



**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**DESTEK VEKTÖR MAKİNESİ İLE ROBOTİK KOLLARIN UYARLAMALI
MODEL ÖNGÖRÜLÜ KONTROLÜ**

DOKTORA TEZİ

Sanem KILIÇASLAN

Mekatronik Mühendisliği Anabilim Dalı

AĞUSTOS, 2022

**T.C.
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**DESTEK VEKTÖR MAKİNESİ İLE ROBOTİK KOLLARIN UYARLAMALI
MODEL ÖNGÖRÜLÜ KONTROLÜ**

DOKTORA TEZİ

**Sanem KILIÇASLAN
(162081601)**

Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Gökhan GELEN

AĞUSTOS, 2022

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 162081601 numaralı Doktora Öğrencisi Sanem KILIÇASLAN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “DESTEK VEKTÖR MAKİNESİ İLE ROBOTİK KOLLARIN UYARLAMALI MODEL ÖNGÖRÜLÜ KONTROLÜ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Gökhan GELEN**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Hakan GÜRKAN**
Bursa Teknik Üniversitesi

Doç. Dr. Emrah ZERDALI
Ege Üniversitesi

Dr. Öğr. Üyesi Ekrem DÜVEN
Bursa Teknik Üniversitesi

Dr. Öğr. Üyesi Mehmet Kürşat YALÇIN
Niğde Ömer Halisdemir Üniversitesi

Teslim Tarihi : 06 Eylül 2022
Savunma Tarihi : 17 Ağustos 2022



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı: Sanem Kılıçaslan

İmza:

[Handwritten signature of Sanem Kılıçaslan]

ÖNSÖZ

Her zaman bilgi ve fikirlerini aktaran değerli tez danışmanım Doç. Dr. Gökhan Gelen'e bu tez çalışmasının oluşturulmasındaki katkılarından ve sabırlarından dolayı teşekkürlerimi sunarım. Tez sürecimin başından sonuna kadar desteklerini eksik etmeyen aileme ve özellikle eşime ayrıca sonsuz teşekkür ederim.

Ağustos 2022

Sanem Kılıçaslan
(Kontrol Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vi
İÇİNDEKİLER	vii
KISALTMALAR	viii
ÇİZELGE LİSTESİ.....	ix
ŞEKİL LİSTESİ.....	x
ÖZET.....	xii
SUMMARY	xiii
1. GİRİŞ	1
2. DESTEK VEKTÖR MAKİNELERİ REGRESYONU	5
2.1. Destek Vektör Makinası Sınıflandırması	5
2.1.1 Doğrusal ayrılabilen veriler	5
2.1.1.1 Lagrange çarpanları yöntemi.....	7
2.1.2 Doğrusal olmayan sınıflandırma	9
2.1.3 Doğrusal olmayan destek vektör makineleri.....	11
2.2 Destek Vektör Regresyonu.....	13
2.2.1 ϵ -Duyarlı kayıp fonksiyonu.....	14
2.2.2 Doğrusal regresyon	14
2.2.3 Doğrusal olmayan regresyon	16
2.3 En Küçük Kareler Destek Vektör Makinesi.....	17
2.3.1 En küçük kareler destek vektör sınıflandırması	17
2.3.2 En küçük kareler destek vektör regresyonu	18
3. ROBOTİK KOLLAR İÇİN DESTEK VEKTÖR MAKİNASI DİNAMİK MODELİ.....	20
3.1 Eğitim Verisi Oluşturulması.....	20
3.2 Destek Vektör Makinası Modelinin Eğitilmesi.....	24
4. DVM TABANLI UYARLAMALI MODEL ÖNGÖRÜLÜ KONTROLÖR TASARIMI	28
5. DENETLEYİCİ PERFORMANSININ İNCELENMESİ	33
5.1 Yüksüz Durumda Yörünge Takip Kontrolü Performans Karşılaştırması	33
5.1.1 Basit yörünge uygulaması	33
5.1.2 Karmaşık yörünge uygulaması.....	36
5.2 Yüksüz Durumda Geçici Hal Performansı Karşılaştırması.....	40
5.3 Yük Altında Yörünge Takip Kontrolü Performans Karşılaştırması.....	42
5.3.1 Ani yük değişimi uygulaması	42
5.3.2 Anahtarlama yük değişimi uygulaması.....	45
5.3.3 Zamanla azalan yük uygulaması	48
5.4 Zamanla Azalan Yük Altında Geçici Hal Performansı Karşılaştırması.....	51
6. SONUÇ VE ÖNERİLER.....	54
KAYNAKLAR	56
ÖZGEÇMİŞ.....	60

KISALTMALAR

ANFIS	: Adaptive Network Based Fuzzy Inference System (Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi)
ANN	: Artificial Neural Network (Yapay Sinir Ağları)
DVM	: Destek Vektör Makineleri
DVR	: Destek Vektör Regresyonu
LS-SVM	: Least Square Support Vector Machine (En Küçük Kareler Destek Vektör Makinesi)
m	: Metre
N	: Newton
SVM	: Support Vector Machine (Destek Vektör Makinesi)
rad	: Radyan

ÇİZELGE LİSTESİ

Sayfa

Çizelge 3.1 : Denavit-Hartenberg parametreleri.....	23
Çizelge 5.1 : Yüksüz durum yörünge takip performansları karşılaştırması.	39
Çizelge 5.2 : Yüksüz durum PID performansları karşılaştırması.	40
Çizelge 5.3 : Yük altında yörünge takip performansları karşılaştırması.	50
Çizelge 5.4 : Yük altında PID performansları karşılaştırması.	51

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Optimal hiperdüzlem.....	5
Şekil 2.2 : Destek vektörleri.	6
Şekil 2.3 : Sınıflandırma verisi.	9
Şekil 2.4 : Doğrusal olmayan hiperdüzlem.	11
Şekil 2.5 : Kayıp fonksiyonları.....	13
Şekil 2.6 : Doğrusal destek vektörleri.....	15
Şekil 3.1 : uArm Swift Pro robot kol [34].	23
Şekil 3.2 : Robot çalışma uzayı – pozisyon (m).	24
Şekil 3.3 : DVR model test verisi- eklem açısı 1.....	25
Şekil 3.4 : DVR model test verisi- eklem açısı 2.....	25
Şekil 3.5 : DVR model test verisi- eklem açısı 3.....	26
Şekil 3.6 : DVR model test verisi- eklem açısı 4.....	26
Şekil 4.1 : Destek vektör regresyonu tabanlı model kestirimli uyarılama mekanizması [10].	28
Şekil 4.2 : En küçük kareler destek vektör makinası tabanlı uyarılmalı PID yapısı [23].	29
Şekil 4.3 : Uyarılama mekanizması parametre güncelleme algoritması.....	31
Şekil 4.4 : Yörünge takibi kontrol yapısı.....	32
Şekil 5.1 : Basit referans yörünge.....	34
Şekil 5.2 : Basit yörünge için x eksenli referans ve çıkış pozisyon değerleri.....	34
Şekil 5.3 : Basit yörünge için y eksenli referans ve çıkış pozisyon değerleri.....	35
Şekil 5.4 : Basit yörünge için z eksenli referans ve çıkış pozisyon değerleri.....	35
Şekil 5.5 : Basit yörünge için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.....	36
Şekil 5.6 : Karmaşık referans yörünge.	37
Şekil 5.7 : Karmaşık yörünge için x eksenli referans ve çıkış pozisyon değerleri.	37
Şekil 5.8 : Karmaşık yörünge için y eksenli referans ve çıkış pozisyon değerleri.	38
Şekil 5.9 : Karmaşık yörünge için z eksenli referans ve çıkış pozisyon değerleri.	38
Şekil 5.10 : Karmaşık yörünge için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.....	39
Şekil 5.11 : Yüksüz Durum için 1.eklem referans ve çıkış açısı değerleri.....	40
Şekil 5.12 : Yüksüz durum için 2.eklem referans ve çıkış açısı değerleri.	41
Şekil 5.13 : Yüksüz durum için 3.eklem referans ve çıkış açısı değerleri.	41
Şekil 5.14 : Ani yük değişimi için uç işlevciye uygulanan yük.	42
Şekil 5.15 : Ani yük değişimi için için x eksenli referans ve çıkış pozisyon değerleri.	43
Şekil 5.16 : Ani yük değişimi için için y eksenli referans ve çıkış pozisyon değerleri.	43

Şekil 5.17 : Ani yük değişimi için z eksen referans ve çıkış pozisyon değerleri.	44
Şekil 5.18 : Ani yük değişimi için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.	44
Şekil 5.19 : Anahtarlama yük değişimi için referans yörünge.	45
Şekil 5.20 : Anahtarlama yük değişimi için uç işlevciye uygulanan yük.	45
Şekil 5.21 : Anahtarlama yük değişimi için x eksen referans ve çıkış pozisyon değerleri.	46
Şekil 5.22 : Anahtarlama yük değişimi için y eksen referans ve çıkış pozisyon değerleri.	46
Şekil 5.23 : anahtarlama yük değişimi için z eksen referans ve çıkış pozisyon değerleri.	47
Şekil 5.24 : Anahtarlama yük değişimi için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.	47
Şekil 5.25 : Zamanla azalan yük için uç işlevciye uygulanan yük.	48
Şekil 5.26 : Zamanla azalan yük değişimi için x eksen referans ve çıkış pozisyon değerleri.	48
Şekil 5.27 : Zamanla azalan yük değişimi için y eksen referans ve çıkış pozisyon değerleri.	49
Şekil 5.28 : Zamanla azalan yük değişimi için z eksen referans ve çıkış pozisyon değerleri.	49
Şekil 5.29 : Zamanla azalan yük için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.	50
Şekil 5.30 : Yük altında 1.eklem referans ve çıkış açısı değerleri.	52
Şekil 5.31 : Yük altında 2.eklem referans ve çıkış açısı değerleri.	52
Şekil 5.32 : Yük altında 3.eklem referans ve çıkış açısı değerleri.	53

DESTEK VEKTÖR MAKİNESİ İLE ROBOTİK KOLLARIN UYARLAMALI MODEL ÖNGÖRÜLÜ KONTROLÜ

ÖZET

Robotik kolların dinamiğinin doğru bir şekilde hesaplanması ve denetleyici parametrelerinin uyarlanması için; modelin keskinliği ve hassasiyeti büyük önem taşımaktadır. Doğrusal olmayan sistem dinamiklerinin keskin bir şekilde tanımlanmasında yapay sinir ağları ve destek vektör makinası algoritmaları sıklıkla tercih edilmektedir. Destek vektör makineleri, makine öğrenmesi yöntemleri arasında en etkili regresyon tekniklerinden biridir.

Bu tez çalışması kapsamında, robotik kolların destek vektör makinesi tabanlı uyarlamalı model öngörülü kontrolünü sağlayacak yöntem önerilmiştir. İlk olarak, örnek alınan bir manipülatörün verileri kullanılarak destek vektör regresyonu ile dinamik model tahmini yapılmıştır. Dinamik model tahmini yapılırken eğitilen modelin öğrenme parametreleri eğitim verisinin ezberlenmesini bir başka deyişle aşırı öğrenmeyi engellemek amacıyla optimize edilmiştir. Kullanılan manipülatör dört eksenli hafif yapılı bir robot koldur. Tahmin edilen bu model, uyarlama mekanizmasında kullanılarak modelleme hataları ve bozucu etkilerinin minimuma indirildiği görülmüştür. Elde edilen kontrol yapısının farklı yörüngeler üzerinde ve değişken yük koşullarında başarılı bir yörünge takip performansı gösterdiği izlenmiştir. Karmaşık yörüngelerin takibinde de önerilen kontrol yapısının başarılı olduğu yapılan benzetim çalışmaları ile gösterilmiştir. Önerilen denetleyici yörünge takibi başarısını etkileyen özellikle zamanla değişen yükün baskın olduğu anlarda minimum konum hatası ile yörünge takibini sağlanmıştır. Destek vektör regresyonu ile kestirilen model ve uyarlamalı kontrol mekanizmasının birlikte kullanımı, sistemdeki modellenememiş dinamikler, belirsizlikler, dış bozucular ve parametre değişimlerine karşı oldukça etkili olmaktadır.

