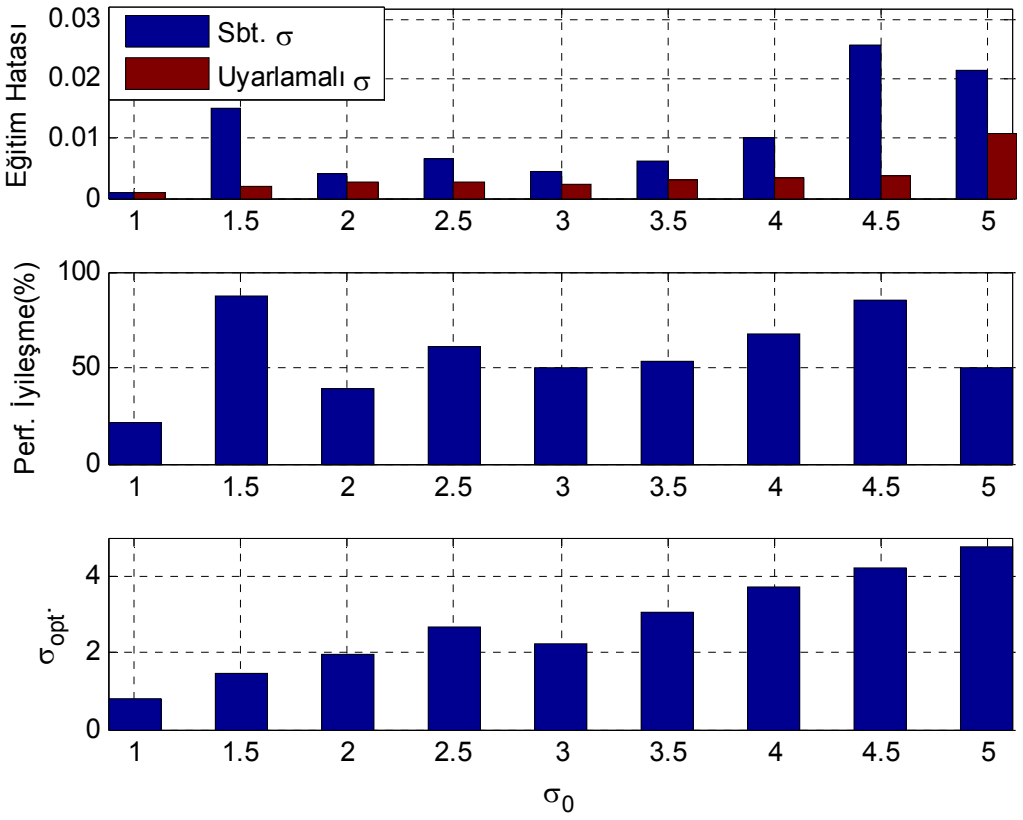
Şekil 4.8 : Kontrol işareti ve sistem çıkışı.



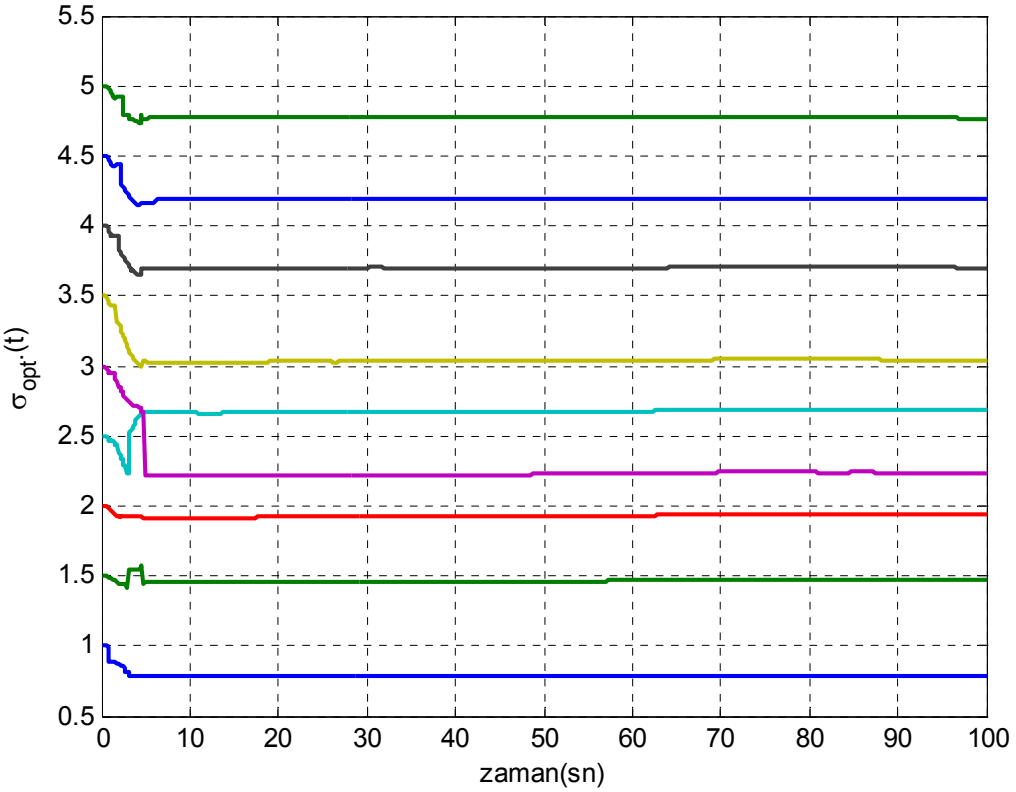
Şekil 4.9 : Eğitim hataları ve performanstaki iyileşme.



Şekil 4.10 : Çekirdeğin band genişliğinin ilk değerleri ve yakınsanan değerler.

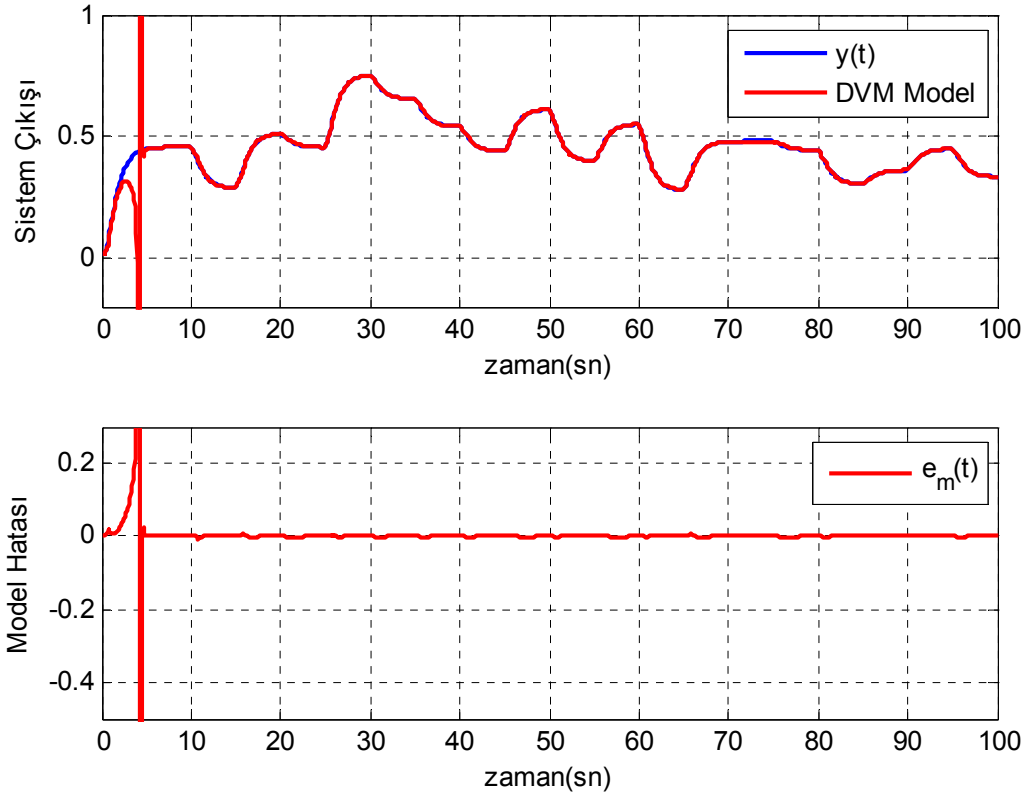


Şekil 4.11 : İlk koşullar(σ_0), eğitim hataları , performans, yakınsanan değerler.

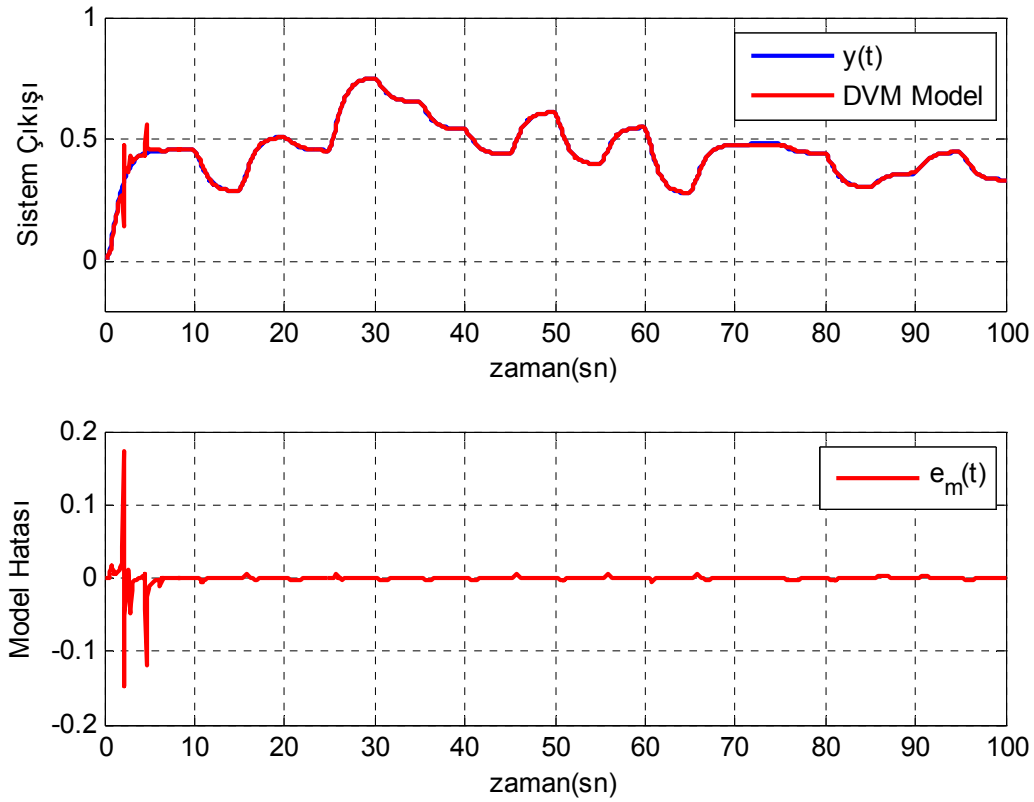


Şekil 4.12 : Band genişliklerinin değişimi.

