T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DELTA PARALEL ROBOTLARIN YÖRÜNGE TAKİP KONTROLÜ İÇİN PEKİŞTİRMELİ ÖĞRENME İLE PID PARAMETRELERİNİN OPTİMİZASYONU

Hazırlayan
Oğuzhan KABAKULAK

Danışman
Dr. Öğr. Üyesi Sertaç SAVAŞ

Yüksek Lisans Tezi

Şubat 2026
KAYSERİ

T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DELTA PARALEL ROBOTLARIN YÖRÜNGE TAKİP KONTROLÜ İÇİN PEKİŞTİRMELİ ÖĞRENME İLE PID PARAMETRELERİNİN OPTİMİZASYONU

(Yüksek Lisans Tezi)

Hazırlayan
Oğuzhan KABAKULAK

Danışman
Dr. Öğr. Üyesi Sertaç SAVAŞ

Şubat 2026
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Oğuzhan KABAKULAK

“Delta Paralel Robotların Yörünge Takip Kontrolü için Pekiştirmeli Öğrenme ile PID Parametrelerinin Optimizasyonu” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan	**Danışman**
Oğuzhan KABAKULAK	Dr. Öğr. Üyesi Sertaç SAVAŞ
İmza	İmza

Mekatronik Mühendisliği ABD Başkanı

Prof. Dr. Şahin YILDIRIM

İmza

TEŞEKKÜR

“Delta Paralel Robotların Yörünge Takip Kontrolü için Pekiştirmeli Öğrenme ile PID Parametrelerinin Optimizasyonu” konulu tezin belirlenmesinde, yürütülmesinde ve sonuçlandırılmasında maddi manevi destek ve yardımlarda bulunan değerli danışman hocam Sayın Dr. Öğr. Üyesi Sertaç SAVAŞ’a teşekkür ederim.

Tez çalışması boyunca verdiği maddi, manevi destek ve gösterdiği anlayıştan dolayı nişanlım Esmanur ERCİYES’e, yine her daim yanımda olan annem ve babama teşekkür ederim.

Oğuzhan KABAKULAK

Şubat 2026, KAYSERİ

DELTA PARALEL ROBOTLARIN YÖRÜNGE TAKİP KONTROLÜ İÇİN PEKİŞTİRMELİ ÖĞRENME İLE PID PARAMETRELERİNİN OPTİMİZASYONU

Oğuzhan KABAKULAK

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Şubat 2026
Danışman: Dr. Öğr. Üyesi Sertaç SAVAŞ

ÖZET

Delta paralel robotlar, kapalı-zincirli paralel mimarileri sayesinde endüstride yüksek hız ve hassasiyet sunar; ancak bu yapı aynı zamanda doğrusal olmayan ve yörüngeye bağlı dinamikler doğurduğundan, kural-tabanlı klasik PID ayarları farklı yörüngelerde tutarlı performans veremeyebilir. Bu çalışmada, delta paralel robotların yörünge takip kontrolü için pekiştirmeli öğrenme tabanlı bir PID ayar yöntemi önerilmektedir. Derin Deterministik Politika Gradyanı (Deep Deterministic Policy Gradient – DDPG) algoritması kullanılarak PID kazançları (K_p, K_i, K_d) sürekli eylem uzayında önceden tanımlı sınırlar içerisinde optimize edilmekte ve böylece doğrusal olmayan ve yörüngeye bağlı dinamiklerde klasik kural-tabanlı ayarların sınırlılıklarının aşılması hedeflenmektedir. Önerilen DDPG-PID yöntemi; Ziegler–Nichols (ZN) ve Cohen–Coon (CC) ayar kuralları ile dört farklı referans yörünge (daire, lemniskat, elmas ve yıldız) üzerinde benzetim ortamında karşılaştırmalı olarak değerlendirilmiştir. Takip performansı RMSE, IAE, ISE, ITAE ve maksimum hata metrikleriyle nicel olarak ölçülmüştür. Sonuçlar, DDPG-PID'nin tüm yörüngelerde en düşük hatayı verdiğini; RMSE'yi ZN-PID'ye göre yaklaşık %35–58, CC-PID'ye göre ise yaklaşık %79–82 oranında azalttığını ve diğer metriklerde de belirgin iyileşmeler sağladığını göstermektedir. Genel olarak bu sonuçlar, önerilen yöntemin hem yumuşak eğrilikli hem de keskin köşeli yörüngelerde yüksek takip doğruluğu sağladığını ve delta robotlarda klasik kural-tabanlı yöntemlere uygulanabilir bir alternatif sunduğunu göstermektedir.

Anahtar Kelimeler: Delta paralel robot, PID ayarı, yörünge takip kontrolü, pekiştirmeli öğrenme, Derin Deterministik Politika Gradyanı (DDPG).