Anahtar kelimeler: Robot manipülatörler, yörünge takibi, makine öğrenmesi, destek vektör makinası, uyarlamalı kontrol, model öngörülü kontrol.

SUPPORT VECTOR MACHINE BASED MODEL PREDICTIVE ADAPTIVE CONTROL OF ROBOTIC ARMS

SUMMARY

For the correct calculation of the dynamics of the robotic arms and the adaptation of the controller parameters; the accuracy and precision of the model has great importance. Artificial neural networks and support vector machine algorithms are often preferred for the accurate definition of nonlinear system dynamics. Support vector machines are one of the most effective regression techniques among machine learning methods.

Within the scope of this thesis, a method that will provide support vector machine based adaptive model predictive control of robotic arms is proposed. First, dynamic model estimation was performed with support vector regression using the data of a sampled manipulator. While estimating the dynamic model, the learning parameters of the trained model are optimized to prevent memorization of the training data, in other words, over-learning. The manipulator used is a four-axis lightweight robot arm. It has been observed that modeling errors and disruptive effects are minimized by using this predicted model in the adaptation mechanism. It was observed that the obtained control structure showed a successful trajectory tracking performance on different trajectories and under variable load conditions. It has been shown by the simulation studies that the proposed control structure is successful in the tracking of complex trajectories. Trajectory tracking is provided with minimum position error, especially when the time-varying load is dominant, which affects the success of the proposed controller trajectory tracking. The combined use of the model predicted by support vector regression and adaptive control mechanism is very effective against unmodeled dynamics, uncertainties, external disturbances and parameter changes in the system.

Keywords: Robot manipulators, trajectory tracking, machine learning, support vector machine, adaptive control, model predictive control.

1. GİRİŞ

Veri çiftlerinin birbirleriyle ilişkilerinin olmadığı durumlardaki sınıflandırma problemlerinde Destek Vektör Makinesi (DVM) yöntemi önerilmektedir. Bu yöntemin anafikrini oluşturan ve önerilmesi 1909 yıllarına dayanan çekirdek kavramı, ilk olarak "COLT" isimli konferansta 1995 yılında Rus Matemeatikçi Vladimir Vapnik tarafından sunulmuştur. Optimizasyon probleminde global çözümün garanti edilmesi DVM'leri yapay sinir ağlarına göre üstün kılmaktadır. Optimizasyon probleminin konveks bir yapıya bürünmesi yöntemiyle yerel minimuma takılma problemi çözülmüştür. Bu sayede optimizasyon problemlerinin çözümünde önemli bir gelişme elde edilmektedir.

Birden fazla sınıflandırma probleminde, DVM tabanlı yöntemler tercih edilmektedir. Mikrodalga teknolojisi ile çalışan cihazlarda gürültüyü önlemek için kullanılması sağlık alanında kullanıma bir örnektir [1]. Özellikle kanserli dokuların tanısı ve sınıflandırılması konusunda DVM yöntemine başvurulmaktadır [2]. Doğrusal olmayan sistemlerin kara kutu (black-box) modellerinin oluşturulmasında DVM yönteminin başarısı etkilidir [3]. Bunun dışında ses tanıma için; iki ayrı çekirdek fonksiyonu önerilerek GMM modeli (Gauss Karışım Metodu) ve DVM sınıflandırıcı birlikte kullanılır [4].

İstatistiksel öğrenme teorisine dayanan DVM sınıflandırma problemlerinde kullanıldığı gibi regresyon analizlerinde de etkilidir. Belirsiz girdi ve çıktılarla parametreler hakkında ön bilgi olmadığı durumlarda kullanılan yöntemde yeni veri girişlerini sınıflandırmak için eğitim verilerindeki değerler eşlenerek karar fonksiyonları oluşturulur.

Bir robot koldaki hedef nokta için gerekli kuvvet ve torklar, hareketin ileri ya da ters dinamik olarak ifade edilen dinamik denklemleri kullanılarak tanımlanır. İleri dinamik; uç işlevcinin ivmesinin eklem konumu, hızı ve kuvvet/torklarına göre bulunmasıdır. Robot kolun gerçek zamanlı kontrolünde dinamik değerlerinin doğru bir şekilde hesaplanmada önemli bir noktadır.

Kontrol yöntemini belirleyici olmasının en büyük nedeni sistem belirsizlikleridir. Sistem belirsizliklerini gidermek için kullanılan lineer kontrol yöntemlerinin çözüm olmadığı durumlarda nonlinear yöntemlere başvurulur. Bu yöntemlerden biri olan model referans uyarlamalı kontrolde hedef, bilinmeyen sistem çıkışını referans alınan modelin sistem çıkışına yakınsatmaktır. Bu yöntemde referans alınan sistem modeli önem kazanmaktadır [5]. Gürbüz uyarlamalı kontrolün uygulamaları örnekleri mobil robotların yörünge takip problemine çözüm olarak karşımıza çıkmaktadır.

Uyarlamalı kontrol yapısı kullanılırken referans model olarak yapay sinir ağları ile oluşturulan tahmini modelin kullanımı yine mobil robotların kinematik kontrolünde karşımıza çıkmaktadır.

Robot manipülatörleri dışında genel olarak çok-giriş çok-çıkışlı nonlinear sistemlerin yörünge takip problemi uyarlama yapısı ile çözülmektedir [8]. Bu yapı aynı zamanda sistem sınırlamalarını da kontrol problemi içinde çözmektedir. Robot manipülatörlerinin doğal sınırları olan çalışma uzayında çözüm sunmak uyarlamalı kontrol yapısının bir başka üstünlüğüdür.

Bununla beraber destek vektör makinelerinin kontrol yöntemi araştırmalarında yaygın bir kullanımı bulunmaktadır. Uçuş kontrolü [9, 27] ile tank sistemlerinin modellenmesi [10] problemlerinde destek vektör makinesinin model öngörülü kontrolörlerde model belirleme için kullanılması örnek bir uygulama alanı olarak karşımıza çıkmaktadır.

Karadeniz bölgesindeki söğüt ağacı türlerini izole etmek için DVM tabanlı vektör izdüşüm kontrol modeli kullanılmıştır. [11] Ayrıca, farklı yükler altında kazan sistemlerinin gürbüz kontrolünde model tanımlaması için en küçük kareler destek vektör makinesi regresyonu kullanılmıştır [12]. En küçük kare DVM, doğrusal olmayan kontrol valfi modellemesinde de kullanılmıştır [13]. DVM, iç model kontrolör [14] ile sabit mıknatıslı senkron motorları kontrol etmek için kullanılır. DVM ile araç elektrik kontrol sistemi modellemesi yeni bir otomotiv kontrol yöntemi olarak tanıtılmıştır [15].

Kinematik hesaplamalar, yol planlaması ve konum kontrolünü içeren robotik problemlerine DVR uygulanarak çeşitli çözümler sunulmuştur. Bu çözümlere bir örnek, hareketi oldukça karmaşık ve doğrusal olmayan özelliklere sahip paralel robotların kinematik modellemesidir [16]. Yedi veya daha fazla eklemi olan robotların

ters kinematik denklemlerinin analiz yöntemleri yine oldukça karmaşıktır. Ayrıca, tekil noktalar bir sorun teşkil eder. Kinematik problemini robotu SVM regresyon ile modelleyerek çözmek, doğru ve verimli bir çözüm sağlar [17]. Bu yöntem endüstriyel robotlar üzerinde de test edilmiş ve diğer yöntemlere kıyasla faydalı olduğu belirlenmiştir [18].

Yörünge planlamasındaki temel problem olan çalışma alanında engellerden kaçınma, bulanık DVM algoritması ile çözülmüştür [19]. Robotik görüntü işleme problemlerinin bazı uygulamalarında DVM kullanılmaktadır. Mobil robotların konumlandırılmasında, engel tanıma hatalarını ortadan kaldırmak için uygulanmıştır [20].

Uyarlamalı PID konusundaki örnekler incelendiğinde bu yöntem öncelikle doğrusal sistemlere uygulanmıştır. PID kontrolör parametrelerinin belirlenmesinde en küçük kareler DVM yöntemi akıllı bir kontrol yöntemi olarak kullanılmıştır [21]. En küçük kareler DVM uyarlamalı kontrolün ayrıca yanma odası enerji optimizasyonu probleminde uygulaması bulunmaktadır [22].

Genelleştirilmiş bir en küçük kareler DVM uyarlamalı kontrol yapısı [23]'te sunulmuş ve ayrıca Ph nötralizasyon işleminde uygulanmıştır. Burada kullanılan yöntem çok çözünürlüklü dalgacık en küçük destek vektör makinası ağı olarak adlandırılmıştır. Önerilen ağ yapısı model öngörmede kullanılmış ve kontrolör yapısı referans yörüngeyi takip etmek üzere tasarlanmıştır.

Şimdiye kadar bahsedilen destek vektör makinası tabanlı uyarlamalı kontrol yapısının yörünge izleme problemleri üzerine uygulamaları da görülmektedir. Modeli bilinmeyen bir nonlineer sistem için klasik yapay sinir ağı ile birlikte takip kontrolü için kullanılmıştır [24]. Bunun yanında bulanık mantık yapısının destek vektör makinası ile birlikte kullanımı altı eksenli paralel robot yörünge takip kontrolünde kullanılmıştır [25]. Ayrıca iki eksenli bir robot manipülatörü yörünge takip problemi için geri adım kontrolü adı verilen yöntemle en küçük kareler destek vektör makinası yardımıyla çevrimdışı olarak tahmin edilen parametrelerle bir uyarlama mekanizması kurulmuştur [26].

Literatürde bulunan çalışmalarda yörünge takip problemine tek başına destek vektör makinası veya uyarlama mekanizması kullanılarak çözüm aranmıştır. Her iki yöntemin eksik yönleri ve açıkları bulunmaktadır.

Analitik yöntemle oluşturulan dinamik modeli baz alarak oluşturulan bir uyarlamalı kontrol yapısı, teorik modelin eksikleri ve hatalarını da uyarlama mekanizmasına taşımaktadır. Bu iki çözümün beraber kullanılarak önerilen yapı karşılaşılan eksiklikleri gidermektedir. Bozucu bastırmada uyarlama mekanizması başarılı olurken, baz alınan dinamik model destek vektör regresyonu ile tahmin edilerek modelleme hatalarının önüne geçilmiştir. Hassas konumlandırmada önemi artan modelleme hataları, robot kolun çalışma uzayı gerekli hassasiyette taranıp eğitim verisine eklenerek minimize edilebilir.

Uyarlamalı yapının bir başka avantajı da; denetleyici parametreleri öğrenilen sistem modeline göre güncellendiği için manipülatöre dışardan uygulanan herhangi bir etkiye karşı kontrol yapısı hızlı cevap verebilmektedir. Uygulama alanına bağlı olarak özellikle ani ya da zamanla değişen yük profillerinin oluşturduğu etki; kısa sürede kompanse edilerek yörünge takip performansı korunmaktadır.