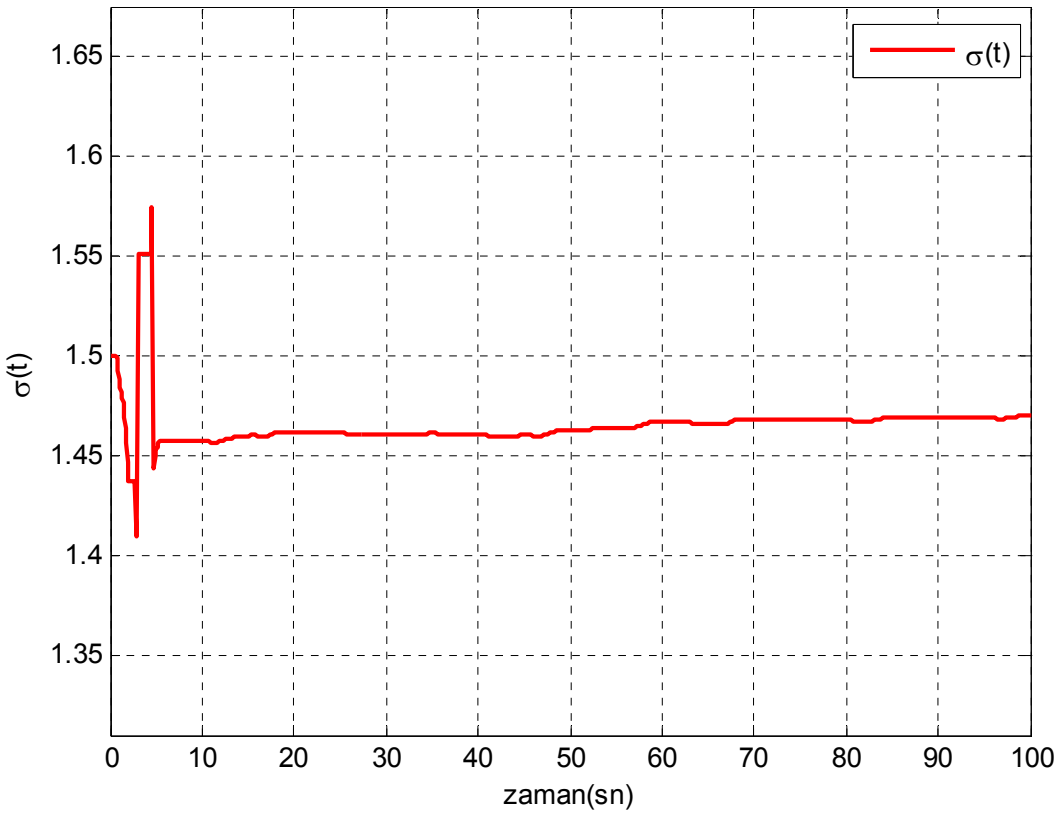
Şekil 4.12'da çekirdek parametrelerinin optimal değerlerine yakınsaması verilmiştir.



Şekil 4.13 : Uyarlamasız çekirdeğe sahip modelin çıktısı.



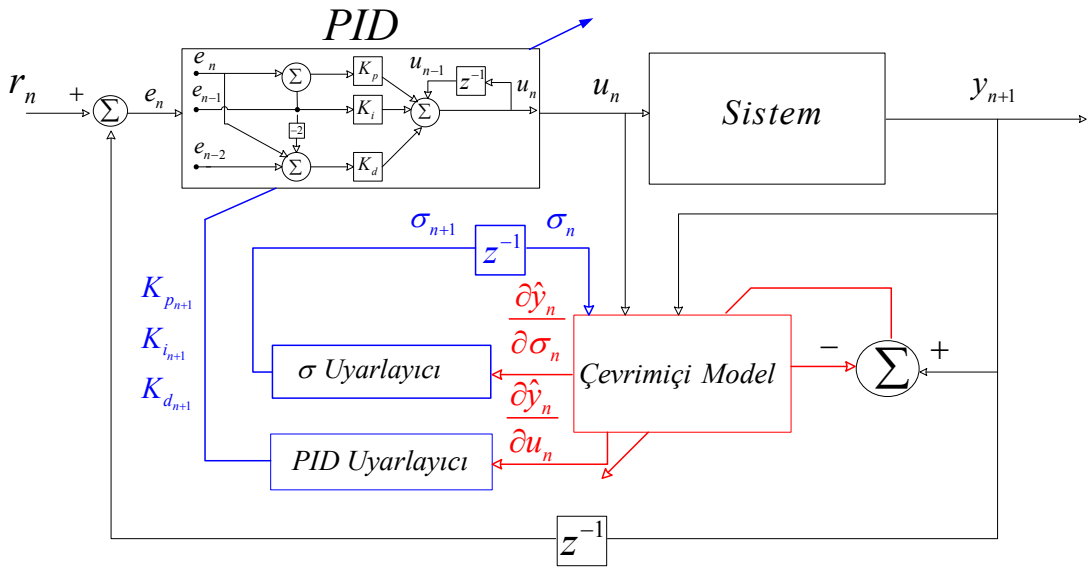
Şekil 4.14 : Uyarlamalı çekirdeğe sahip modelin çıktısı.



Şekil 4.15 : Çekirdek parametresinin değişimi.

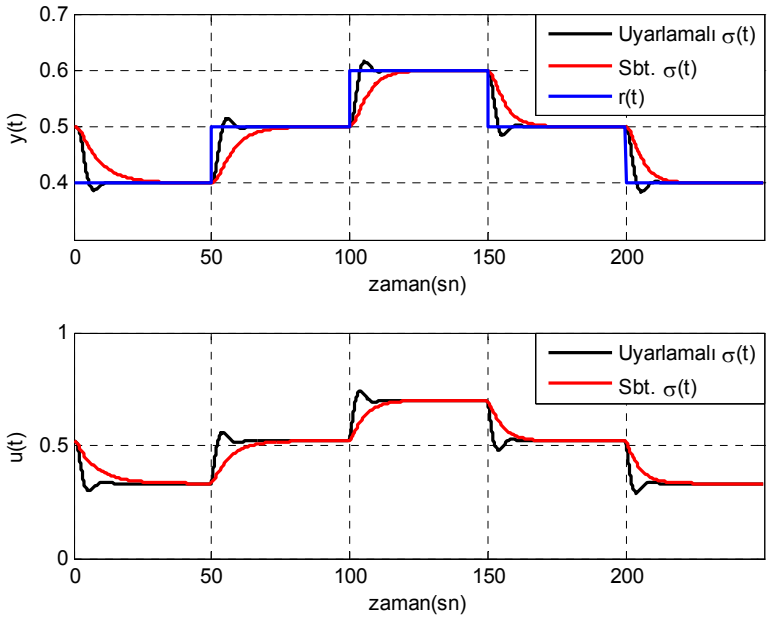
4.4.2 Çekirdek uyarlamasının kontroldeki etkileri

Önerilen uyarlamalı kontrolör ve uyarlamalı çekirdek şekil 4.16'de verilmiştir.



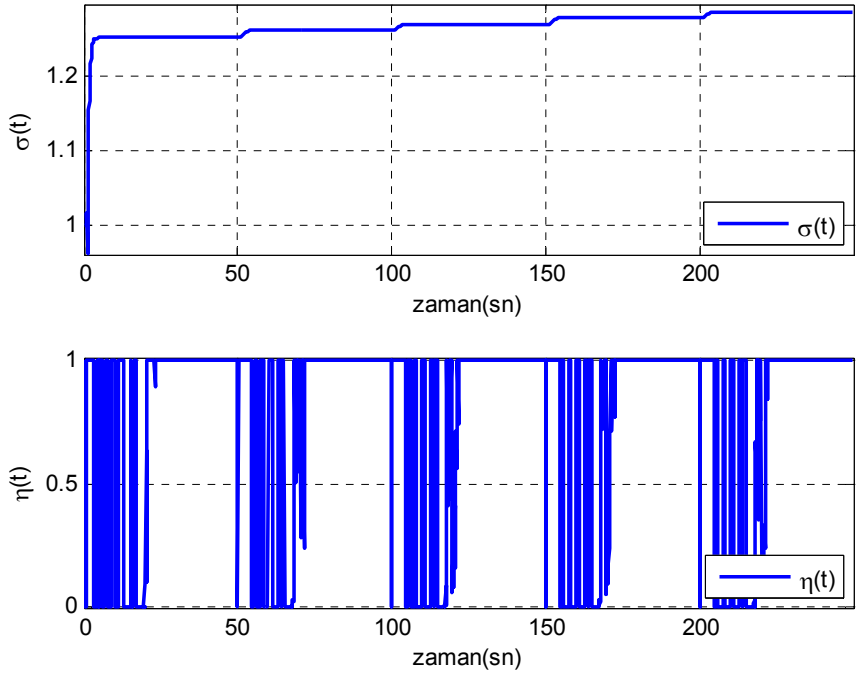
Şekil 4.16 : Kontrol ve modelleme yapısı.

Çevrimiçi model bloğunun çıktısı olan jakobiyen bilgisi uyarlamalı PID kontrolörün parametrelerini belirlemek için kullanılmaktadır. Tüm kontrolör parametrelerinin ilk değerleri sıfır olarak seçilmiştir. Çekirdek parametresine katılan esnekliğin kontrol performansına etkisini incelemek için çekirdek parametresinin ilk değeri minimum eğitim hatasının elde edilmesini sağlayan $\sigma(0)=1$ olarak seçilmiştir.

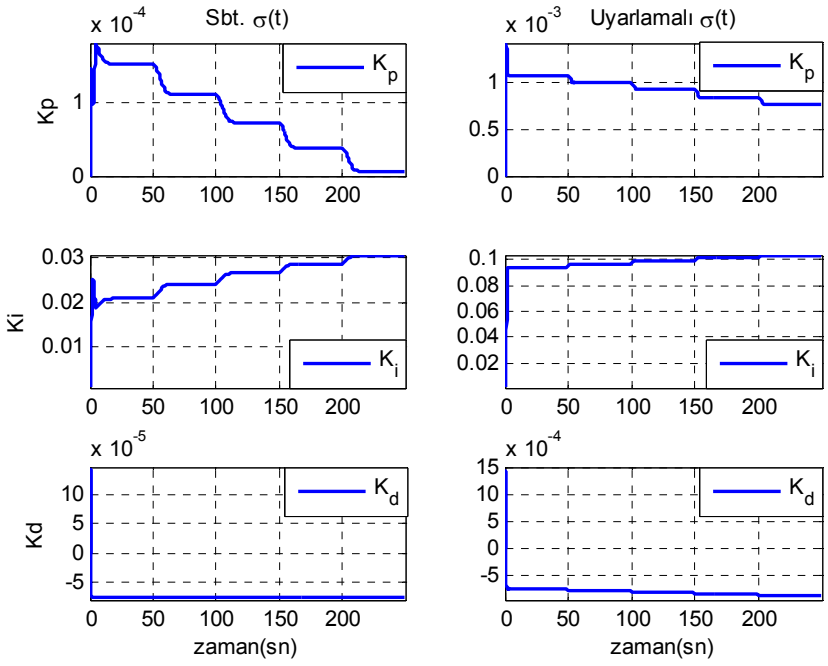


Şekil 4.17 : Uyarlamalı ve sabit çekirdek parametresinin sisteme etkisi.

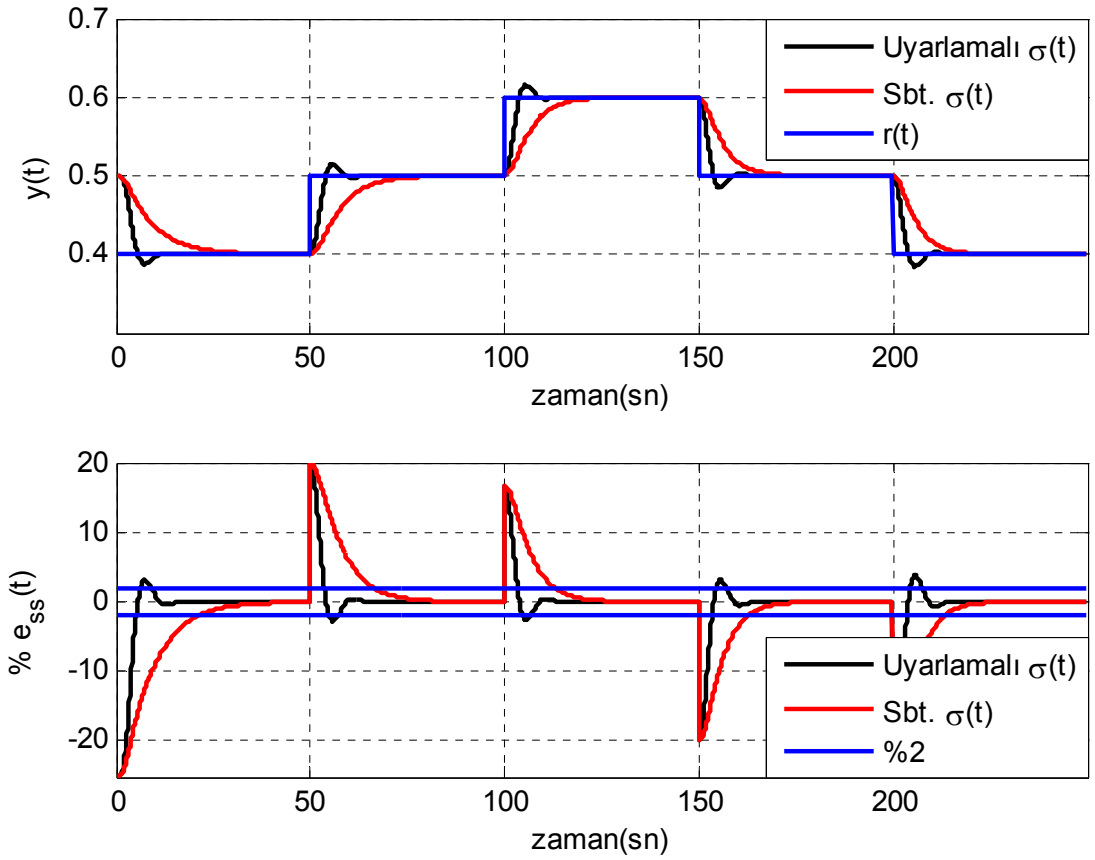
Şekil 4.17 sabit çekirdekli model ve uyarlamalı çekirdeğe sahip modelle belirlenen PID kontrolörlerin iyi bir izleme performansı sağladıklarını göstermektedir. Buna ek olarak çekirdek parametresine katılan adaptasyon yeteneğinin sistemi hızlandırdığı görülmektedir. Çekirdek parametresinin değişimi ve öğrenme oranı şekil 4.18'de verilmiştir. Kontrolör parametrelerinin değişimi şekil 4.19'da gösterilmektedir. Sistemin cevapları ve sürekli hal hataları ise şekil 4.20'de verilmiştir.