OPTIMIZATION OF PID PARAMETERS FOR TRAJECTORY TRACKING CONTROL OF DELTA PARALLEL ROBOTS USING REINFORCEMENT LEARNING

Oğuzhan KABAKULAK

Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, February 2026
Supervisor: Assist. Prof. Dr. Sertaç SAVAŞ

ABSTRACT

Delta parallel robots provide high speed and precision in industry thanks to their closed-chain parallel architectures; however, because this structure also gives rise to nonlinear and trajectory-dependent dynamics, classical rule-based PID tuning may not deliver consistent performance across different trajectories. This study proposes a reinforcement learning–based PID tuning method for trajectory tracking control of delta parallel robots. Using the Deep Deterministic Policy Gradient (DDPG) algorithm, the PID gains (K_p, K_i, K_d) are optimized within predefined bounds in a continuous action space, thereby aiming to overcome the limitations of classical rule-based tuning under nonlinear and trajectory-dependent dynamics. The proposed DDPG-PID method is comparatively evaluated against the Ziegler–Nichols (ZN) and Cohen–Coon (CC) tuning rules in a simulation environment on four reference trajectories (circle, lemniscate, diamond, and star). Tracking performance is quantitatively assessed using the RMSE, IAE, ISE, ITAE, and maximum error metrics. The results show that DDPG-PID yields the lowest error across all trajectories, reducing RMSE by approximately 35–58% compared with ZN-PID and by approximately 79–82% compared with CC-PID, while also providing significant improvements in the other metrics. Overall, these results indicate that the proposed method achieves high tracking accuracy on both smoothly curved and sharp-cornered trajectories and offers an applicable alternative to classical rule-based methods for delta robots.

Keywords: Delta parallel robot, PID tuning, trajectory tracking control, reinforcement learning, Deep Deterministic Policy Gradient (DDPG).

İÇİNDEKİLER

DELTA PARALEL ROBOTLARIN YÖRÜNGE TAKİP KONTROLÜ İÇİN PEKİŞTİRMELİ ÖĞRENME İLE PID PARAMETRELERİNİN OPTİMİZASYONU

BİLİMSEL ETİĞE UYGUNLUK ..... **ii**

YÖNERGEYE UYGUNLUK ..... **iii**

KABUL VE ONAY ..... **iv**

TEŞEKKÜR ..... **v**

ÖZET ..... **vi**

ABSTRACT ..... **vii**

İÇİNDEKİLER ..... **viii**

KISALTMALAR ..... **x**

TABLOLAR LİSTESİ ..... **xi**

ŞEKİLLER LİSTESİ ..... **xii**

GİRİŞ **1**

1. BÖLÜM

TEZİN AMACI VE LİTERATÜR ÇALIŞMASI

1.1. Tezin Amacı **3**

1.2. Literatür Çalışması **4**

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Delta Robotun Matematiksel Modeli **8**

2.2. PID Denetleyici ve Kazanç Ayarı **10**

2.2.1. Ziegler-Nichols Yöntemi 10

2.2.2. Cohen-Coon Yöntemi 11

2.2.3. Önerilen DDPG-PID Yöntemi 12

2.3. Bozucu Modelleri 14

2.4. Performans Metrikleri 15

2.5. Simülasyon Parametreleri 16

3. BÖLÜM

KONTROL ÇALIŞMALARI

3.1. Simülasyon Çalışmaları 18

3.2. Daire Yörünge Sonuçları 21

3.3. Lemniskat Yörünge Sonuçları 25

3.4. Elmas Yörünge Sonuçları 30

3.5. Yıldız Yörünge Sonuçları 34

3.6. Gerçek Çalışma Koşulları Altında Dayanıklılık (Robustluk) Analizi 39

4. BÖLÜM

SONUÇ VE ÖNERİLER

KAYNAKÇA 48

ÖZGEÇMİŞ 53

KISALTMALAR

PID	:	Proportional-Integral-Derivative – Oransal-İntegral-Türev
DDPG	:	Deep Deterministic Policy Gradient – Derin Deterministik Politika Gradyanı
ZN	:	Ziegler–Nichols
CC	:	Cohen–Coon
RMSE	:	Root Mean Squared Error – Kök Ortalama Kare Hata
IAE	:	Integral of Absolute Error – Mutlak Hatanın İntegrali
ISE	:	Integral of Squared Error – Hatanın Karesinin İntegrali
ITAE	:	Integral of Time-weighted Absolute Error – Zaman Ağırlıklı Mutlak Hatanın İntegrali
DOF	:	Degree of Freedom – Serbestlik Derecesi
3B	:	3 Boyutlu
RL	:	Reinforcement Learning – Pekiştirmeli Öğrenme
CTC	:	Computed Torque Control – Hesaplamalı Tork Kontrolü
CSPR	:	Cable Suspended Parallel Robot – Kablo Askılı Paralel Robot
SAC	:	Soft Actor-Critic – Yumuşak Aktör–Eleştirmen
ROS	:	Robot Operating System – Robot İşletim Sistemi
DRL	:	Deep Reinforcement Learning – Derin Pekiştirmeli Öğrenme
CDPR	:	Cable-Driven Parallel Robot – Kablo Tahrikli Paralel Robot
EFK	:	Efficient Forward Kinematics – Verimli İleri Kinematik
FOPDT	:	First-Order Plus Dead Time – Ölü Zamanlı Birinci Derece (Model)
Maks	:	Maksimum
Min	:	Minimum