Tezde, giriş bölümünde tezin çözüm sunduğu problem tanıtılarak literatürdeki mevcut çözümler incelenmiştir. İkinci bölümde ise, robot kol dinamik modellemesinde kullanılan destek vektör makinası regresyonu yöntemi sınıflandırma özelliğini de içerecek şekilde açıklanmıştır. Üçüncü bölümde, dört eksenli robot kol dinamik modeli DVR yöntemi ile çıkarılmış ve oluşturulan modelin test verilerine yer verilmiştir. Dördüncü bölümde, öngörülen modele dayanan DVM tabanlı uyarlamalı PID kontrol yöntemi anlatılmıştır. Beşinci bölümde, önerilen denetleyicinin performansı çeşitli senaryolar üzerinde incelenmiştir. Altıncı bölümde ise, tezde ortaya konulan DVM tabanlı uyarlamalı PID kontrolcünün faydaları doğrultusunda kullanım alanları ve gelecek çalışmalar tartışılmıştır.

2. DESTEK VEKTÖR MAKİNELERİ REGRESYONU

Bu bölümde; önerilen kontrol yapısında robot kol modellemede kullanılacak olan destek vektör makineleri regresyonu, yaygın kullanım alanı olan sınıflandırma problemi örneğinden yola çıkılarak tanıtılmıştır.

2.1. Destek Vektör Makinası Sınıflandırması

2.1.1 Doğrusal ayrılabilen veriler


D eğitim verilerini temsil etmektedir.

$$D = \{(x^1, y^1), \dots, (x^l, y^l)\} \quad y \in (-1, 1) \quad l : \text{örnek sayısı} \quad (2.1)$$

DVM sınıflandırmasındaki amaç en iyi sınıflandırıcı düzlemi elde etmektir. Denklem 2.2 ve Şekil 2.1 de eğitim verilerini doğrusal olarak ayırabilecek optimum hiperdüzlem görülmektedir.

$$\langle w, x \rangle + b = 0 \quad \langle \rangle : \text{nokta çarpım} \quad (2.2)$$

$w : \text{ağırlık vektörü} \quad b : \text{bias}$



Şekil 2.1 : Optimal hiperdüzlem.

En yakın eğitim verisine olan uzaklığı maksimum olan optimal hiperdüzlem Denklem 2.3 deki eşitsizlikleri sağlamalıdır.


$$\langle w, \hat{x}_i \rangle + b \geq 1 \quad y^i = 1 \quad \langle w, \hat{x}_i \rangle + b \leq -1 \quad \hat{y}_i = -1 \quad (2.3)$$

Optimizasyon probleminin kısıtı bu iki eşitsizlik tek bir eşitsizlikte birleştirilerek oluşturulur.

$$\hat{y}_i \cdot [\langle w, \hat{x}_i \rangle + b] \geq 1 \quad i = 1, \dots, l \quad (2.4)$$

Ağırlık vektörü ve bias teriminin optimum değerini bulmak problemin temel amacıdır. Şekil 2.2 de görüldüğü gibi bir vektörün optimal hiperdüzleme olan uzaklığına marjin denir.

$$d(w, b : x) = |\langle w, \hat{x}_i \rangle + b| / \|w\| \quad (2.5)$$



Şekil 2.2 : Destek vektörleri.

$$p(w, b) = \min_{x^i, y^i = -1} d(w, b : x^i) + \min_{x^i, y^i = 1} d(w, b : x^i) : \hat{x}_i >) p(w, b) = 2 / \|w\| \quad (2.6)$$

Sınıflama hatasının minimum değerini alması için marjin maksimize edilmelidir. Bu durum ağırlık vektörü normu minimizasyonu ile sağlanır [27].

$$\Phi(w) = \frac{1}{2} \|w\|^2 \quad (2.7)$$

2.1.1.1 Lagrange çarpanları yöntemi

Denklem 2.8 de belirtildiği üzere birincil minimizasyon problemi, Lagrange fonksiyonu ile oluşturulur.

$$\text{Amaç fonksiyonu: } \Phi(w) = \frac{1}{2} \|w\|^2$$

$$\text{Kısıt : } y^i \cdot [w, x^i] + b \geq 1 \quad i = 1, \dots, l$$

$$\text{Lagrange Fonksiyonu:} \quad (2.8)$$

$$\Phi(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^l \alpha_i [y^i \cdot [w, x^i] + b] - 1$$

Eyer noktasında ağırlık vektörü ve bias terimi minimumda, lagrange çarpanları maksimumdadır. Eyer noktası, bu problemde sınıflandırma hatasını minimize eden noktadır.

$$\max_{\alpha} W(\alpha) = \max_{\alpha} (\min_{w, b} \Phi(w, b, \alpha)) \quad (2.9)$$

Optimizasyon problemi Karush-Kuhn-Tucker (KKT) koşulları yardımıyla çözülür ve bu koşullar Denklem 2.10 da görülen türev değerlerinden oluşur.

$$\frac{\partial \Phi}{\partial b} = 0 \quad \rightarrow \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (2.10)$$

$$\frac{\partial \Phi}{\partial w} = 0 \quad \rightarrow \quad w = \sum_{i=1}^l \alpha_i y_i x_i$$

Problemin son hali amaç fonksiyonu ve kısıtları birleştiren Lagrange fonksiyonu oluşturularak elde edilir.

$$\begin{aligned} \Phi(w, b, \alpha) = & \frac{1}{2} \|w\|^2 \\ & - \sum_{i=1}^l \alpha_i [y^i \cdot [w, x^i]] - b \cdot \sum_{i=1}^l \alpha_i [y^i] + \sum_{i=1}^l \alpha_i \end{aligned} \quad (2.11)$$

$$\|w\|^2 = \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j < x_i, x_j > \quad (2.12)$$

Yeni amaç fonksiyonu:

$$Q(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j < x_i, x_j > \quad (2.13)$$

$$\text{Kısıtlar: } \sum_{i=1}^l \alpha_i y_i = 0 \quad \alpha_i \geq 0$$

Optimum α değerleri optimal hiperdüzlemi belirler. Destek vektörlerini, lagrange çarpanları sıfır olmayan eğitim verileri oluşturur. Denklem 2.14 de optimal hiperdüzlem, destek vektörler ve Lagrange çarpanları olarak ifade edilmiştir.

$$f(x) = \sum_{i=1}^l \alpha_i y_i < x_i, x > + b \quad (2.14)$$

Ağırlık vektörü ve bias terimi hesaplamaları destek vektörleri cinsinden Denklem 2.15 de gösterilmiştir.

$$w^* = \sum_{i=1}^l \alpha_i y_i x_i$$

$$b^* = \frac{-1}{2} < w^*, x_r + x_s > \quad y_r = -1, y_s = 1 \quad (2.15)$$

$< x_r, y_r >, < x_s, y_s >:$ destek vektörleri

Karar fonksiyonu Denklem 2.16 daki gibi oluşturulur. Oluşturulan fonksiyonun signum değeri alınarak verinin hangi sınıfta olduğuna karar verilir.

$$f(x) = \text{sgn}(< w^*, x > + b) \quad (2.16)$$


Alternatif bir fonksiyon olarak , Denklem 2.17 deki gibi gerek deęerleri veren fonksiyon kullanılır [28]. $h(z)$ fonksiyonu birden fazla sınıfı ierdięi iin uygulamada pratiktir.

$$f(x) = h(< w^*, x > + b)$$

$$h(z) = \begin{cases} -1 & z < -1 \\ z & -1 < z < 1 \\ 1 & z > 1 \end{cases} \quad (2.17)$$

2.1.2 Doęrusal olmayan sınıflandırma

Veri kümesi Şekil 2.3 deki gibi doęrusal olarak fakat ek bir hata ile ayrıldığında, bu hatayı minimize etmek amacıyla ikinci bir fonksiyon eklenir [29].



Şekil 2.3 : Sınıflandırma verisi.

$\xi_i \geq 0$: sınıflandırma hatası

$0 \leq \xi \leq 1$ durumu verinin doęru sınıfta olduęunu gösterir. (2.18)

$\xi > 1$ durumu verinin yanlış sınıfta olduęunu gösterir.

Doęrusal problemdeki kısıtlar yeni durumda da kullanılabilir. Doęrusallık hatası dışında problem aynıdır.

$$\begin{aligned} < w, x^i > + b \geq 1 - \xi_i \quad y^i = 1 \\ < w, x^i > + b \leq -1 + \xi_i \quad y^i = -1 \end{aligned} \quad (2.19)$$

$$y^i \cdot [\langle w, x^i \rangle + b] \geq 1 - \xi_i$$

$$\text{Amaç fonksiyonu: } \Phi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i$$

Dual problem Lagrange fonksiyonu ile oluşturulur. Amaç fonksiyonuna destek vektörleri doğrusal olmayan bir fonksiyon ile eklenir.

$$\begin{aligned} \Phi(w, b, \xi, \alpha, \beta) = \\ \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l \xi_i - \sum_{i=1}^l \alpha_i [y^i \cdot [\langle w, x^i \rangle + b] - 1 + \xi_i] - \sum_{i=1}^l \beta_i \xi_i \end{aligned}$$

$$\text{Dual Problem : } \max_{\alpha} W(\alpha, \beta) = \max_{\alpha, \beta} (\min_{w, b, \xi} \Phi(w, b, \xi, \alpha, \beta))$$

$$\frac{\partial \Phi}{\partial b} = 0 \quad \rightarrow \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (2.20)$$

$$\frac{\partial \Phi}{\partial w} = 0 \quad \rightarrow \quad w = \sum_{i=1}^l \alpha_i y_i x_i$$

$$\frac{\partial \Phi}{\partial \xi} = 0 \quad \rightarrow \quad \alpha_i + \beta_i = C$$

Dual probleme lagrange fonksiyonunda kısıtlar eklendiğinde Denklen 2.21 deki gibi oluşturulur. Problem yine sınıflandırma olduğundan kısıtlar aynıdır.

$$Q(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \langle x_i, x_j \rangle \quad (2.21)$$

$$\text{Kısıtlar: } \sum_{i=1}^l \alpha_i y_i = 0$$

Kısıtlarda görünen ve ayrıca tanımlanan C parametresi, lagrange çarpanlarının muhtemel değerleri için üst sınırdır. Destek vektörlerinin optimal hiperdüzlemde bulunması, C parametresinin Lagrange çarpanları ile aynı değerde olması ile mümkündür. C değeri ne kadar büyük olursa, test hatası o kadar yüksek olur. Bu değer, problemin kapasitesini belirlemek için başka bir kontrol ekler.

$$w^* = \sum_{i=1}^l \alpha_i y_i x_i$$


$$b^* = \frac{-1}{2} \langle w^*, x_r + x_s \rangle \quad y_r = -1, y_s = 1 \langle x_r, y_r \rangle, \quad \langle x_s, y_s \rangle: \text{destek vektörleri}$$
(2.22)

Karar fonksiyonu Denklem 2.23 deki gibi oluşturulur.

$$f(x) = \text{sgn}(\langle w^*, x \rangle + b)$$
(2.23)

2.1.3 Doğrusal olmayan destek vektör makineleri

Doğrusal olmayan destek vektör makineleri, veri kümesinin doğrusal bir fonksiyon tarafından doğrudan veya bazı hatalarla bölünemediği durumlarda kullanılan algoritmalarıdır. Gerçek hayat problemlerinin doğrusal olmayan yönleri olduğundan, Şekil 2.4 teki bir veri setini doğrusal hiperdüzlem ile ayırtırmak çoğu zaman mümkün değildir. Bu nedenle sınıflandırma problemi ayırma eğrisi dikkate alınarak çözülebilir. Ancak pratikte eğriyi tahmin etmek çok zordur.



Şekil 2.4 : Doğrusal olmayan hiperdüzlem.