Şekil 4.18 : Çekirdeğin band genişiliği ve öğrenme oranı.



Şekil 4.19 : PID kontrolör parametreleri.



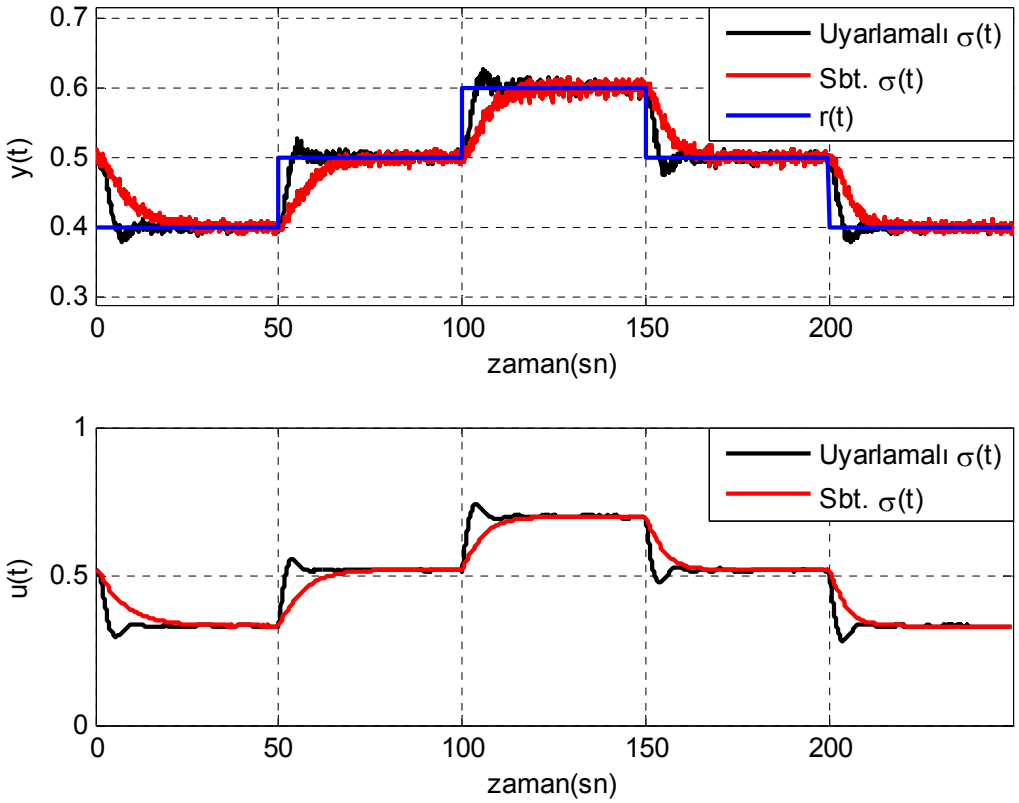
Şekil 4.20 : Sürekli hal hatası.

Ölçme gürültüsüne bağlı olarak kontrolörlerin dayanıklılığını test etmek için sistemin çıkışına 40 dB işaret gürültü oranına sahip gauss gürültüsü eklenmiştir. SNR aşağıdaki gibi verilmektedir.

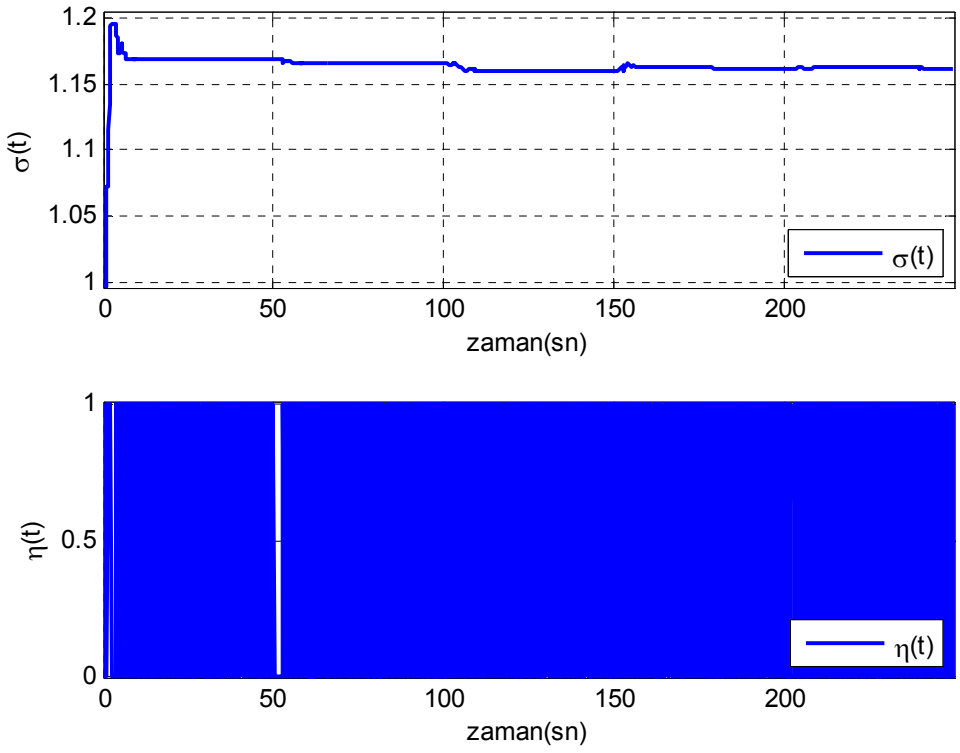
$$SNR = 10\log_{10}(\frac{\sigma_y^2}{\sigma_\upsilon^2})\ dB \qquad \textbf{(4.6)}$$

Burada σ_y^2 ve σ_υ^2, sırasıyla, sistem çıkışının ve eklenen gürültünün varyanslarıdır [10]. Şekil 4.21'de kapalı çevrim sistemin gürültülü koşullardaki davranışı verilmiştir. Şekil 4.22 çekirdek parametresinin değişimini, şekil 4.23 gürültü altında kontrolör parametrelerinin değişimini, şekil 4.24 ise sürekli hal hatasını göstermektedir.

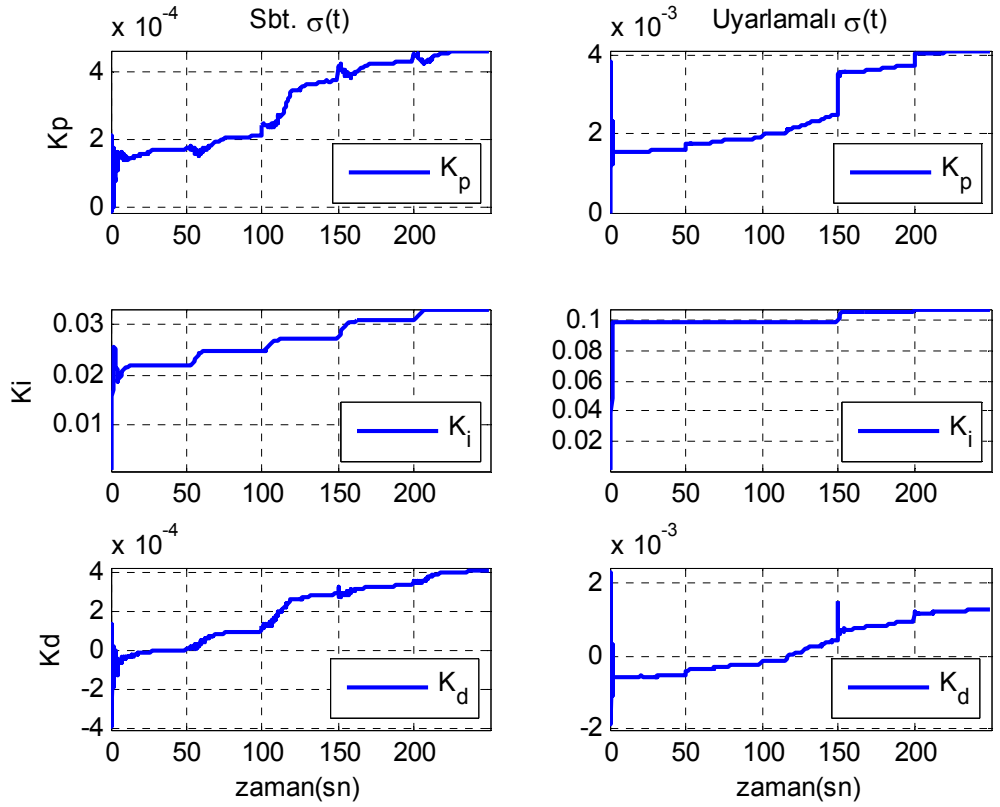
Kontrolörlerin performansını, yerleşme zamanı cinsinden karşılaştırmak için referans olarak 0.4 genliğe sahip bir basamak fonksiyonu kullanılmıştır. Kontrolörlerin bozucu bastırma yeteneklerini kıyaslamak için, 0.1 genliğe sahip bir bozucu işaret 60. saniyede sistemin çıkışına eklenmiştir.



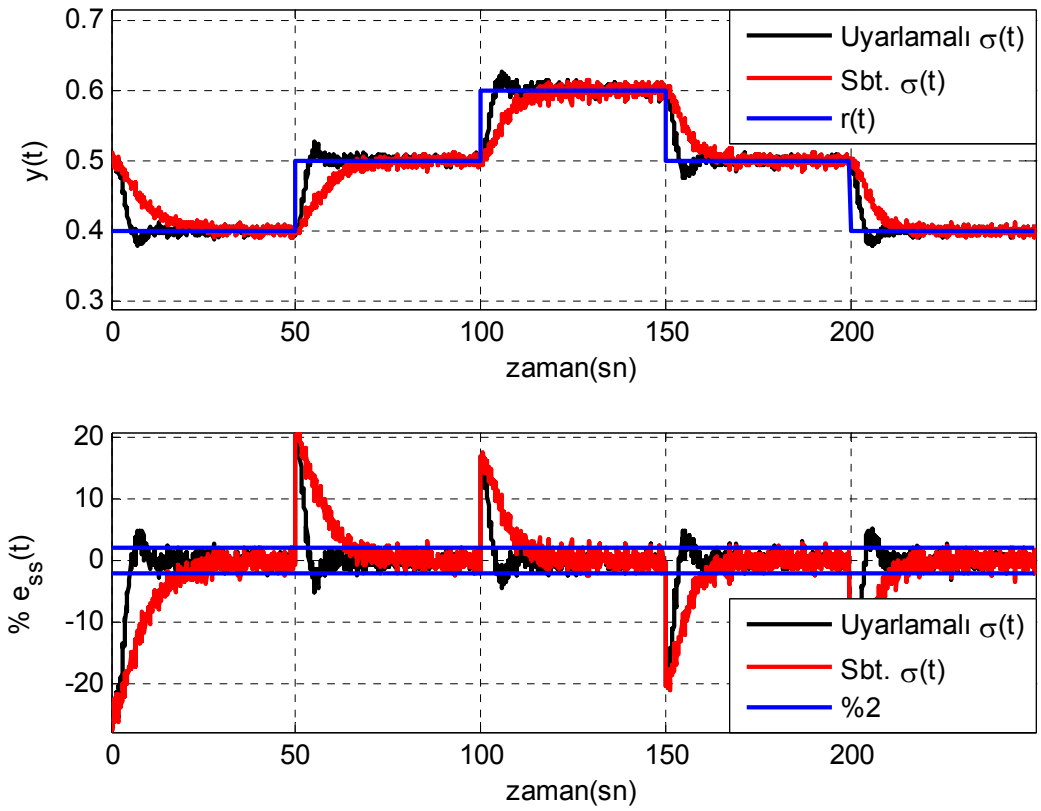
Şekil 4.21 : Uyarlamalı ve sabit çekirdek parametresinin sisteme etkisi.