Bu durumda, veriler girdi uzayından doğrusal olmayan bir harita (ϕ) aracılığıyla doğrusal sınıflandırmaya izin veren daha yüksek boyutlu bir özellik uzayına dönüştürülür. Doğrusal sınıflandırma formülasyonlarının yardımıyla bu yeni özellik, veri setini sınıflandırabilen en iyi hiper düzlemi araştırır.

$\varphi(x)$ geiş fonksiyonu ile hiperdüzlem bir üst uzaya ıkarılır.

$$\begin{aligned} \text{Optimal hiperdüzlem : } \sum_{i=1}^l w_i \varphi_i(x) + b &= 0 \\ w &= \sum_{i=1}^l \alpha_i d_i \varphi_i(x) \quad \sum_{i=1}^l \alpha_i d_i \varphi_i^T(x) \varphi_i(x) + b = 0 \end{aligned} \quad (2.24)$$

Haritalama fonksiyonunun özelliğı açık değıldir ve özümü bilinse bile üst boyutlardaki bir uzayda kompleks hale gelir. ekirdek fonksiyonları bu karmaşıklığı gidermek için sunulmuştur. Bu fonksiyon polinom, radyal veya sigmoid forma dayalı olabilir [22].

$$\text{ekirdek fonksiyonu: } K(x, x_i) = \varphi^T(x) \varphi(x_i) \quad (2.25)$$

ekirdek fonksiyonu simetriktir. Bu yüzden fonksiyon giriş değıerleri Denklem 2.26 daki gibi düzenlenebilir.

$$K(x, x_i) = K(x_i, x)$$

$$\text{Optimal hiperdüzlem : } \sum_{i=1}^l \alpha_i d_i K(x, x_i) = 0 \quad (2.26)$$

ekirdek fonksiyonu ile dual problem Denklem 2.27 deki gibi oluşturulur. Doğrusal olmayan fonksiyon yerine ekirdek fonksiyonu gelir.

$$Q(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (2.27)$$

Dual problemin kısıtları değışmemektedir.

$$\text{Kısıtlar: } \sum_{i=1}^l \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C \quad (2.28)$$

$$\langle w^* x \rangle = \sum_{i=1}^l \alpha_i y_i K(x, x_i)$$

Sınıflandırma için karar fonksiyonu çekirdek fonksiyonu ile birlikte Şekil 2.29 daki gibi oluşturulur.

$$f(x) = \text{sgn} \left(\sum_{i=1}^l \alpha_i y_i K(x, x_i) + b \right) \quad (2.29)$$


$$b = \frac{-1}{2} \sum_{i=1}^l \alpha_i y_i [K(x, x_r) + K(x, x_s)] \quad y_r = -1, y_s = 1$$

Karar fonksiyonu; bias terimi de çekirdek fonksiyonuna eklendiğinde Denklem 2.30 daki hale gelir.

$$f(x) = \text{sgn} \left(\sum_{i=1}^l \alpha_i y_i K(x, x_i) \right) \quad (2.30)$$

2.2 Destek Vektör Regresyonu

Destek vektör makinelerinin regresyon problemini çözmesi için kullanılan farklı kayıp fonksiyonları Şekil 2.5 te görülmektedir.



Şekil 2.5 : Kayıp fonksiyonları.

ϵ -duyarlı kayıp fonksiyonu, DVM yönteminin regresyon ile ilişkilendirilmesine izin verir. Kayıp fonksiyon hassasiyet parametresi olmadan uygulandığında tüm veriler destek vektörleri şeklinde belirlenir. Bu durumda tüm veriler hesaplamada kullanılacağından işlem yükü artar.

2.2.1 ϵ -Duyarlı kayıp fonksiyonu

ϵ 'ye duyarlı kayıp fonksiyonu, hataların bir ϵ aralığında göz ardı edileceği veri kümeleri için uygundur. Mutlak kayıp fonksiyonunun aksine, bu aralıktaki verilerin regresyona uygun olduğu ve hata içermediği varsayılır. Böyle bir marjın belirlenmesi, kayıp fonksiyonunu ϵ DVM regresyonunda kullanım için mantıklı kılar.

Kayıp fonksiyonu:

$$L(d, y) = |d - y| \quad d: \text{istenen değer} \quad y: \text{gerçek değer}$$

ϵ – sensitive Kayıp Fonksiyonu : (2.31)

$$L_{\epsilon}(d, y) = \begin{cases} |d - y| - \epsilon & |d - y| \geq \epsilon \\ 0 & \text{diğer} \end{cases}$$


2.2.2 Doğrusal regresyon

D eğitim verilerini gösterir.

$$D = \{(x^1, y^1), \dots, (x^l, y^l)\} \quad l : \text{örnek sayısı} \quad (2.32)$$

Eğitim verileri arasındaki ilişki Denklem 2.33 ve Şekil 2.6 daki optimum doğrusal fonksiyon ile ifade edilebilir. Regresyonun amacı bu fonksiyonu tahmin etmektir.

$$f(x) = \langle w, x \rangle + b = 0 \quad \langle \rangle : \text{nokta çarpımı} \quad (2.33)$$



Şekil 2.6 : Doğrusal destek vektörleri.

$$\begin{aligned} \text{Primer amaç fonksiyonu: } \Phi(w, \epsilon) &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\epsilon_i^- + \epsilon_i^+) \\ \text{Kısıtlar : } y^i - \langle w, x^i \rangle - b &\leq \epsilon + \epsilon_i^+ \quad y^i - \langle w, x^i \rangle + b \geq \epsilon - \epsilon_i^- \\ \epsilon + \epsilon_i^- \quad \epsilon_i^-, \epsilon_i^+ &\geq 0 \end{aligned} \quad (2.34)$$

Lagrange çarpanları yöntemi ile oluşturulan Denklem 2.35 deki amaç fonksiyonu ile dual problem elde edilir. Amaç fonksiyonuna, sınıflandırma probleminden farklı olarak kısıtlar ϵ 'ye duyarlı kayıp fonksiyonu ile ifade edilir.

$$\begin{aligned} &\Phi(w, \epsilon, \alpha^+, \alpha^-, \eta^+, \eta^-) \\ &= \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\epsilon_i^- + \epsilon_i^+) - \sum_{i=1}^l (\eta_i^+ \epsilon_i^+, \eta_i^- \epsilon_i^-) \\ &\quad - \sum_{i=1}^l \alpha_i^+ (\epsilon + \epsilon_i^+ - y^i + \langle w, x^i \rangle + b) \\ &\quad - \sum_{i=1}^l \alpha_i^- (\epsilon + \epsilon_i^- - y^i + \langle w, x^i \rangle + b) \end{aligned} \quad (2.35)$$

Eyer noktası Denklem 2.36 daki koşullar ile belirlenir. Koşullar sınıflandırma ile benzerlik gösterir.

$$\begin{aligned}
\frac{\partial \Phi}{\partial b} = 0 & \quad \rightarrow \quad \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) = 0 \\
\frac{\partial \Phi}{\partial w} = 0 & \quad \rightarrow \quad w = \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) x_i \\
\frac{\partial \Phi}{\partial \varepsilon} = 0 & \quad \rightarrow \quad \alpha_i + \eta_i = C
\end{aligned} \tag{2.36}$$

Dual problem kısıtlar ile birlikte Denklem 2.37 deki gibi oluşturulur. Kısıtlar regresyon hatasını minimize edecek şekilde belirlenir. Bu koşul da sınıflandırma probleminde olduğu gibi ağırlık vektörü ve bias terimi minimumda, lagrange çarpanları maksimumda tutacak şekilde belirlenir.

$$\begin{aligned}
\max_{\alpha_i^+, \alpha_i^-} (\alpha_i^+, \alpha_i^-) &= \max_{\alpha_i^+, \alpha_i^-} -\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^+ - \alpha_i^-) (\alpha_j^+ - \alpha_j^-) < x_i, x_j \\
&> + \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) \cdot y_i + \varepsilon \cdot \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) \\
\text{Kısıtlar: } \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) &= 0 \quad 0 \leq \alpha_i^+, \alpha_i^- \leq C
\end{aligned} \tag{2.37}$$

$$\begin{aligned}
w^* &= \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) x_i \quad b^* = \frac{-1}{2} < w^*, x_r + x_s > \\
&< x_r, y_r >, \quad < x_s, y_s > : \text{destek vektörleri}
\end{aligned}$$

2.2.3 Doğrusal olmayan regresyon

Regresyona tabi tutulacak veriler de doğrusal olmayan bir fonksiyon olabilir. Doğrusal olmayan haritalama çekirdek fonksiyonu ile gerçekleştirilerek veri seti bir üst uzaya haritalanır ve böylece regresyon üst uzayda uygulanır [31].

$$\begin{aligned}
\max_{\alpha_i^+, \alpha_i^-} (\alpha_i^+, \alpha_i^-) &= \max_{\alpha_i^+, \alpha_i^-} -\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\alpha_i^+ - \alpha_i^-) (\alpha_j^+ - \alpha_j^-) \\
&\alpha_j^-) K(x_i, x_j) + \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) \cdot y_i + \varepsilon \cdot \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-)
\end{aligned} \tag{2.38}$$

Doğrusal regresyon ile kısıtlar aynıdır. Çekirdek fonksiyonu kısıtları etkilemez.

$$\begin{aligned}
\text{Kısıtlar: } \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) &= 0 \quad 0 \leq \alpha_i^+, \alpha_i^- \leq C \\
\langle w^*, x \rangle &= \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) K(x, x_i) \\
b^* &= \frac{-1}{2} \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) (K(x_i, x_r) + K(x_i, x_s))
\end{aligned} \tag{2.39}$$

$$\text{Regresyon fonksiyonu : } f(x) = \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) K(x, x_i) + b$$

Regresyon fonksiyonunun bias terimini içermesi çekirdek fonksiyonuna bağlıdır. Çekirdek fonksiyonunun kompleks hale gelmesi , tahmin edilecek sistem modelinin karmaşıklığına bağlıdır.

$$f(x) = \sum_{i=1}^l (\alpha_i^+ - \alpha_i^-) K(x, x_i) \tag{2.40}$$

2.3 En Küçük Kareler Destek Vektör Makinesi

En küçük kareler DVM yöntemi, doğrusal olmayan veri kümelerinde regresyon gerçekleşmesini sağlar. Bu formülasyon kara kutu (black-box) modelleri ve optimal kontrol problemlerine çözüm olarak sunulmuştur [30].