Şekil 4.22 : Çekirdeğin band genişiliği ve öğrenme oranı.



Şekil 4.23 : PID kontrolör parametreleri.

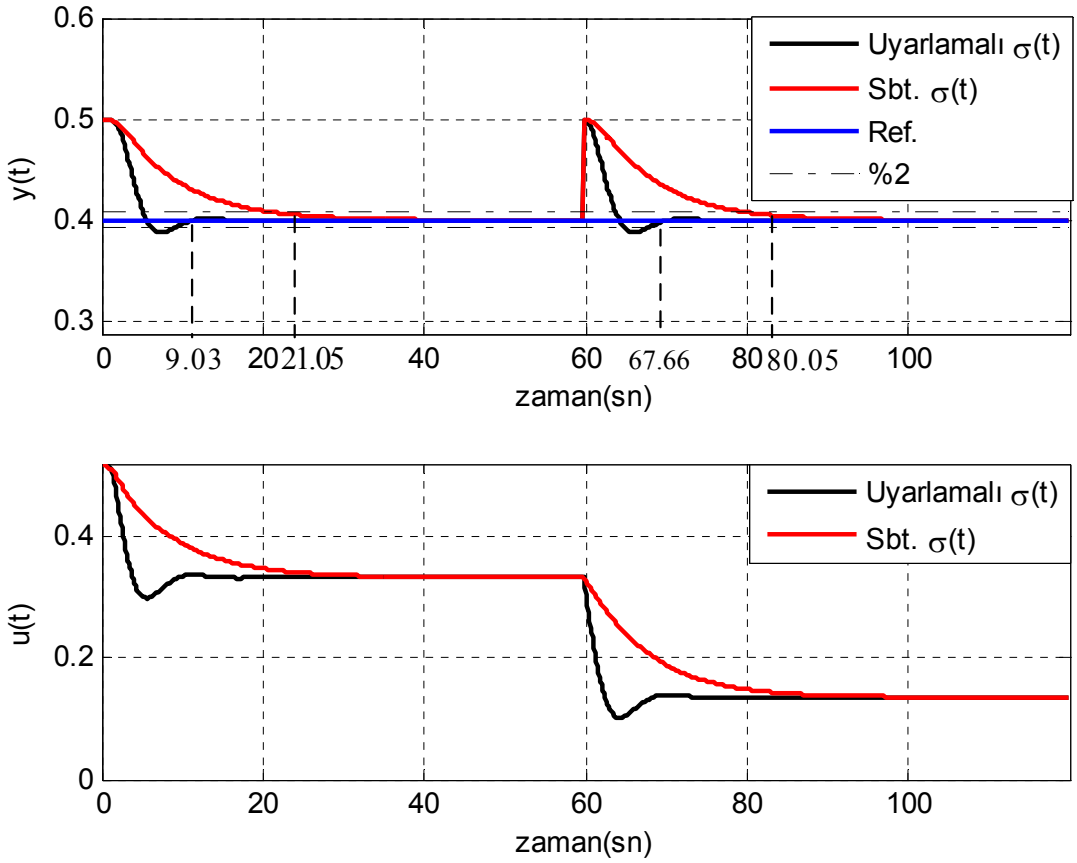


Şekil 4.24 : Sürekli hal hatası.

Kontrolörlerin yerleşme zamanı ve bozucu bastırma yetenekleri şekil 4.25'de verildiği gibidir. Çizelge 4.2'de sabit ve uyarlamalı çekirdek parametresi kullanılan çevrimiçi DVR için modelleme ve izleme performansları kıyaslanmıştır. Aşağıdaki fonksiyon performanstaki iyileşmeyi belirlemek için kullanılmıştır.

$$\% J_{imp} = 100 \sum_{n=1}^{N} \frac{|x_{sabit}| - |x_{uyarlamalı}|}{|x_{sabit}|} \qquad \textbf{(4.7)}$$

Burada x sabit veya uyarlamalı çekirdekli model tabanlı kontrolörün geçici zaman özellikleridir (örn: Yerleşme zamanı, bozucu bastırma zamanı). Çizelge 4.2, çekirdek parametresine katılan uyarlama yeteneğinin, gürültülü ve gürültüsüz koşullarda modelin performansını ve buna bağlı olarak kontrolörlerin performansını iyileştirdiğini göstermektedir. Çizelge 4.1'de, çizelge 4.2'deki sembollerin açıklamaları verilmiştir.



Şekil 4.25 : Oturma ve bozucu bastırma süreleri.

Çizelge 4.1 : Semboller.

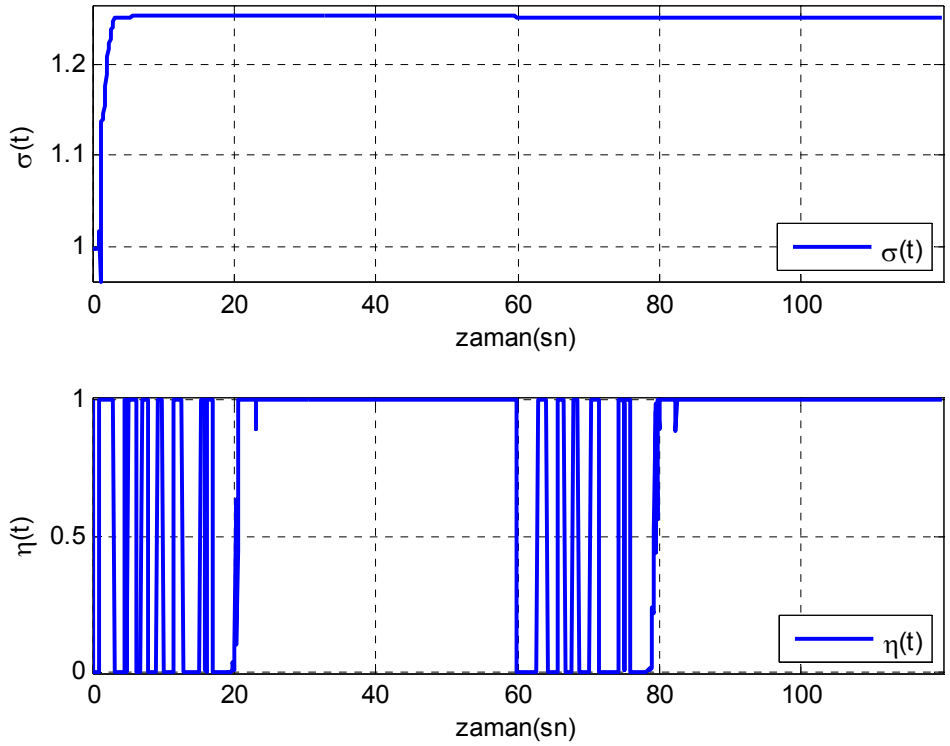
Sembol	Açıklama
$e_{tr,ns}$	Gürültüsüz koşullarda Ortalama Mutlak İzleme Hatası
$e_{\mathrm{mod},ns}$	Gürültüsüz koşullarda Ortalama Mutlak Model Hatası
$e_{tr,ny}$	Gürültülü koşullarda Ortalama Mutlak İzleme Hatası
$e_{\mathrm{mod},ny}$	Gürültülü koşullarda Ortalama Mutlak Model Hatası
t_s (sn)	%2 lik Oturma Zamanı
t_{dr} (sn)	Bozucu Bastırma Zamanı

Çizelge 4.2'nin 4. sütünundan görülebileceği gibi, uyarlamalı çekirdeğe sahip yapı ile kontrol edilen sistemin performansı sabit çekirdekli yapı ile elde edilen performansa göre daha iyidir. Bozucu işaretine karşı kontrolörün uyarlanması şekil 4.25'de verilmiştir. Çekirdeğin değişimi ve öğrenme oranı şekil 4.26'daki gibidir. Şekil 28 ve şekil 29'da modelin cevabı verilmiştir.

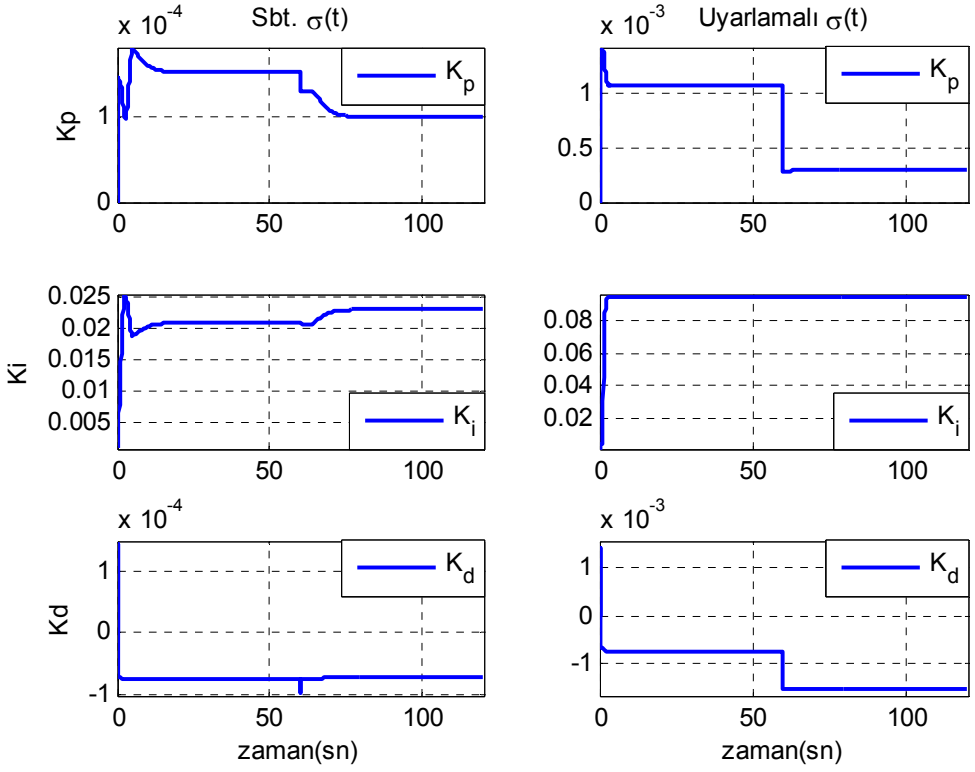
Çizelge 4.2 : Model ve kontrolör performansı.

Sembol	Sabit $\sigma(t)$	Uyarlamalı $\sigma(t)$	Performans (%)
$e_{tr,ns}$	0.0153	0.0062	59.478
$e_{\mathrm{mod},ns}$	0.0013	0.00069470	46.5615
$e_{tr,ny}$	0.0167	0.0092	45.2408
$e_{\mathrm{mod},ny}$	0.0044	0.0040	9.4341
t_s (sn)	21.5 sn	9.03 sn	61.796
t_{dr} (sn)	20.05 sn	7.66 sn	49.715

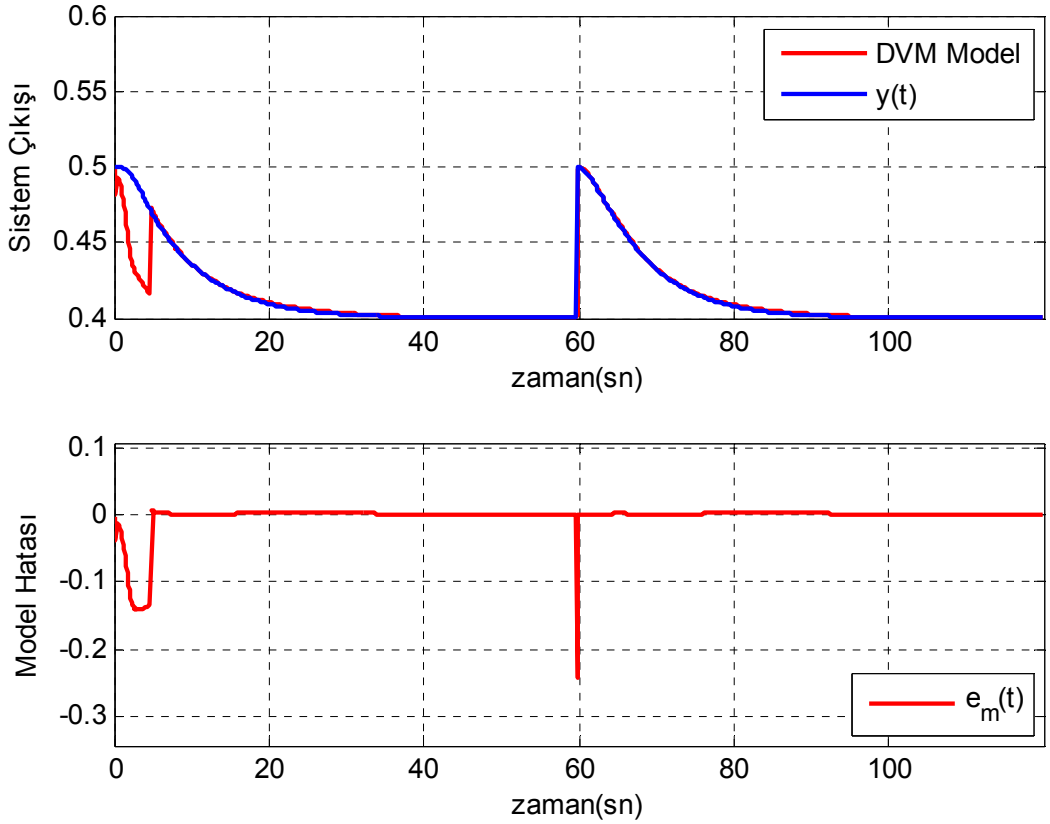
Uyarlamalı PID kontrolörlerin dayanıklılıklarını test etmek için, sistem parametreleri zamanla değişen fonksiyonlar olarak seçilmiş, uyarlamalı çekirdek parametresi kullanılarak elde edilen yapıyla kontrol edilmesi durumunda sistem cevabının değişimi incelenmiştir.



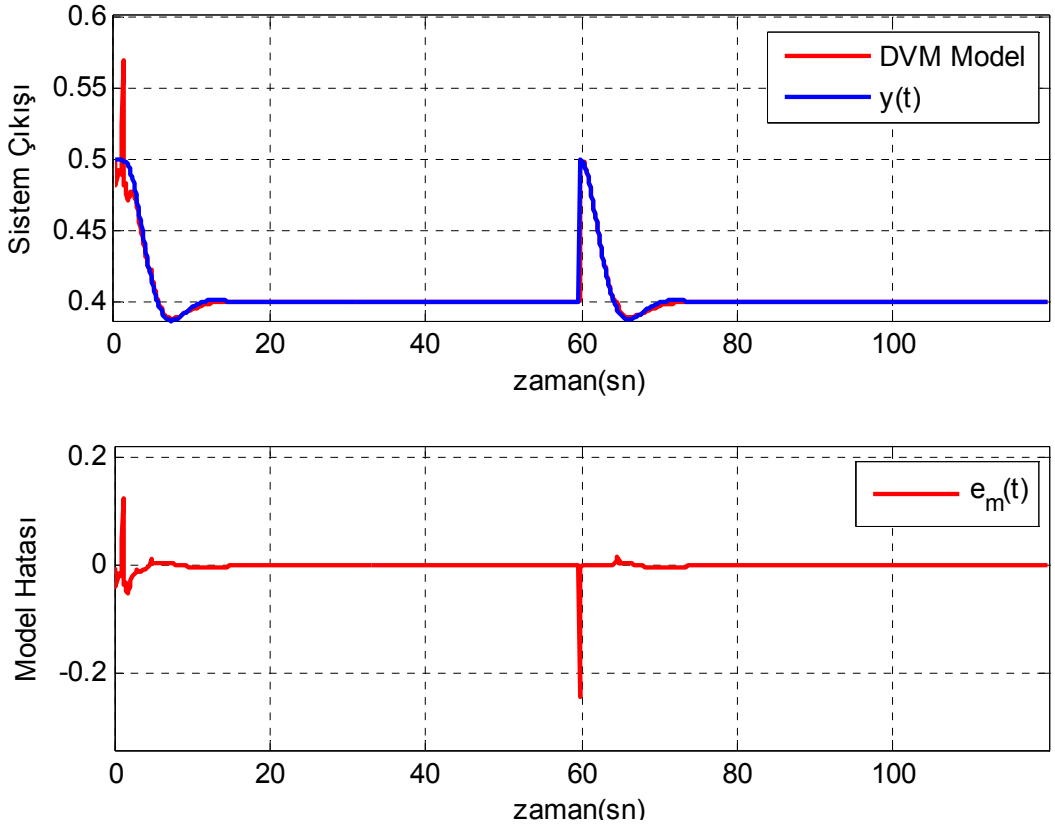
Şekil 4.26 : Çekirdek parametresi ve öğrenme oranı.



Şekil 4.27 : Uyarlamalı PID kontrolör parametreleri.



Şekil 4.28 : Uyarlamasız çekirdeğe sahip modelin çıktısı.



Şekil 4.29 : Uyarlamalı çekirdeğe sahip modelin çıktısı.

İncelenen ilk örnekte sistem parametreleri aşağıdaki gibi değiştirilmiştir.

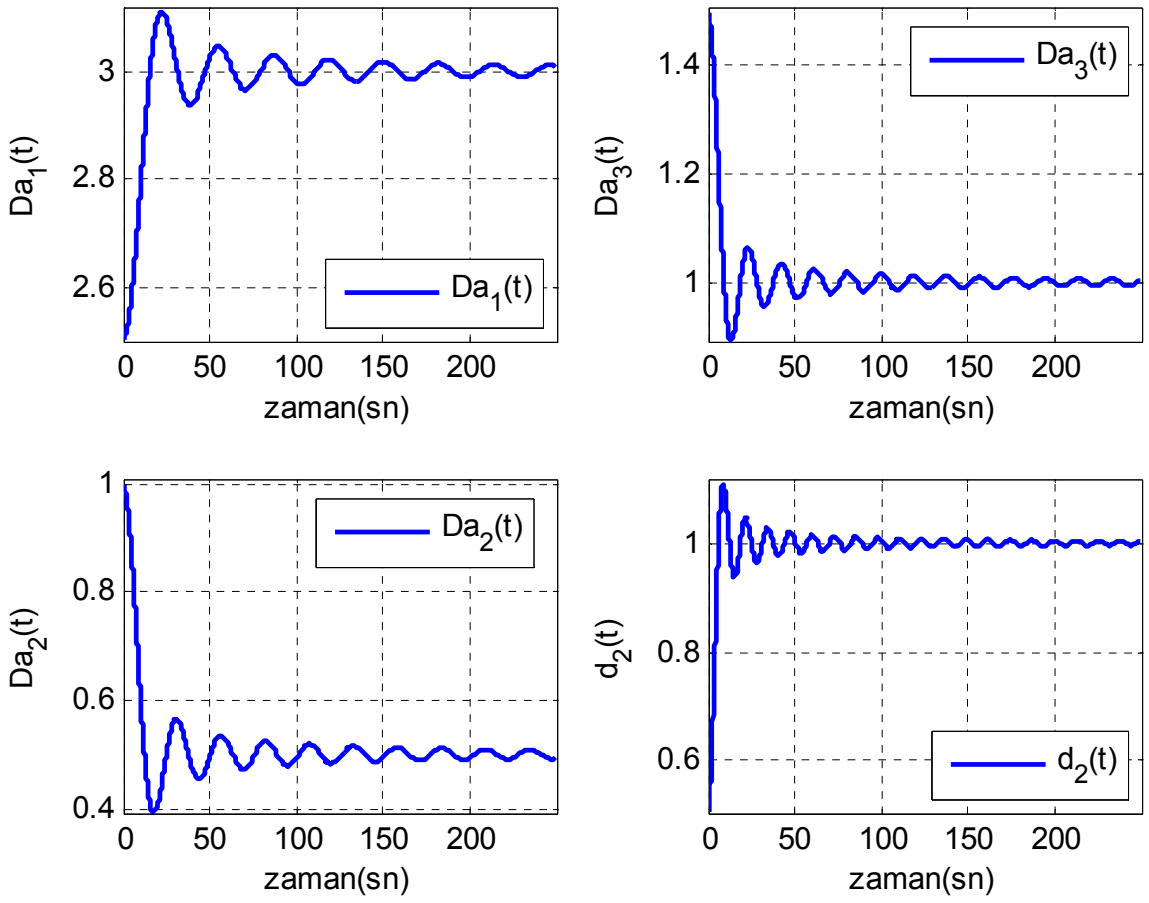
$$Da_1(t) = 3 - 0.5\frac{\sin(\lambda_1(t))}{\lambda_1(t)} \quad , \quad Da_2(t) = 0.5 + 0.5\frac{\sin(\lambda_2(t))}{\lambda_2(t)}$$

$$Da_3(t) = 1 + 0.5\frac{\sin(\lambda_3(t))}{\lambda_3(t)} \quad , \quad d_2(t) = 1 - 0.5\frac{\sin(\beta(t))}{\beta(t)}$$

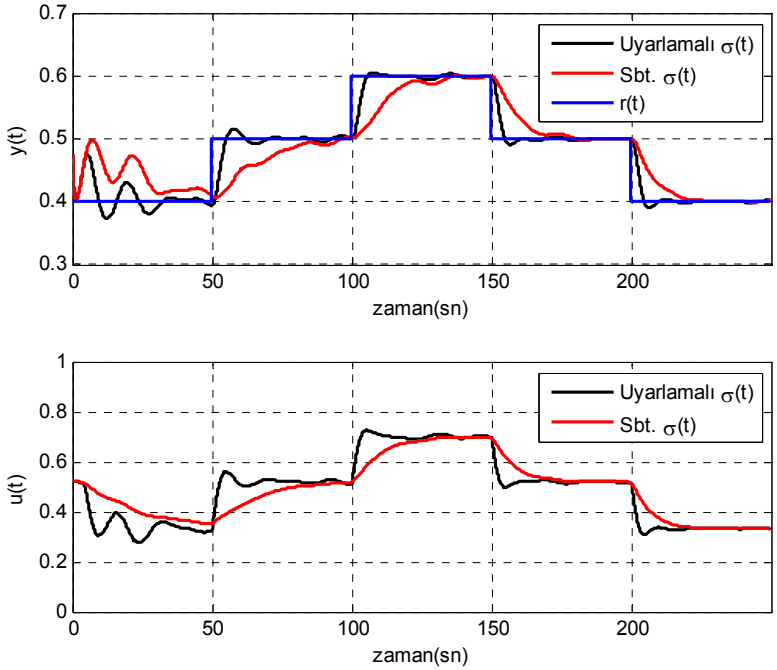
$$\lambda_1(t) = \frac{2\pi t}{100}, \ \lambda_2(t) = \frac{2\pi t}{80}$$

$$\lambda_3(t) = \frac{2\pi t}{60}, \ \beta(t) = \frac{2\pi t}{40}$$

Sistem parametrelerinin zamanla değişimi şekil 4.30'da verilmiştir.