2.3.1 En küçük kareler destek vektör sınıflandırması

En küçük kareler yöntemine göre amaç fonksiyonu Denklem 2.41 deki halini alır. En küçük kareler yöntemi ile optimizasyon problemi kolaylaşır.

$$\Phi(w, e) = \frac{1}{2} \|w\|^2 + \gamma \sum_{k=1}^l e_k^2 \tag{2.41}$$

$$\text{Kısıt : } y^i \cdot [\langle w, \varphi(x_i) \rangle + b] \geq 1 - e_i \quad i = 1, \dots, l$$

Yeni halde optimal hiperdüzlem eşitliği de değişir. Hiperdüzlem denklemine hata terimi de eklenir.

$$y^i \cdot [< w , \varphi(x_i) > + b] = 1 - e_i \quad (2.42)$$

Dual problem en küçük kareler hata terimi ile birlikte Denklem 2.43 deki halini alır.

$$\Phi(w, b, e, \alpha) = \frac{1}{2} \|w\|^2 + \gamma \sum_{k=1}^l e_k^2 \sum_{i=1}^l \alpha_i [y^i \cdot [< w , \varphi(x_i) > + b] - 1 + e_i] \quad (2.43)$$

Eğer noktası koşulları da optimizasyon problemi değiştiğinden farklılaşır.

$$\begin{aligned} \frac{\partial \Phi}{\partial b} = 0 & \rightarrow \sum_{i=1}^l \alpha_i y_i = 0 \\ \frac{\partial \Phi}{\partial w} = 0 & \rightarrow w = \sum_{i=1}^l \alpha_i y_i \varphi(x_i) \\ \frac{\partial \Phi}{\partial \varepsilon} = 0 & \rightarrow \alpha_i = \gamma e_i \end{aligned} \quad (2.44)$$

Problemin son hali Denklem 2.45 teki gibi olur. Denklemde de görüldüğü gibi en küçük kareler yöntemi optimizasyon problemini matris formuna indirgeyerek kompleks yapıdan uzaklaştırır.

$$\begin{bmatrix} 0 & \overrightarrow{Y^T} \\ Y & \Omega + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad (2.45)$$

$$\Omega_{kl} = y_k y_l \varphi(x_k)^T \varphi(x_l) = K(x_k, x_l) \quad k, l = 1, \dots, N$$

2.3.2 En küçük kareler destek vektör regresyonu

En küçük kareler yöntemi yaklaşımı ile regresyon fonksiyonu da ifade edilebilir. Optimal hiperdüzlemin yerini regresyon fonksiyonu alır.

$$\begin{bmatrix} 0 & \overrightarrow{Y^T} \\ Y & \Omega + \gamma^{-1} I \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}$$

$$\Omega_{kl} = \Omega_{kl} = \varphi(x_k)^T \varphi(x_l) = K(x_k, x_l) \quad k, l = 1, \dots, N \quad (2.46)$$

$$f(x) = \langle w, \varphi(x) \rangle + b = 0$$

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b$$

Amaç fonksiyonuna ağırlıklandırma parametreleri regresyon matrisini robust hale getirmek amacıyla eklenmektedir. Böylece tahmin edilen regresyon fonksiyonun kararlı olması sağlanır.

$$\Phi(w, e) = \frac{1}{2} \|w\|^2 + \frac{1}{2} \gamma \sum_{k=1}^l v_k e_k^{2*} \quad (2.47)$$

Son haliyle optimal regresyon fonksiyonu Denklem 2.48 deki gibi olur.

$$y^i = [\langle w^*, \varphi(x_i) \rangle + b^*] + e_i^* \quad i = 1, \dots, l \quad (2.48)$$

Ağırlıklandırma katsayısı v_k , hata teriminin (e_k) bir fonksiyonu olarak ele alındığında daha robust bir regresyon tahmini yapılmaktadır [32].

3. ROBOTİK KOLLAR İÇİN DESTEK VEKTÖR MAKİNASI DİNAMİK MODELİ

Önceki bölümde detayları anlatılan DVR yöntemi kullanılarak, dört eksenli seri bir robot kol için öncelikle çalışma uzayı içerisinde eğitim verisi oluşturulmuş, sonrasında da bu eğitim verisi ile dinamik model tahmini yapılmıştır. Veri oluşturma ve model tahmini Python kullanılarak yapılmıştır. Bu bölümde tahmin edilen dinamik model ve test verileri yer almaktadır.

3.1 Eğitim Verisi Oluşturulması

DVM regresyonu ile dinamik model oluşturmak için öncelikle manipülatör eklem açıları sınır değerleri içinde taranarak, bir çalışma uzayı oluşturulmuştur. Örnek bir manipülatör olarak 4 eksenli hafif yapılı robot kol kullanılmıştır. Toplam ağırlığı 1.2 kg'dır. Eklem açlarına karşılık tork değerleri Euler-Lagrange yöntemi ile hesaplanmıştır. Bu yöntem denge prensibine dayanarak belirli eklem açısı, hız ve ivme değerlerine karşılık gelen tork değerlerini bulmak için eklemlerin potansiyel ve kinetik enerjilerini kullanır [33].

Dinamik denklemler oluşturulurken Euler-Lagrange metodu uygulanmıştır. Euler-Lagrange yöntemi enerji dengesi prensibine dayanır. Belirli eklem açıları, hızları ve ivmelerine karşılık elde edilen tork değerini bulmak için, eklemlerin potansiyel ve kinetik enerjileri kullanılır.

Bir eklem için Lagrangian terimi:

$$L = K - P \quad (3.1)$$

Buna karşılık gelen Euler-Lagrange denklemi:

$$\tau = \frac{d}{dt} \left[\frac{dL}{d\dot{q}} \right] - \frac{dL}{dq} \quad q: \text{eklem konumu} \quad \dot{q} : \text{eklem hızı} \quad (3.2)$$

Eklem kinetik enerjisi eklem konum ve hızına, potansiyel enerji ise sadece eklem konumuna bağlıdır. Denklemden L terimi yerine konulduğunda:

$$\begin{aligned}
 & \text{Kinetik enerji: } K(q, \dot{q}) \quad \text{Potansiyel Enerji: } P(q) \\
 & \tau = \frac{d}{dt} \left[\frac{dK(q, \dot{q})}{d\dot{q}} - \frac{dP(q)}{d\dot{q}} \right] - \left(\frac{dK(q, \dot{q})}{dq} - \frac{dP(q)}{dq} \right) \\
 & \tau = \frac{d}{dt} \left[\frac{dK(q, \dot{q})}{d\dot{q}} \right] - \frac{dK(q, \dot{q})}{dq} + \frac{dP(q)}{dq}
 \end{aligned} \tag{3.3}$$

Burada ilk terim ivme, ikinci terim coriolis (yan kuvvet), üçüncü terim ise yer çekimi etkisini ifade etmektedir.

Çizgisel ve rotasyonel hızdan dolayı oluşan kinetik enerji:

$$K = \frac{1}{2} m v^T v + \frac{1}{2} \omega^T I \omega \quad I : \text{eylemsizlik tensörü} \tag{3.4}$$

Kinetik enerjinin 4 serbestlik derecesi için yazılmasında Jacobian matrisi kullanılır.

$$\begin{aligned}
 K(\theta, \dot{\theta}) &= \dot{\theta}^T \left(\frac{1}{2} m J_v(\theta)^T J_v(\theta) \right. \\
 &+ \left. \frac{1}{2} J_w(\theta)^T R(\theta) I R(\theta)^T J_w(\theta) \right) \dot{\theta}
 \end{aligned} \tag{3.5}$$

J_v : Çizgisel hızlar için Jacobian matrisi

J_w : Rotasyonel hızlar için Jacobian matrisi

I : Eylemsizlik tensörü R : Rotasyon matrisi

Jacobian matrisi, her bir eklem için ayrı olarak eklem kütle merkezine göre hesaplanır.

Potansiyel enerji denklemi eklem konumuna bağlı olarak yazılır.

$$P = m \cdot g \cdot h(\theta) \tag{3.6}$$

Euler-Lagrange denkleminde enerji ifadeleri yerine konulduğunda Denklem 3.7 elde edilir.

$$\tau = D(\theta) \cdot \ddot{\theta} + C(\theta, \dot{\theta}) \cdot \dot{\theta} + G(\theta) \quad (3.7)$$

Denklemden kullanılan matrisler:

$$D(\theta) = \frac{1}{2} m J_V(\theta)^T J_V(\theta) + \frac{1}{2} J_W(\theta)^T R(\theta) I R(\theta)^T J_W(\theta) \quad (3.8)$$

Eklem silindirik olarak düşünüldüğünde her eklem için eylemsizlik tensörü I aşağıdaki gibi elde edilir.

$$I = \begin{bmatrix} \left(\frac{m}{12}\right) * (l_h^2 + l^2) & 0 & 0 \\ 0 & \left(\frac{m}{12}\right) * (l_h^2 + l_w^2) & 0 \\ 0 & 0 & \left(\frac{m}{12}\right) * (l^2 + l_w^2) \end{bmatrix} \quad (3.9)$$

Rotasyon matrisi ilk eklem için:

$$R = \begin{bmatrix} \cos(\theta) & 0 & \sin(\theta) \\ \sin(\theta) & 0 & -\cos(\theta) \\ 0 & 1 & 0 \end{bmatrix} \quad (3.10)$$

Diğer eklemler için:

$$R = \begin{bmatrix} \cos(\theta) & -\sin(\theta) & 0 \\ \sin(\theta) & \cos(\theta) & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.11)$$

$C(\theta, \dot{\theta})$. Coriolis terimi $M(\theta)$ matrisinden yola çıkılarak hesaplanmaktadır.

$$c_{ijk} = \frac{1}{2} \left(\frac{d D_{kj}}{d \theta_i} + \frac{d D_{ki}}{d \theta_j} - \frac{d D_{ij}}{d \theta_k} \right) c_{kj} = \sum_{i=1}^n c_{ijk} \dot{q}_i \quad (3.12)$$

$G(\theta)$ yerçekimi terimi potansiyel enerjinin değişimini ifade eder.

$$G(\theta) = \frac{dP(\theta)}{d\theta} = \frac{d(m.g.h(\theta)')}{d\theta} \quad (3.13)$$

Model oluşturulurken uygulama örneği olarak kullanılan uArm Swift Pro robot kol Şekil 3.1 de görülmektedir.



Şekil 3.1 : uArm Swift Pro robot kol [34].

Benzetimlerde kullanılan robot kol ölçüleri gerçek değerler ile uyumludur. Manipülatöre ait Denavit-Hartenbeg parametreleri Çizelge 3.1 deki gibi belirlenmiştir [35].


Çizelge 3.1 : Denavit-Hartenberg parametreleri.

Eklem	a_i	α_i	d_i	θ_i
1	0.0132 m	0	0	θ_1
2	0.142 m	0	0	θ_2
3	0.159 m	0	0	θ_3
4	0	4.71 rad	0.107m	θ_4

Dört eklem açısının sınır değerleri Denklem 3.14 teki gibidir.

$$\begin{aligned}
 -90^\circ &< \theta_1 < 90^\circ \\
 0^\circ &< \theta_2 < 145^\circ \\
 0^\circ &< \theta_3 < 120^\circ \\
 0^\circ &< \theta_4 < 150^\circ
 \end{aligned}
 \tag{3.14}$$

Bu sınır açısı değerleri taranarak dinamik model ile beraber eğitim verisi olarak kullanılmak üzere Şekil 3.2 de gösterilen çalışma uzayı oluşturulmuştur.




Şekil 3.2 : Robot çalışma uzayı – pozisyon (m).


3.2 Destek Vektör Makinası Modelinin Eğitilmesi

Destek vektör makinası modeli eğitilirken her eklem için ayrı bir model oluşturulmuştur. Bu modellerde giriş değeri eklem açısı değerleri, çıkış değeri de ilgili eklemin tork değeri olacak şekilde seçilmiştir.


Çalışma uzayındaki veriler kullanılırken; verilerin %66'sı eğitimde kullanılıp, %33'ü test verisi olarak ayrılmıştır. Model başarımlar oranları test verisi üzerinden denenmiştir. Şekil 3.3,3.4,3.5 ve 3.6 da bulunan tahmin ve test verisi grafiklerine ortalama karesel hata ve modelin kararlılığını ölçen r^2 parametresi eklenmiştir. Hata değerlerinin kabul edilebilir düzeyde ve kararlılık faktörünün 1'e yakın olduğu görülmüştür.




Şekil 3.3 : DVR model test verisi- eklem açısı 1.



Şekil 3.4 : DVR model test verisi- eklem açısı 2.



Şekil 3.5 : DVR model test verisi- eklem açısı 3.



Şekil 3.6 : DVR model test verisi- eklem açısı 4.