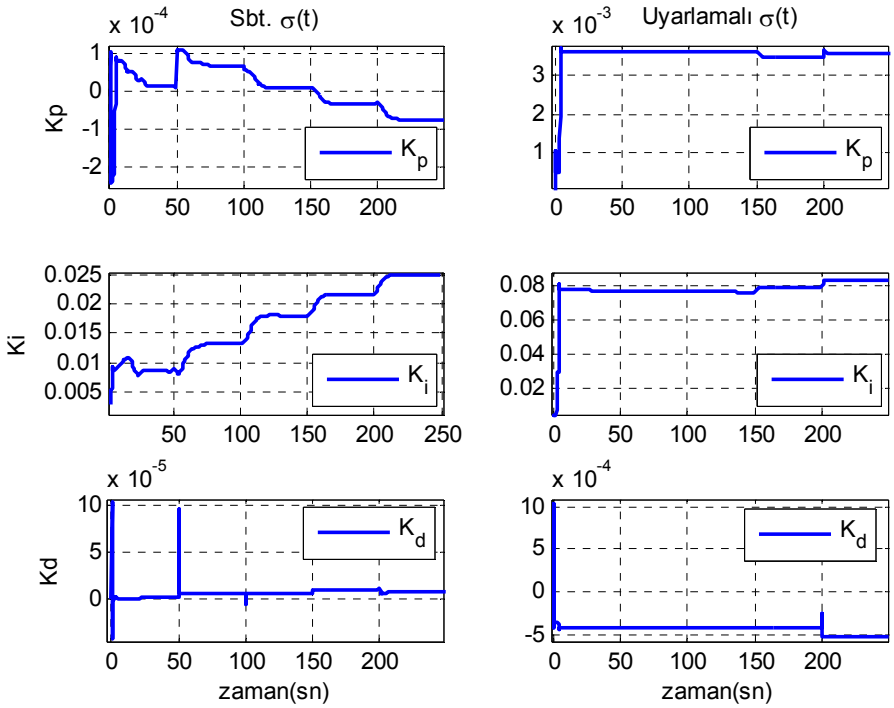


Şekil 4.30 : Sistemin değişen parametreleri.

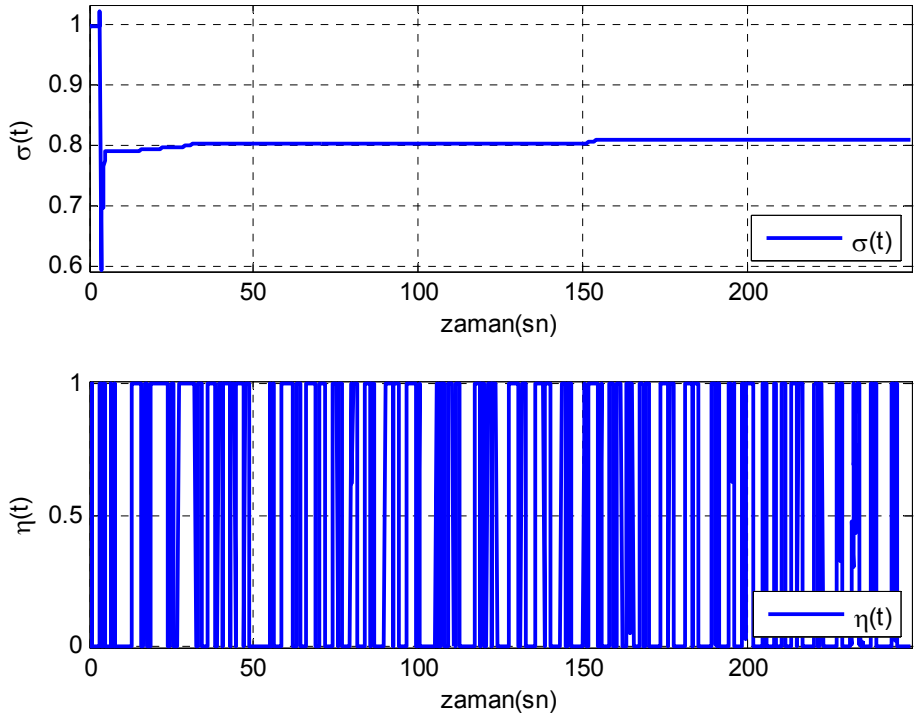


Şekil 4.31 : Kontrol işareti ve sistem cevapları.

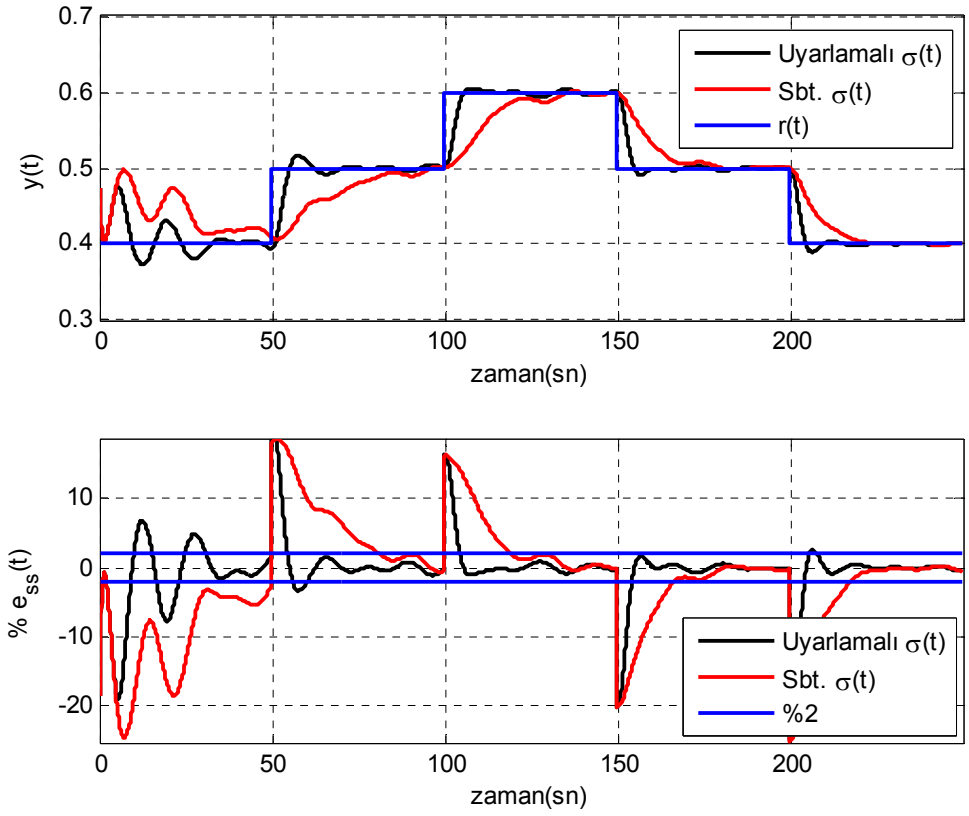
Şekil 4.31'de kontrolörlerin ürettiği kontrol işaretleri ve sistem çıkışları verilmiştir. Uyarlamalı ve sabit çekirdek parametresine sahip ÇEK-DVM tabanlı uyarlamalı PID kontrolörlerin performansı şekilde verilmiştir. Uyarlamalı çekirdek, sistem üzerindeki belirsizliklere karşı çok daha iyi kontrol performansı elde edilmesini sağlamaktadır.



Şekil 4.32 : Uyarlamalı PID kontrolör parametreleri.



Şekil 4.33 : Çekirdek parametresi ve öğrenme oranı.



Şekil 4.34 : Sürekli hal hatası.

Çizelge 4.3 : Dayanıklılık(% Performans).

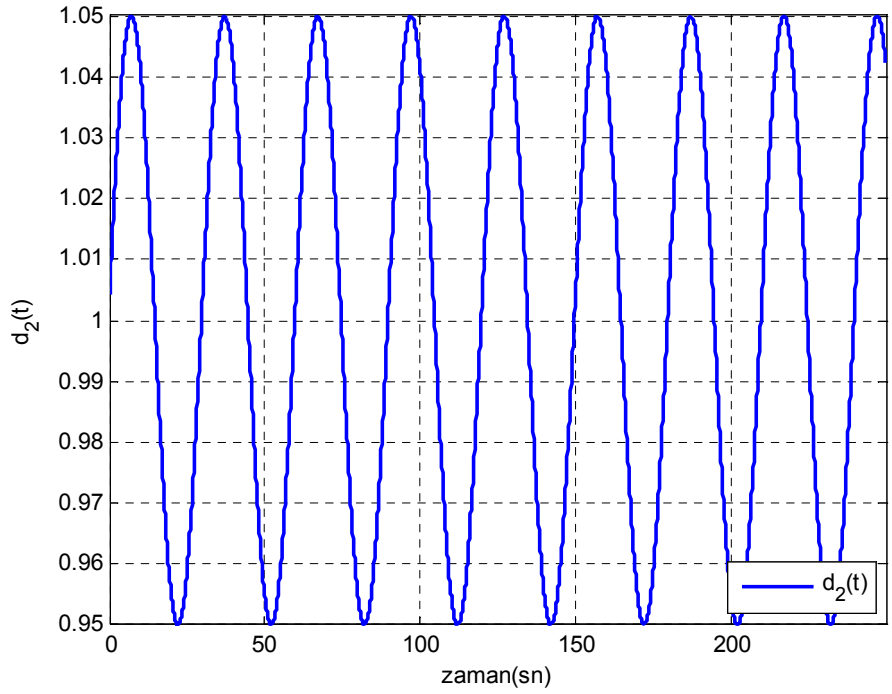
Sembol	Sabit $\sigma(t)$	Uyarlamalı $\sigma(t)$	Performans (%)
e_{tr}	0.0257	0.0095	63.2817
e_{mod}	0.0012	0.0012	-1.3620

Çizelge 4.3'de parameter değişikliğine karşı uyarlamalı çekirdeğin eğitim ve izleme hatası açısından iyileştirilmesi verilmiştir. e_{tr} izleme hatasını ve e_{mod} modelleme hatasını göstermektedir. Model performansında çok az değişim görülürken kontrol performansı % 64 oranında iyileştirilmiştir.

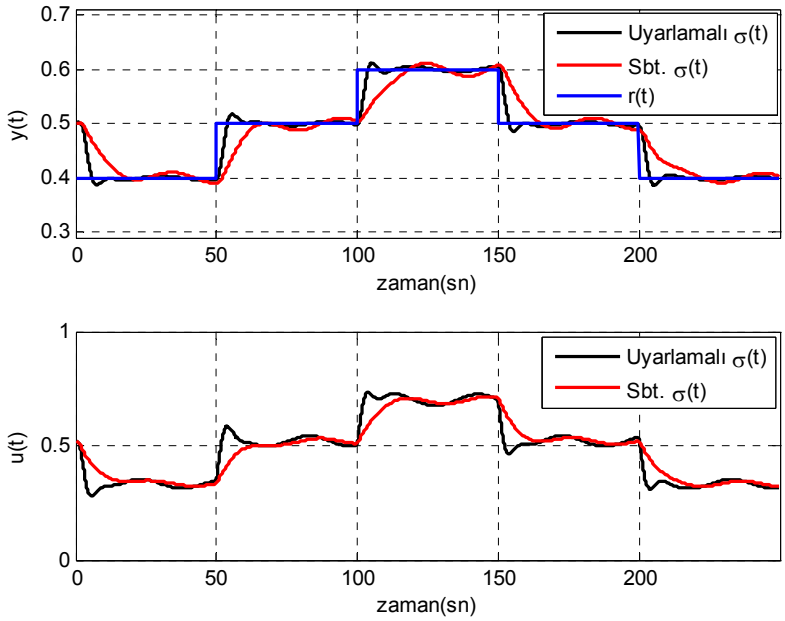
Sistem parametrelerinden sadece $d_2(t)$ parametresi periyodik olarak değişen bir değişken olarak alınırsa, sistem parametreleri aşağıdaki gibi ifade edilir.

$$Da_1(t) = 3,\ Da_2(t) = 0.5\ ,\ Da_3(t) = 1$$
$$d_2(t) = 1 + 0.05\ \sin(\beta(t))$$
$$\beta(t) = \frac{2\pi t}{30}$$

Sistem parametresinin zamanla değişimi şekil 4.35'de verilmiştir.

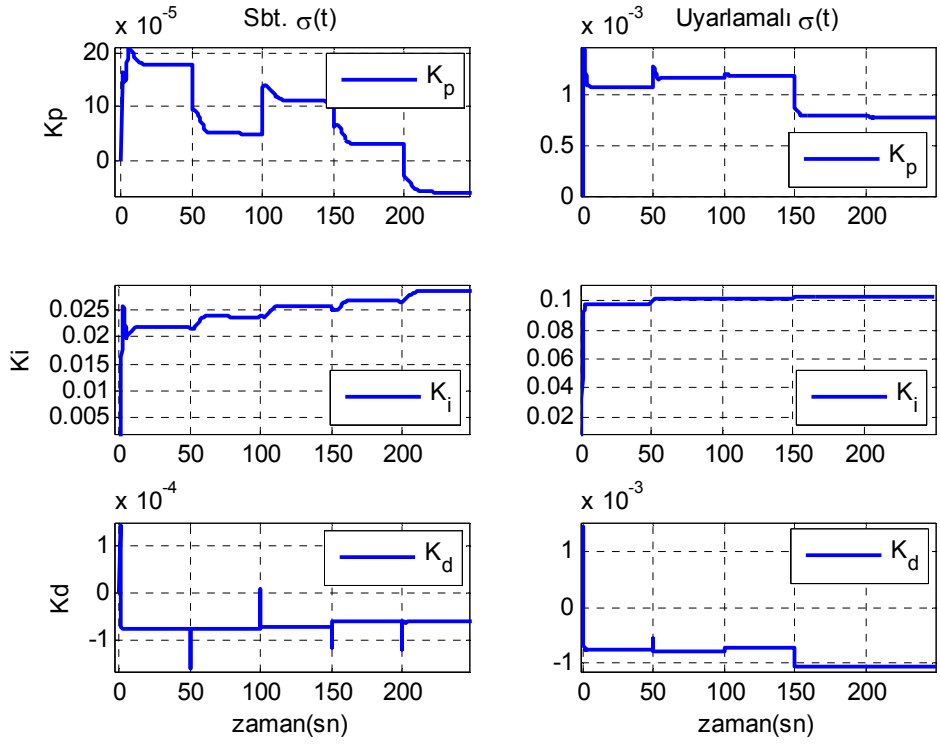


Şekil 4.35 : Sistemin zamanla değişen parametresi.

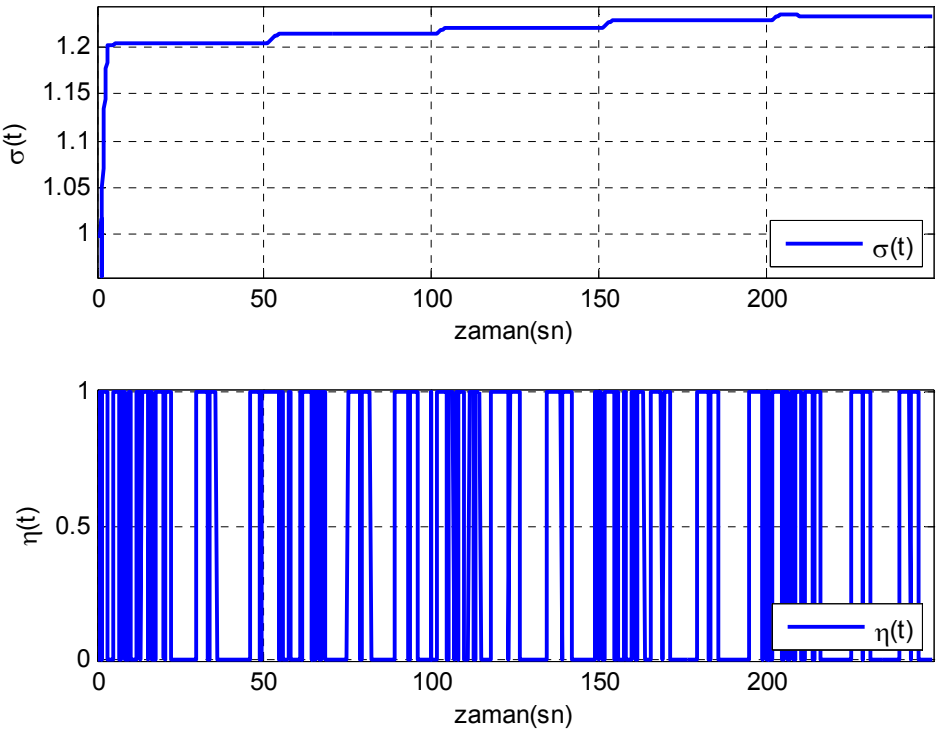


Şekil 4.36 : Kontrol işareti ve sistem cevapları.

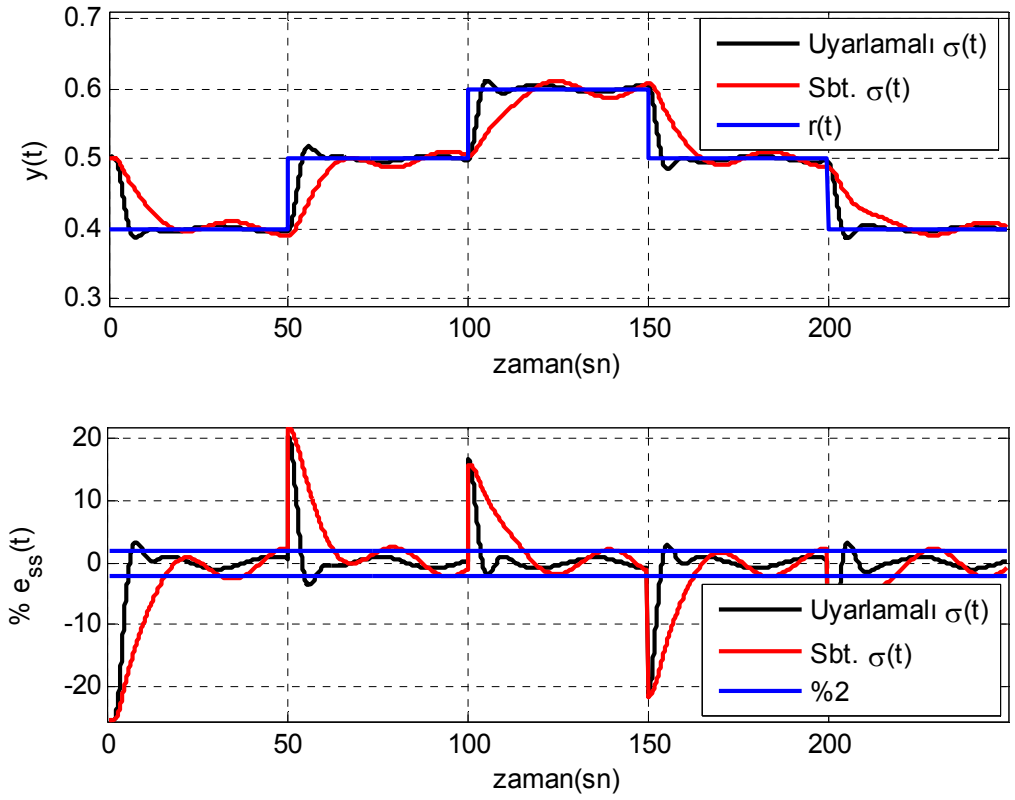
Şekil 4.36'de bu durum için kontrolörlerin ürettiği kontrol işaretleri ve sistem çıkışları verilmiştir. Uyarlamalı çekirdek, sistem üzerindeki belirsizliklere karşı çok daha iyi kontrol performansı elde edilmesini sağlamaktadır.



Şekil 4.37 : Uyarlamalı PID kontrolör parametreleri.



Şekil 4.38 : Çekirdek parametresi ve öğrenme oranı.



Şekil 4.39 : Sürekli hal hatası.

Kontrolörleri dayanıklılık açısından kıyaslamak için çizelge 4.4 oluşturulmuştur. Çizelge 4.4'den görüleceği üzere model performansı % 39 iyileşirken, kontrol performansı %57 iyileşmiştir.

Çizelge 4.4 : Dayanıklılık(% Performans)

Sembol	Sabit $\sigma(t)$	Uyarlamalı $\sigma(t)$	Performans (%)
e_{tr}	0.0198	0.0085	57.3519
e_{mod}	0.002	0.0012	38.7364

5. SONUÇLAR VE GELECEK ÇALIŞMALAR

Bu çalışmada DVM'nin sınıflandırma ve regresyon problemlerinde kullanımı hakkında geniş bir bilgi verildikten sonra öncelikli olarak sistem tanıma problemi üzerinde başarımı ele alınmıştır. DVM'yi sistem tanıma araçı olarak kullanarak 4'lü tank sisteminin dinamikleri kestirilmiştir. Optimal çekirdek parametresi ızgaralama yöntemi kullanılarak belirlenmiştir. ε-DVR tabanlı uyarlamalı PID kontrolör kullanılarak kararsız ve doğrusal olmayan manyetik askı sisteminin kontrolü gerçeklenmiştir. ε-DVR karesel problem çözücüden dolayı global çözüme ulaşmak için oldukça işlemsel yük içermektedir. Kontrol sürecinde sistemden kaynaklanacak belirsizliklerle baş etmek için ÇEK-DVR kullanılarak çevrimdışı DVM'nin işlemsel yükü elimine edilmiştir. Bu çalışmada asıl olarak ÇEK-DVR'nin modelleme performansını geliştirmek için çekirdek parametresinin çevrim içi uyarlanması önerilmiştir. Önerilen metodun tanılama ve kontrol üzerindeki etkileri incelenmiştir. Yöntemin başarımı, sürekli karıştırma tank reaktörü (CSTR) sisteminde test edilmiştir. Bu yöntemin, gürültü ve bozucu etkisi altında uyarlamalı PID kontrolörler üzerindeki etkisi incelenmiştir. Yöntemin sistemin cevabını hızlandırdığını, bozucu ve gürültülü ortamda başarılı bir performans sergilediği görülmüştür. Kontrolörlerin dayanıklılığı test edilmiş ve yöntemin dayanıklılık açsından kontrolörün performansını iyileştirdiği gözlemlenmiştir. Simülasyon sonuçları çekirdek parametresine katılan uyarlama yeteneğinin modelin performansını ve dolaylı olarak kontrolörün performansını iyileştirdiğini göstermektedir. Çoklu çekirdek yapıları ve türevsel tabanlı yeni uyarlama teknikleri kullanılarak regresyon performansı çevrimiçi süreçte artırılabilir.