Her bir eklem için oluşturulan destek vektör makinası modelinde C çekirdek fonksiyonu yarıçapı, epsilon maksimum sınıflandırma hatası değeri ve gama öğrenme katsayısı parametreleri farklı değerler içinde çizgi arama metodu ile taranarak; model tahminlerdeki ortalama karesel hatayı minimize edecek şekilde optimum değerler seçilmiştir [36]. Tarama aralıkları ve optimum değerler aşağıdaki gibidir.

$$100 < C < 1000 : 100$$

$$0,001 < \epsilon < 0,01 : 0,001$$

$$0,1 < \gamma < 1 : 0,001$$

$$\text{Eklem 1: } C = 700, \epsilon = 0,009, \gamma = 0,28 \quad (3.15)$$

$$\text{Eklem 2: } C = 900, \epsilon = 0,009, \gamma = 0,28$$

$$\text{Eklem 3: } C = 900, \epsilon = 0,009, \gamma = 0,54$$

$$\text{Eklem 4: } C = 900, \epsilon = 0,009, \gamma = 0,98$$


4. DVM TABANLI UYARLAMALI MODEL ÖNGÖRÜLÜ KONTROLÖR TASARIMI

DVM modeli tabanlı kontrolör tasarımı, doğrusal olmayan destek vektör regresyonu ile üçüncü bölümde tahmin edilen sistem dinamik modeli kontrolör parametrelerinin uyarlanması için kullanılmaktadır.

Denklemlerde $y(n)$ sistemin çıkışı, $u(n)$ kontrol işareti, $r(n)$ referans işareti, $e(n)$ izleme hatası, $\check{e}(n)$ modelleme hatasıdır. Modelleme ve referans izleme hataları Denklem 4.1 de belirtilmiştir [37].

$$e(n) = r(n) - y(n), \check{e}(n) = y(n) - \hat{y}(n) \quad (4.1)$$

Uyarlamalı PID kontrolör yapısı üç ayrı bölümden oluşur. Bu bölümler DVR dinamik modeli, PID kontrolör ve PID kontrolör parametre uyarlayıcısıdır. Şekil 4.1 de denetleyici yapısı görülmektedir.



Şekil 4.1 : Destek vektör regresyonu tabanlı model kestirimli uyarlama mekanizması [10].


PID kontrolörde [38, 39, 40], K_p , K_d ve K_i sistemin davranışına bağlı olarak uyarlanması gereken kontrolör parametrelerdir.

$$u_{n+1} = u_n + K_p (e_n - e_{n-1}) + K_i e_n + K_d (e_n - 2e_{n-1} + e_{n-2}) \quad (4.2)$$

PID kontrolörün girişleri aşağıdaki gibi tanımlanabilir.

$$xc(1) = e(n) - e(n-1), xc(2) = e(n), xc(3) = (e_n - 2e_{n-1} + e_{n-2}) \quad (4.3)$$

Kontrolör parametreleri başlangıç anında optimal değerlerde değildir ve optimizasyon teorisi kullanılarak uygun bir şekilde uyarlama mekanizması kullanılmaktadır. DVM modeli çıkışı ile sistem çıkışı arasındaki hata; parametre uyarlama mekanizmasına girişi oluşturur. Kestirilen DVM modelin uyarlama yapısındaki yeri Şekil 4.2 de görülmektedir.



Şekil 4.2 : En küçük kareler destek vektör makinası tabanlı uyarlamalı PID yapısı [23].

Gradyan iniş metodu kontrol parametrelerini optimal değerlere uyarlamak için kullanılır.

$$J(n) = \frac{[r(n) - y(n)]^2}{2} = \frac{1}{2} e^2(n) \quad (4.4)$$

Kontrolör parametrelerini optimize etmek için Denklem 4.5 teki kurallar uygulanır.

$$\begin{aligned} \Delta K_p(n) &= -\eta(n) \frac{\partial J(n)}{\partial e(n)} \frac{\partial e(n)}{\partial y(n)} \frac{\partial y(n)}{\partial u(n)} \frac{\partial u(n)}{\partial K_p(n)} \\ \Delta K_i(n) &= -\eta(n) \frac{\partial J(n)}{\partial e(n)} \frac{\partial e(n)}{\partial y(n)} \frac{\partial y(n)}{\partial u(n)} \frac{\partial u(n)}{\partial K_i(n)} \\ \Delta K_d(n) &= -\eta(n) \frac{\partial J(n)}{\partial e(n)} \frac{\partial e(n)}{\partial y(n)} \frac{\partial y(n)}{\partial u(n)} \frac{\partial u(n)}{\partial K_d(n)} \end{aligned} \quad (4.5)$$

Burada $-\eta(n)$ öğrenme oranıdır. Eklemlerin Jakobiyeen bilgileri kontrolör parametrelerinin güncellemesinde kullanılır. Sistemin Jakobiyeen bilgisi Denklem 4.6 daki gibi elde edilir.

$$\frac{\partial y(n)}{\partial u(n)} \cong \frac{\partial \check{y}(n)}{\partial u(n)}$$

$$\frac{\partial \check{y}(n)}{\partial u(n)} = - \sum_{i=n-L}^K \frac{\alpha_i(n)(u(n) - x_{svi}(1))K(x_c(n), x_{svi}(n))}{\sigma(n)^2} \quad (4.6)$$

K : Çekirdek fonksiyonu

$\sigma(n)^2$ = Çekirdek fonksiyonu yarıçapı

Kontrolör parametreleri denklem 4.7 deki gibi uyarlanır.

$$K_p(n+1) = K_p(n) + \Delta K_p(n),$$

$$\Delta K_p(n) = -\eta(n)e(n) \frac{\partial y(n)}{\partial u(n)} xc(1)$$


$$K_i(n+1) = K_i(n) + \Delta K_i(n),$$

$$\Delta K_d(n) = -\eta(n)e(n) \frac{\partial y(n)}{\partial u(n)} xc(2) \quad (4.7)$$

$$K_d(n+1) = K_d(n) + \Delta K_d(n),$$

$$\Delta K_i(n) = -\eta(n)e(n) \frac{\partial y(n)}{\partial u(n)} xc(3)$$

$\sigma(n)^2$ ve $\eta(n)$ değerleri destek vektör makinası modelindeki çekirdek fonksiyonu yarıçapı ve uyarlama parametresinden alınarak belirlenmiştir. PID kontrolör parametre güncelleme algoritması Şekil 4.3 de görülmektedir.




Şekil 4.3 : Uyarlama mekanizması parametre güncelleme algoritması.

Sistemi benzetimini oluşturmak amacıyla kontrol yapısı oluşturulduktan sonra sistem olarak dört eksenli robot manipülatörünün ters dinamik modeli kullanılarak kontrolör çıkışında uygulanan tork değerlerine göre eklem açısal pozisyonları bulunmuştur. İstenen bir tork değerine karşılık eklemlerin ivme değerleri Euler-Lagrange denklemi yardımıyla bulunabilir [42].

$$\tau = D(\theta) \cdot \ddot{\theta} + C(\theta, \dot{\theta}) + G(\theta)$$

$$D(\theta) \cdot \ddot{\theta} = \tau - C(\theta, \dot{\theta}) - G(\theta) \quad (4.8)$$

$$\ddot{\theta} = D^{-1}(\theta) \cdot (\tau - C(\theta, \dot{\theta}) - G(\theta))$$



5. DENETLEYİCİ PERFORMANSININ İNCELENMESİ


Tasarım süreci önceki bölümlerde anlatılan DVM tabanlı uyarlamalı PID kontrolör yapısının performans karşılaştırması için sabit katsayılı klasik PID kontrolör kullanılmıştır. PID katsayıları belirlenirken Ziegler-Nichols yöntemi kullanılmıştır [43]. Bu yöntemle göre her bir eklem için ileri dinamik denklemlerden yola çıkılarak sabit bir tork değeri girişi için açılı çıkışı hesaplanmış ve basamak cevabı zaman sabitleri kullanılarak PID kontrolör katsayıları Denklem 5.1 deki gibi belirlenmiştir.

$$\begin{aligned} Kp: K_{p_1} &= 0.07; K_{p_2} = 3.43; K_{p_3} = 1.35; K_{p_4} = 1.35; \\ Ki: K_{i_1} &= 7.00; K_{i_2} = 7.00; K_{i_3} = 61.00; K_{i_4} = 6.35; \\ Kd: K_{d_1} &= 18.00; K_{d_2} = 18.00; K_{d_3} = 55.86; K_{d_4} = 0.34; \end{aligned} \quad (5.1)$$

5.1 Yüksüz Durumda Yörünge Takip Kontrolü Performans Karşılaştırması


5.1.1 Basit yörünge uygulaması

Destek vektör makinası tabanlı model kestirici uyarlamalı kontrol yapısı ve sabit katsayılı PID kontrolör performans karşılaştırması için, dört eksenli robot kolunun çalışma uzayı içerisinde kalan noktalardan geçecek şekilde öncelikle yay çizecek şekilde basit bir yörünge oluşturulmuştur. Oluşturulan yörünge üç boyutlu uzayda temsili Şekil 5.1 de görülmektedir.




Şekil 5.1 : Basit referans yörünge.


Referans yörünge koordinatları alınarak, ters kinematik model aracılığı ile referans eklem açısı değerleri oluşturulmuştur. Çıkış eklem açısı değerleri ileri kinematik model ile çıkış Kartezyen koordinatlarına çevrilmiştir. Referans ve çıkış kartezyen koordinat değerleri Şekil 5.2, 5.3 ve 5.4 de görülmektedir.



Şekil 5.2 : Basit yörünge için x eksen referans ve çıkış pozisyon değerleri.




Şekil 5.3 : Basit yörünge için y eksenini referans ve çıkış pozisyon değerleri.



Şekil 5.4 : Basit yörünge için z eksenini referans ve çıkış pozisyon değerleri.

DVM tabanlı uyarlamalı PID çıkış ve referansın kartezyen koordinatlarında üç boyutlu yörünge gösterimi Şekil 5.5 de görülebilir. X,Y ve Z eksenlerinde yörünge takip kontrolü başarımları incelendiğinde DVM Tabanlı uyarlamalı PID kontrolörün sürekli halde izleme hatasının daha düşük olduğu görülmektedir.




Şekil 5.5 : Basit yörünge için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.

5.1.2 Karmaşık yörünge uygulaması

Performans karşılaştırması için, karmaşık bir yörüngede takip kontrolünü gerçekleştirmek adına yine dört eksenli robot kolunun çalışma uzayı içerisinde kalan noktalardan geçecek şekilde sinüs ve kosinüs fonksiyonlarından oluşan bir yörünge oluşturulmuştur. Yörünge fonksiyonu aşağıdaki gibidir.


$$\begin{aligned}
 t &< 2 * \pi \text{ olmak üzere;} \\
 scale &= 2 / (3 - \cos(2 * t)); \\
 x &= scale * \cos(t); \\
 y &= (scale * \sin(2 * t) / 2); \\
 z &= (\sin(2 * t))
 \end{aligned} \tag{4.1}$$

Belirlenen geçiş noktalarına göre referans yörünge Şekil 5.6 da gösterilmiştir.




Şekil 5.6 : Karmaşık referans yörünge.


Referans ve çıkış kartezyen koordinat değerleri Şekil 5.7, 5.8ve 5.9 da görülmektedir.DVM tabanlı uyarlamalı PID kontrol yapısının üç ekseninde de klasik yapıya göre daha hassas konum takibini sağladığı görülmektedir.



Şekil 5.7 : Karmaşık yörünge için x ekseni referans ve çıkış pozisyon değerleri.




Şekil 5.8 : Karmaşık yörünge için y eksenli referans ve çıkış pozisyon değerleri.



Şekil 5.9 : Karmaşık yörünge için z eksenli referans ve çıkış pozisyon değerleri.

DVM tabanlı uyarlamalı PID çıkış ve referansın kartezyen koordinatlarında üç boyutlu yörünge gösterimi Şekil 5.10 da görülebilir.



Şekil 5.10 : Karmaşık yörünge için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.

Basit ve karmaşık yörüngelerde yüksüz durum için yörünge takip performansı Çizelge 5.1 de gösterilmiştir. Yüksüz durum için yörünge izleme hataları RMS değerleri incelendiğinde her iki yörünge için de özellikle hassas yörünge takibi konusunda klasik PID yapısına göre DVM Tabanlı uyarlamalı PID kontrolörün başarılı bir performans sergilediği görülmektedir.

Çizelge 5.1 : Yüksüz durum yörünge takip performansları karşılaştırması.

	Basit Yörünge		Karmaşık Yörünge	
	PID	DVM Tabanlı Uyarlamalı PID	PID	DVM Tabanlı Uyarlamalı PID
RMS X(m)	0,0027	0,0005	0,0037	0,0015
RMS Y(m)	0,0065	0,0021	0,0105	0,0039
RMS Z(m)	0,0026	0,0011	0,0045	0,0016

5.2 Yüksüz Durumda Geçici Hal Performansı Karşılaştırması

Kartezyen koordinatlara etki eden üç eklem için basamak fonksiyonu referans girişine göre yüzde aşım miktarı, yükselme ve yerleşme zamanları karşılaştırılmıştır. Değerler Çizelge 5.2 de görülebilir.


Çizelge 5.2 : Yüksüz durum PID performansları karşılaştırması.

1.Eklem	PID	DVM Tabanlı Uyarlamalı PID
%0S	5,75	4,62
Tr(sn)	0,30	0,12
Ts(sn)	6,32	3,00


2.Eklem	PID	DVM Tabanlı Uyarlamalı PID
%0S	0,0006	0,00
Tr(sn)	5,58	2,70
Ts(sn)	12,06	5,80

3.Eklem	PID	DVM Tabanlı Uyarlamalı PID
%0S	0,006	0,00
Tr(sn)	8,94	4,34
Ts(sn)	12,78	6,18


Referans ve çıkış eklem açıları Şekil 5.11, 5.12 ve 5.13 dedir. Geçici hal performans parametreleri açısından iki kontrolör yapısı yüksüz durumda karşılaştırıldığında, DVM tabanlı uyarlamalı kontrolün verilen referansa göre yükselme ve yerleşme zamanının yeterli seviyede olduğu görülmektedir.



Şekil 5.11 : Yüksüz Durum için 1.eklem referans ve çıkış açı değerleri.



Şekil 5.12 : Yüksüz durum için 2.eklem referans ve çıkış açı değerleri.




Şekil 5.13 : Yüksüz durum için 3.eklem referans ve çıkış açı değerleri.

5.3 Yk Altında Yrnge Takip Kontrol Performans Karşılařtırması

U iřlevciye uygulanan zamana baėlı ve yerekimi ynndeki yk etkisi, ileri dinamik denklemler aracılıėı ile diėer eklemlere aktarılmıřtır [40] . Uygulanan maks. 6 N'a ulařan yk profilleri hafif yapılı (1,2 kg) ve 4 eksenli robot kol iin anlamlı bir yk oluřturmaktadır. Bu yk performansları ile hafif yapılı cerrahi robotlarda uygulanan yke bir rnek teřkil etmektedir [44,45].


5.3.1 Ani yk deėiřimi uygulaması

Blm 5.1.2'de belirlenen referans karmařık yrnge zerinde řekil 5.14'de grlen anlık deėiřen yk profili uygulanmıřtır [46].




řekil 5.14 : Ani yk deėiřimi iin u iřlevciye uygulanan yk.


Referans ve ıkıř Kartezyen koordinat deėerleri řekil 5.15, 5.16 ve 5.17 de gzlmektedir.



Şekil 5.15 : Ani yük değişimi için için x eksen referans ve çıkış pozisyon değerleri.




Şekil 5.16 : Ani yük değişimi için için y eksen referans ve çıkış pozisyon değerleri.



Şekil 5.17 : Ani yük değişimi için için z eksen referans ve çıkış pozisyon değerleri.


DVM tabanlı uyarlamalı PID çıkış ve referansın kartezyen koordinatlarında üç boyutlu yörünge gösterimi Şekil 5.18 de görülebilir. Ani yük değişimi sonrası referans yörüngeyi takip etme performansları karşılaştırıldığında önerilen DVM tabanlı uyarlamalı PID kontrolör yük etkisini daha kısa sürede kompozne etmektedir.




Şekil 5.18 : Ani yük değişimi için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.

5.3.2 Anahtarlama yük değişimi uygulaması

Anahtarlama yük değişimini simüle etmek için yük alma ve bırakma noktaları belirlenerek Şekil 5.19 daki yörünge oluşturulmuştur. Referans yörünge üzerinde Şekil 5.20 de görülen anahtarlama yük değişimi profili uygulanmıştır [47].




Şekil 5.19 : Anahtarlama yük değişimi için referans yörünge.




Şekil 5.20 : Anahtarlama yük değişimi için uç işlevciye uygulanan yük.


Referans ve çıkış Kartezyen koordinat değerleri Şekil 5.21, 5.22 ve 5.23 de görülmektedir. DVM tabanlı uyarlamalı PID kontrol yapısının üç eksende yük değişimi durumlarında da klasik yapıya göre daha hassas konum takibini sağladığı görülmektedir.



Şekil 5.21 : Anahtarlamalı yük değişimi için x eksen referans ve çıkış pozisyon değerleri.




Şekil 5.22 : Anahtarlamalı yük değişimi için y eksen referans ve çıkış pozisyon değerleri.



Şekil 5.23 : anahtarlama yük değişimi için z eksen referans ve çıkış pozisyon değerleri.


DVM tabanlı uyarlamalı PID çıkış ve referansın kartezyen koordinatlarında üç boyutlu yörünge gösterimi Şekil 5.24 de görülebilir. Anahtarlama yük uygulamasında DVM tabanlı uyarlamalı kontrol yönteminin yük değişimlerine karşı hassasiyetinin klasik kontrol yöntemine göre daha iyi olduğu görülmektedir.




Şekil 5.24 : Anahtarlama yük değişimi için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.

5.3.3 Zamanla azalan yük uygulaması


Bölüm 5.1.2 de belirlenen referans karmaşık yörünge üzerinde Şekil 5.25 de görülen zamanla azalan yük profili uygulanmıştır. Referans ve çıkış Kartezyen koordinat değerleri Şekil 5.26, 5.27 ve 5.28 de görülmektedir. Üç eksen ayrı ayrı incelendiğinde yük etkisinin artmasıyla DVM tabanlı uyarlamalı kontrol yapısının konum takip performansındaki etkisinin arttığı görülmektedir.




Şekil 5.25 : Zamanla azalan yük için uç işlevciye uygulanan yük.



Şekil 5.26 : Zamanla azalan yük değişimi için x eksen referans ve çıkış pozisyon değerleri.




Şekil 5.27 : Zamanla azalan yük değişimi için y eksenli referans ve çıkış pozisyon değerleri.



Şekil 5.28 : Zamanla azalan yük değişimi için z eksenli referans ve çıkış pozisyon değerleri.

DVM tabanlı uyarlamalı PID çıkış ve referansın kartezyen koordinatlarında üç boyutlu yörünge gösterimi Şekil 5.29 da görülebilir. Destek Vektör Makinası tabanlı uyarlamalı kontrol yönteminin karmaşık bir yörüngede ve zamanla azalan yük

karşısında sabit katsayılı klasik PID yapısına göre kartezyen koordinatlarda yörünge izleme performansının başarılı olduğu görülmüştür. Yük etkisi arttıkça önerilen kontrol yapısının performansı artmaktadır. Üç farklı yük profili altında yörünge takip performansı Çizelge 5.3'dir.



Şekil 5.29 : Zamanla azalan yük için referans ve çıkış yörüngeleri kartezyen koordinat gösterimi.

Çizelge 5.3 : Yük altında yörünge takip performansları karşılaştırması.

	Ani Değişen Yük Profili		Anahtarlama Yüklü Profili		Zamanla Azalan Yük Profili	
	DVM Tabanlı Uyarlamalı		DVM Tabanlı Uyarlamalı		DVM Tabanlı Uyarlamalı	
	PID	PID	PID	PID	PID	PID
RMS X(m)	0,0101	0,0014	0,0031	0,0004	0,0103	0,0011
RMS Y(m)	0,0211	0,0050	0,0052	0,0015	0,0221	0,0035
RMS Z(m)	0,0133	0,0016	0,0033	0,0005	0,0142	0,0012


5.4 Zamanla Azalan Yük Altında Geçici Hal Performansı Karşılaştırması

Kartezyen koordinatlara etki eden 3 eklem için basamak fonksiyonu referans girişine göre yük altında yüzde aşım miktarı, yükselme ve yerleşme zamanları karşılaştırılmıştır. Değerler Çizelge 5.4 de görülebilir. Yük profili olarak Bölüm 5.3.2 deki zamanla azalan yük uygulanmıştır.


Çizelge 5.4 : Yük altında PID performansları karşılaştırması.

1.Eklem	PID	DVM Tabanlı Uyarlamalı PID
%0S	4,04	5,48
Tr(sn)	0,62	0,12
Ts(sn)	8,6	2,08
2.Eklem	PID	DVM Tabanlı Uyarlamalı PID
%0S	0,08	0,18
Tr(sn)	16,56	1,76
Ts(sn)	31,90	3,76
3.Eklem	PID	DVM Tabanlı Uyarlamalı PID
%0S	0,24	0,58
Tr(sn)	22,34	2,60
Ts(sn)	30,74	3,76


Referans ve çıkış eklem açıları Şekil 5.30, 5.31 ve 5.32 dedir. Yük altında geçici hal performans parametreleri açısından iki kontrolör yapısı karşılaştırıldığında, DVM tabanlı uyarlamalı kontrolör uygulandığında verilen referansa göre yükselme ve yerleşme zamanı ile birlikte sürekli hal hatasının da büyük oranda iyileştiği görülmektedir.



Şekil 5.30 : Yük altında 1.eklem referans ve çıkış açı değerleri.



Şekil 5.31 : Yük altında 2.eklem referans ve çıkış açı değerleri.



Şekil 5.32 : Yük altında 3.eklem referans ve çıkış açı değerleri.

6. SONUÇ VE ÖNERİLER

Bu tez çalışması kapsamında, robotik kolların destek vektör makinesi tabanlı uyarlamalı model öngörülü kontrolü sağlanmıştır. Önerilen destek vektör makinesi tabanlı uyarlamalı kontrol yönteminin basit ve karmaşık farklı yörüngelerde ve özellikle zamanla değişen yük karşısında sabit katsayılı klasik PID yapısına göre kartezyen koordinatlarda yörünge izleme performansının %10-14 oranında daha başarılı olduğu görülmüştür. Yük etkisinin fazla olduğu yerlerde önerilen kontrol yönteminin yörünge izleme performansı artmaktadır. Ayrıca geçici hal performans parametreleri açısından karşılaştırıldığında, DVM tabanlı uyarlamalı kontrolün verilen referansa göre yükselme ve yerleşme zamanının yeterli seviyede olduğu görülmüştür. Destek vektör makinesi modelindeki hiper parametrelerin eğitim verilerinin ezberlenmesinden çok öğrenilmesi doğrultusunda optimize edilmesi, model tahminlerindeki doğruluk oranını arttırdığından model tabanlı uyarlamalı PID kontrolör performansında büyük oranda iyileşme sağlanmıştır.