KAYNAKLAR

[1] **Khuu, H.V., Lee, H.K., ve Tsai, J.L.,**. Machine Learning with Neural Networks and Support Vector Machines

[2] **Boswell, D.** (2002). Introduction to Support Vector Machines

[3] **Guyon, I., Weston J, Barnhill S., Vapnik V.** (2002). Gene Selection for Cancer Classification Using Support Vector Machines, Machine Learning Vol: 46 Iss: 1-3 s: 389-422

[4] **Guo, G.D., Li, S.Z., Chan K.L.,** (2001). Support Vector Machines for face recognition , Image and Vision Computing, Vol: 19 Iss: 9-10 s: 631-638

[5] **Mukkalama, S., Sung, A.H.** (2003). Detecting denial of service attacks using Support Vector Machines, 12th IEEE International Conference on Fuzzy Systems ,St Louis,MO,May 25-28,2003

[6] **Xia, L., Xu, R., Yan, B.** (2007). LTCC Interconnect Modeling by Support Vector Regression, Progress In Electromagnetics Research PIER 69, 67–75, 2007

[7] **Abdessemed, F., Bazi, Y.,**. Kernel Regression for Robot Manipulator Control

[8] **Na ,M.G., Upadhyaya B.,R.,** (2006). Model Predictive control of an SP-100 space reactor using support vector regression and genetic optimization, IEEE Transactions on Nuclear Science Vol:53 s: 2318-2327 Part: Part 2

[9] **Shang, W., Zhao, S., Shen,Y.**(2008). Adaptive PID Controller Based on Online LSSVM Identification, 2008 IEEE/ASME International Conference on Advanced Intelligent Mechatronics, vols 1-3 s: 694-698 , 2008

[10] **İplikçi S.** (2010). A comparative study on a novel model-based PID tuning and control mechanism for nonlinear systems, International Journal of Robust and Nonlinear Control, Vol: 20 s: 1483- 1501

[11] **Sun, W. S., Lee, J., Lee, In-Beum** (2009). Process Identification and PID Control, IEEE Press, Singapore, 2009

[12] **Choi, Y., Chung,W.K.,**(2004). PID Trajectory Tracking Control for Mechanical Systems , Lecture Notes in Control and Information Sciences , Springer Verlag, Berling Heidelberg (2004)

[13] **Bobál, V., Böhm, J., Fessl, J., Macháček, J.** (2005). Digital Self-tuning controller: algorithms, implementation and applications" Advanced Textbooks in Control and Signal Processing, Springer-Verlag London Limited 2005

[14] **David, Sanchez A. V.** (2003). Advanced support vector machines and kernel methods, Neurocomputing, Vol: 55, s:5-20

[15] **Smola, A.J., Scholkopf, B.**(2004). A tutorial on support vector regression, Statistics and Computing Vol: 14 s: 199-222

[16] **İplikçi, S.,** (2009). Controlling the Experimental Three –Tank System via Support Vector Machines , Lecture Notes in Computer Science , Springer Berlin / Heidelberg , Vol: 5495/2009,Adaptive and Natural Computing Algorithms , s: 391 – 400

[17] **Zhao, J., Li, P., Wang, X.S.** (2009). Intelligent PID Controller Design with Adaptive Criterion Adjustment via Least Square Support Vector Machines, 21st Chinese Control and Decision Conference, 2009

[18] **Takao, K. Yamamoto, T., Hinamoto, T.,** (2006). A design of PID controllers with a switching structure by a support vector machine, International Joint Conference on Neural Network (IJNN), proceedings, vol. 1-10, 2006, s: 4684-4689.

[19]**Campbell,W.M., Sturim,D.E. ,Reynolds, D.A.**(2006). Support vector machines using GMM supervectors for speaker verification , IEEE Signal Processing Letters, Vol. 13, No. 5, May 2006

[20] **Gunn, S.** (1998). Support Vector Machines for Classification and Regression, ISIS Technical Report, 14 Mayıs 1998

[21] **Cristianini, N.,Campbell, C. ,Shawe-Taylor, J.** (1999). Dynamically Adapting Kernels in Support Vector Machines, Advances in Neural Information Processing Systems Vol:11, s: 204-210

[22] **Wu, K.-P., Wang, S.-D.,** (2009). Choosing the kernel parameters for support vector machines by the inter-cluster distance in the feature space, Pattern Recognition vol: 42 , s:710-717

[23] **Han, F., Wang, Z., Lei, M. and Zhou, Z.** (2008). An Iterative Modified Kernel for Support Vector Regression, IEEE Conference on Cybernetics and Intelligent Systems, vol. 1-2, s. 1116-1121

[24] **Xu, Z., Dai,M., Meng,D.,** (2009). Fast and efficient strategies for model selection of gaussian support vector machines , IEEE Transaction on Systems Man and Cybernetics Part B-Cybernetics , Volume:39 , Issue:5 , s: 1297-1307

[25] **Wang,T., Tian,S., Huang,H., Deng,D.,**(2009). Learning by local kernel polarization , Neurocomputing Volume: 72 Issue: 13-15 s: 3077-3084

[26] **Xu, J.F., Liu, L.,** (2009). Gradient-based Optimization of Kernel Polarization for RBF Kernels, International Conference on Computational Intelligence and Natural Computing, Vol:1 , s: 85-87, 2009

[27] **Keerthi, S.S., Sindhwani, V., Chapelle, O.** (2006). An Efficient Method for Gradient - Based Adaptation of Hyperparameters in SVM Models, Technical Report

[28] **Rubio, G., Pomares, H., ve diğerleri** (2009). Efficient Optimization of the Parameters of LS-SVM for Regression versus Cross- Validation Error, in: Artificial Neural Networks-ICANN 2009, Part II, Lecture Notes in Computer Science, vol. 5769, 2009, s. 406–415

[29] **Bo, L., Wang, L., and Jiao, L.,** (2005). Multiple Parameter Selection for LS-SVM Using Smooth Leave-One-Out Error, in: Advances in Neural Network-ISNN 2005, Proceedings, Lecture Notes in Computer Science, vol. 3496, s. 851-856

[30] **Boughorbe, S., Tarel, J.P. and Boujemaa, N.,** (2005). The LCCP for Optimizing Kernel Parameters for SVM, Artificial Neural Networks: Formal Models and Their Applications-ICANN 2005,PT 2, Proceedings, Lecture Notes in Computer Science, vol. 3697, 2005, s. 589-594

[31] **Diosan, L., Rogozan, A., and Pecuchet, J.-P.,** (2008). Evolutionary Optimisation of Kernel and Hyper-Parameters for SVM , Modeling Computation and Optimization in Informations Systems and Management Sciences, Proceedings, vol. 14, 2008, s. 107–116

[32] **Huang, C.-L., Dun, J.-F.,** (2008). A distributed PSO–SVM hybrid system with feature selection and parameter optimization, Applied Soft Computing vol:8 , s:1381-1391

[33] **Linn, K.C. Chien, H.Y.,**(2009). CSO-Based feature selection and parameter optimization for support vector machines , Joint Conference on Pervasive Computing, s:783-788 , 2009 ,TAIWAN

[34] **Guo, X.C., Yang, J.H., Wu, C.G., Wang, C.Y., Liang, Y.C.,** (2008). A novel LS-SVMs hyper-parameter selection based on particle swarm optimization, Neurocomputing, vol: 71, s: 3211-3215

[35] **Lin, S.-W., Lee, Z.-J., Chen, S.-C., Tseng, T.-Y.,** (2008). Parameter determination of support vector machine and feature selection using simulated annealing approach, Applied Soft Computing , Vol:8, s:1505-1512

[36] **Yang, C., Yang, H., Deng, F.,** (2008). Quantum-Inspired Immune Evolutionary Algorithm based Parameter Optimization for Mixtures of Kernels and Its Application to Supervised Anomaly IDSs, in: Proceedings of the 7th World Congress on Intelligent Control and Automation, vols. 1-23, s: 4568-4573

[37] **Aydin, İ., Karakose, M., Akin, E.,** (2011). A multi-objective artificial immune algorithm for parameter optimization in support vector machine, Applied Soft Computing vol: 11, s: 120-129.

[38] **Li, S., Tan, M.,** (2010). Tuning SVM parameters by using a hybrid CLPSO–BFGS algorithm, Neurocomputing , vol:73, s: 2089-2096

[39] **Moore, G., Bergeron, C., Bennett, K. P.,** (2011). Model selection for primal SVM, Machine Learning vol: 85, issue: 1-2, s. 175-208

[40] **Niu, D.X., Guo, Y.C.,** An Improved PSO for Parameter Determination and Feature Sellection of SVR and its Application in STLF, Journal of Mult.-Valued Logic and Soft Computing, s: 1-18

[41] **Guo, Y.C.,** (2009). An Integrated PSO for Parameter Determination and feature selection of SVR and its application in STLF, in: Proceedings of 2009 International Conference on Machine Learning and Cybernetics, vols. 1-6, s. 359-364

[42] **Momma, M., Bennett, K.P.,** (2002). A pattern search method for model selection of support vector regression, Proceedings of the second SIAM International Conference on Data Mining, 2002, s.261-274

[43] **Frohlich, H., Zell, A.,** (2005). Efficient Parameter Selection for Support Vector Machines in Classification and Regression via Model-Based Global Optimization, Proceedings of International Joint Conference on Neural Networks(IJCNN), vols. 1-5, 2005, s. 1431-1436

[44] **Hou, L.K., Yang, Q.X.,**(2009). Study on parameters selection of LSSVR based on Grid-Diamond search method , International Conference on Machine Learning and Cybernetics, Vols 1-6, s:1219-1224, 2009 Baoding PEOPLES R CHINA

[45] **Kabaoğlu, R., Eksin, İ.**(2010). Destek vektörü makineleri tabanlı hata bulma, tanıma ve hata toleranslı kontrol yöntemleri, Doktora Tezi, İstanbul Teknik Üniversitesi, İstanbul,Türkiye

[46] **Suja Mani Malar R., Thyagarajan, T.,**(2008). Design of Decentralized Fuzzy Controllers for Quadruple Tank Process" IJCSNS International Journal of Computer Science and Network Security, VOL.8 No.11, November 2008

[47] **Johansson, K.,H.,** (2000). The Quadruple -Tank Process: "A Multivariable Laboratory Process with an Adjustable Zero " IEEE Transactions on Control System Technology ,Vol 8 , No 3,May 2000

[48] **Dormido, S., Esquembre, F.,**(2003). The Quadruple-Tank Processes: An Interactive Tool for Control Education " Proceedings of the European Control , 2003

[49] **Vapnik, V.N.,**(1995). The Nature of Statistical Learning Theory , Springer – Verlag ,New York, 1995

[50] **Ucak, K., Oke, G.** (2011). Adaptive PID Controller Based on Online LSSVR with Kernel Tuning , International Symposium on Innovations in Intelligent Systems and Applications, ,Istanbul Turkey, (2011)

[51] **Farag, A., Mohamed, R. M.,** (2004). Regression using support vector machines:basic foundations" Technical Report December 2004

[52] **Suykens, J. A. K.** (2001). Nonlinear Modeling and Support Vector Machines ' IEEE Instrumentation and Measurement Technology Conference , Budapest, Hungary, May 2001

[53] **Wu, W., Chou, Y. S.,** (1999). Adaptive feedforward and feedback control of non-linear time-varying uncertain systems , International Journal of Control Volume:72 , Issue:12 s. 1127-1138

[54] **Ungar, L.H.,**(1990). A bioreactor benchmark for adaptive-network based process control" Neural Network for Control, MIT Press Cambridge, MA,USA, 1990

[55] **Luenberger, D.G., Ye, Y.,**(2008). Linear and Nonlinear Programming Third Edition, Springer Science + Business Media, LLC, 2008

ÖZGEÇMİŞ



Ad Soyad: Kemal UÇAK

Doğum Yeri ve Tarihi: Ağlasun/BURDUR 26.10.1983

Adres: İ.T.Ü., Genç Akademisyenler Lojmanları D2 Blok Daire:53 Ayazağa Kampüsü, Maslak/İSTANBUL

E-Posta: kemal.ucak@itu.edu.tr

Lisans: Pamukkale Üniversitesi Elektrik-Elektronik Mühendisliği (Bölüm 2. lik derecesi ile)

Mesleki Deneyim ve Ödüller: Araştırma Görevlisi Muğla Üniversitesi (25.02.2009-28.07.2009)

Araştırma Görevlisi İstanbul Teknik Üniversitesi (28.07.2009- halen)

Yayın ve Patent Listesi:

TEZDEN TÜRETİLEN YAYINLAR/SUNUMLAR

- **Ucak K.**., Oke G., 2011: "An Improved Adaptive PID Controller Based on Online LSSVR with Multi RBF Kernel Tuning", ICAIS 2011, International Conference on Adaptive and Intelligent Systems, Klagenfurt, Austria, 6-8 September, 2011
- Sariyildiz E., **Ucak K**. , Oke G., Temeltas H., "A Trajectory Tracking Application of Planar Robot Arm via Support Vector Machines", ICAIS 2011, International Conference on Adaptive and Intelligent Systems, Klagenfurt, Austria, 6-8 September, 2011
- **Ucak K.**., Oke G., 2011: "Modeling of Quadruple Tank System Using Support Vector Regression", INISTA 2011, International Symposium on Innovations in Intelligent Systems and Applications, Istanbul, Turkey, 15-18 June, 2011
- **Ucak K.**., Oke G., 2011: "Adaptive PID Controller Based on Online LSSVR with Kernel Tuning", INISTA 2011, International Symposium on Innovations in Intelligent Systems and Applications, Istanbul, Turkey, 15-18 June, 2011.
- **Ucak K.**, Oke G., 2012: "Kernel Tuning in Online LS-SVR for A Model based Adaptive PID Controller " Neurocomputing (değerlendirme aşamasında)