Tezde ilk olarak; DVR yöntemi yardımıyla çevrimdışı uyarlamayı sağlayacak robot kol dinamik modeli oluşturulmuştur. Elde edilen bu model, uyarlama yapısının ana unsuru olan referans modeli oluşturmaktadır. Bozucu etki altında da konum izleme hatasının korunması, bu model tabanlı uyarlama mekanizmasının yüke göre optimum kontrol çıkışı vermesi ile sağlanmaktadır.

Robot kol yörünge takip kontrolünü sağlayan PID denetleyicinin parametreleri; gerçek sistem ve DVR modeli cevabı arasındaki hatayı optimize edecek şekilde uyarlanmaktadır. Tahmin edilen modelin başarısına göre yörünge izleme performansını artmaktadır. Eğitim verilerinin kapsamı ve uygulanan DVR tahminleyicisinin parametreleri model başarısını etkilemekte ve dolaylı yoldan robot kol denetleyicisinin performansını oluşturmaktadır.

Tezde önerilen DVM ile uyarlamalı model öngörülü kontrol yapısı aşağıdaki özellikleri sayesinde robot kollarda pozisyonlama probleminde çözüm sunar.

- Model tabanlı uyarlama mekanizması farklı profillerdeki yük etkisi gibi bozucu etkiler altında, referans konum izleme performansının aynı başarıda devam ettirilmesini sağlar.
- DVR yöntemi ile modelleme hataları minimize edilerek uyarlama mekanizmasının hassas çalışması sağlanır.
- DVM ile uyarlamalı model öngörülü denetleyici yapısının beraber kullanılması, yörünge izlemede keskin ve hassas kontrolü sağlar.

Öğretilmiş destek vektör makinası modeli ile uyarlanan PID kontrolör yapısı, tıbbi uygulamalarda kullanılan hafif yapılı robotların yük altında hassas pozisyonlama problemi karşısında iyi bir yörünge izleme performansı oluşturacağı değerlendirilmiştir. Eğitim verisinin çeşitli senaryolarda genişletilerek yörünge takip performansının artırılması gelecek çalışmaların konusu olacaktır. Ayrıca çevrimiçi uyarlama kullanılarak; öğretilen model dışındaki yörünge noktalarında da hassas pozisyon takibi sağlanabilir.

KAYNAKLAR

- [1] **Kerhet, A., Raffetto, M., Boni A., ve Massa A.** (2006). A SVM-Based Approach to Microwave Breast Cancer Detection, *Engineering Applications of Artificial Intelligence* 19, no. 7 (807–18, doi:10.1016/j.engappai.2006.05.010.
- [2] **Furey, T., Cristianni, N., Duffy, N., Bednarski, D., Schummer, M. Ve Haussler D.** (2000). Support vector machine classification and validation of cancer tissue samples using microarray expression data. 16, no. 10 : 906–14.
- [3] **Chitralkha, S., ve Sirish, L.** (2010). Application of Support Vector Regression for Developing Soft Sensors for Nonlinear Processes,” *The Canadian Journal of Chemical Engineering* 88, no. October (August 04, 2010): n/a – n/a, doi:10.1002/cjce.20363.
- [4] **Campbell, W., Sturim, D., ve Reynolds D.** (2006). Support Vector Machines Using GMM Supervectors for Speaker Verification. 13, no. 5 (2006): 308–11.
- [5] **Sastry, S., ve Budson, M.**(1989).Adaptive control stability, converge and robustness, Printince Hall Press.
- [6] **Xin, L., Wang, Q., She, J., ve Li, Y.** (2016). Robust adaptive tracking control of wheeled mobile robot, *Robotics and Autonomous Systems*.
- [7] **Mohareri, O., Dhaouadi, R., ve Rad, A.** (2012). Indirect adaptive control of a nonholonomic mobile robot via neural networks , *Neurocomputing*.
- [8] **Chen, M., Ge, S., ve Ren, B.** (2011). Adaptive tracking control of uncertain MIMO nonlinear systems with input constraints, *Automatica*.
- [9] **Jongho, S., Jin, K., Sewook, P., ve Youdan, K.** (2009). Model Predictive Flight Control Using Adaptive Support Vector Regression. *Neurocomputing* 73, no. 4–6:1031–37, doi:10.1016/j.neucom.2009.10.002.
- [10] **Iplikci, S.** (2009). Controlling the Experimental Three-Tank System via Support Vector Machines, 391–400.
- [11] **Turhan, K., ve Serdar, B.** (2013).Support Vector Machines in Wood Identification : The Case of Three Salix Species from Turkey, 249–56, doi:10.3906/tar-1205-47.

- [12] **Hao, Z., Ya Jie, Z., ve Yan Gu, Z.** (2014). Robust Control Method Based on Machine Learning for Boiler Combustion System, *Applied Mechanics and Materials* 685 :368–72, doi:10.4028/www.scientific.net/AMM.685.368.
- [13] **Huang, A., ve Wang, Y.** (2014). Pressure Model of Control Valve Based on LS-SVM with the Fruit Fly Algorithm. *Algorithms* 7, no. 3: 363–75, doi:10.3390/a7030363.
- [14] **Liu, G., Chen, L., Zhao, W., Jiang, Y., ve Qu, L.** (2013). Synchronous Motor Using Support Vector Machine Generalized Inverse.9, no. 2: 890–98.
- [15] **Jian Hua, C.** (2014). Fault Diagnosis for Electrical Control System of Automobile Based on Support Vector Machine. *Applied Mechanics and Materials* 666: 203–7, doi:10.4028/www.scientific.net/AMM.666.203.
- [16] **Antonio, M., Mahmoud T., ve Leopoldo A.** (2013). Solving the Forward Kinematics Problem in Parallel Robots Using Support Vector Regression Engineering Applications of Artificial Intelligence 26, no. 7:1698–1706, doi:10.1016/j.engappai.2013.03.011.
- [17] **Sarıyıldız, E., Uçak, K., Öke G., Temeltaş, H., ve Kouhei, O.** (2012). Support Vector Regression Based Inverse Kinematic Modeling for a 7-DOF Redundant Robot Arm. 2012 International Symposium on Innovations in Intelligent Systems and Applications,1–5, doi:10.1109/INISTA.2012.6247033.
- [18] **Sarıyıldız, E., Uçak, K., Öke G., Temeltaş, H., ve Kouhei, O.** (2013) Intelligent Systems Based Solutions for the Kinematics Problem of the Industrial Robot Arms,” 2013 9th Asian Control Conference (ASCC), June 2013, 1–6, doi:10.1109/ASCC.2013.6606306.
- [19] **Gireesh Kumar, T., Poornaselvan, K., ve Sethumadhavan, M.** (2010). Fuzzy Support Vector Machine-Based Multi-Agent Optimal Path Planning Approach to Robotics Environment” 60, no. 4:387–91.
- [20] **Hirayama, M., Tanaka, K., Okada, N., ve Kondo, E.** (2004) .Vision-Based Self-Localization in Non-Stationary Environments by Using Support Vector Machines. *IEEE Conference on Cybernetics and Intelligent Systems*, 123–28, doi:10.1109/ICCIS.2004.1460398.
- [21] **Zhao, J., Li, P., ve Wang, X.**(2009).Intelligent PID Controller Design with Adaptive Criterion Adjustment ,Chinese Control and Decision Conference.
- [22] **Gu, Y.,Zhao, W., ve Wu, Z.** (2011).Online Adaptive Least Square Support Vector Machine and its Application in Utility Boiler Combustion Optimizations Systems, *Journal of Process Control*.
- [23] **Mahmoud, T.,** (2011). Adaptive Control Scheme Based On The Least Squares Support Vector Machine Network, *Int. J. Appl. Math. Comput. Sci.*,Vol. 21, No. 4, 685–696.

- [24] **Wang, Z., Zhang, Z., ve Mao J.** (2012). Adaptive Tracking Control based on Online LS-SVM Identifier for Unknown Nonlinear System”, IEEE International Conference on Information Science and Technology.
- [25] **Zhu, D., Mei, T., ve Sun, L.** (2011). Fuzzy Support Vector Machines Control for 6-DOF Parallel Robot”, Journal Of Computers, Vol. 6, No. 9.
- [26] **Huang, X., Gao, H., Li, J., Mao, R. ve Wen J.** (2016). Adaptive Back-stepping Tracking Control of Robot Manipulators Considering Actuator Dynamic”, IEEE International Conference on Advanced Intelligent Mechatronics.
- [27] **Shin, J., Kim, H., ve Kim, Y.** (2011). Adaptive support vector regression for UAV flight control”, Neurol Networks.
- [28] **Farag, A., ve Mohamed, M.** (2004). Regression Using Support Vector Machines: Basic Foundations.
- [29] **Cortes, C., ve Vapnik, V.** (1995). Support-Vector Networks.
- [30] **Haykin, S.** (1999). Neural Networks: A Comprehensive Foudation, 2nd Edition.
- [31] **Smola, A., ve Schölkopf, B.** (2003). A tutorial on support vector regression.
- [32] **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
- [33] **Youngsma, K.** (2012). Development of a Model and Simulation Framework for a Modular Robotic Leg, Worcester Polytechnic Institute.
- [34] **Url-1** < <https://www.ufactory.cc/uarm>>, date retrieved 06.2016.
- [35] **Spong, M.W., Hutchinson, S., ve Vidyasagar, M.** (2006). Robot modeling and control, Chapter 3, s:75-93.
- [36] **Hou, L.K., ve 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.
- [37] **Shang, W., Zhao, S., ve 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.
- [38] **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.
- [39] **Luenberger, D.G., ve Ye, Y.** (2008). Linear and Nonlinear Programming Third Edition, Springer Science + Business Media, LLC.
- [40] **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, 2010.
- [41] **Uçak, K.** (2012). Destek Vektör Regresyonu İle Pid Kontrolör Tasarımı.

- [42] **Zhang, D., ve Wei, B.** (2016).Study on Payload Effects on the Joint MotionAccuracy of Serial Mechanical Mechanism. *Machines*. 4. 10.3390/machines4040021.
- [43] **Astrom, K., ve Hagglund, T.** (1995). *PID Controllers; Theory, Design and Tuning"*, Instrument Society of America, Research Triangle Park.
- [44] **Dong-Ho, L., Minho, H., Joonhwan, K. ve Dong-Soo, K.** (2020). Payload optimization of surgical instruments with rolling joint mechanisms. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Las Vegas, NV, USA.
- [45] **Jiahao, W., Yanshu, S., Hailin, H., Fei, L., Junan, C., ve Bing, L.**(2019). Design and Safety Control of a High-Payload Nursing Robotic Arm with Tactile Skin. *Proceeding of the IEEE International Conference on Robotics and Biomimetics Dali, Chi.*
- [46] **Yagiz, N., Hacıoglu, Y., ve Arslan Z.** (2010). Load transportation by dual arm robot using sliding mode control , *Journal of Mechanical Science and Technology* 24 (5) (2010) 1177,1184.
- [47] **Önkol, M., ve Kasnakoğlu C.** (2018). Adaptive Model Predictive Control of a Two-wheeled Robot Manipulator with Varying Mass , *Measurement and Control*, Vol. 51(1-2) 38–56.

ÖZGEÇMİŞ

Ad-Soyad : Sanem KILIÇASLAN

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** :2012, İstanbul Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Kontrol Mühendisliği
- **Yüksek Lisans** : 2015, İstanbul Teknik Üniversitesi , Mekatronik Mühendisliği Anabilim Dalı, Mekatronik Mühendisliği