TABLOLAR LİSTESİ

Tablo 2.1. Delta robot parametreleri. 17
Tablo 2.2. DDPG eğitim hiperparametreleri. 17
Tablo 3.1. Her bir referans yörünge için ZN-PID, CC-PID ve DDPG-PID ile elde edilen PID kazançları 19
Tablo 3.2. ZN-PID, CC-PID ve DDPG-PID'nin takip performansı karşılaştırması 19
Tablo 3.3. Dayanıklılık analizinde kullanılan bozucu parametreler. 39
Tablo 3.4. Gerçekçi bozucu koşullar altında yörünge takip performansı karşılaştırması 40

ŞEKİLLER LİSTESİ

Şekil 2.1. Delta paralel robot 3B modeli. 8
Şekil 2.2. Delta paralel robotun yörünge takibi için önerilen DDPG tabanlı PID ayarlama yapısına ait blok diyagram. 13
Şekil 3.1. Referans yörüngeler: (a) daire, (b) lemniskat, (c) elmas ve (d) yıldız 18
Şekil 3.2. Tüm yörüngeler için ZN-PID, CC-PID ve DDPG-PID RMSE karşılaştırması: (a) daire, (b) lemniskat, (c) elmas ve (d) yıldız 20
Şekil 3.3. Daire yörünge için yöntemlerin tespit ettiği PID parametrelerinin bar çizelgesi 21
Şekil 3.4. X–Y düzleminde daire yörünge takip performansları 22
Şekil 3.5. Daire yörünge için Öklid konum hatası 22
Şekil 3.6. Daire yörünge için X-ekseni takibi 23
Şekil 3.7. Daire yörünge için Y-ekseni takibi 23
Şekil 3.8. Daire yörünge için X-ekseni takip hatası 24
Şekil 3.9. Daire yörünge için Y-ekseni takip hatası 24
Şekil 3.10. Daire yörünge için DDPG öğrenme eğrisi (ITAE) 25
Şekil 3.11. Lemniskat yörünge için yöntemlerin tespit ettiği PID parametrelerinin bar çizelgesi 26
Şekil 3.12. X–Y düzleminde lemniskat yörünge takip performansları 26
Şekil 3.13. Lemniskat yörünge için Öklid konum hatası 27
Şekil 3.14. Lemniskat yörünge için X-ekseni takibi 27
Şekil 3.15. Lemniskat yörünge için Y-ekseni takibi 28
Şekil 3.16. Lemniskat yörünge için X-ekseni takip hatası 28
Şekil 3.17. Lemniskat yörünge için Y-ekseni takip hatası 29
Şekil 3.18. Lemniskat yörünge için DDPG öğrenme eğrisi (ITAE) 29
Şekil 3.19. Elmas yörünge için yöntemlerin tespit ettiği PID parametrelerinin bar çizelgesi 30
Şekil 3.20. X–Y düzleminde elmas yörünge takip performansları 31
Şekil 3.21. Elmas yörünge için Öklid konum hatası 31
Şekil 3.22. Elmas yörünge için X-ekseni takibi 32
Şekil 3.23. Elmas yörünge için Y-ekseni takibi 32
Şekil 3.24. Elmas yörünge için X-ekseni takip hatası 33

Şekil 3.25. Elmas yörünge için Y-ekseni takip hatası.....33
Şekil 3.26. Elmas yörünge için DDPG öğrenme eğrisi (ITAE).....34
Şekil 3.27. Yıldız yörünge için yöntemlerin tespit ettiği PID parametrelerinin bar çizelgesi 35
Şekil 3.28. X–Y düzleminde yıldız yörünge takip performansları 35
Şekil 3.29. Yıldız yörünge için Öklid konum hatası.....36
Şekil 3.30. Yıldız yörünge için X-ekseni takibi.....36
Şekil 3.31. Yıldız yörünge için Y-ekseni takibi.....37
Şekil 3.32. Yıldız yörünge için X-ekseni takip hatası.....37
Şekil 3.33. Yıldız yörünge için Y-ekseni takip hatası.....38
Şekil 3.34. Yıldız yörünge için DDPG öğrenme eğrisi (ITAE).....38
Şekil 3.35. Bozucuların bulunduğu gerçekçi koşullar altında daire yörünge için takip performansı: (a) X–Y düzleminde yörünge takibi, (b) Öklid konum hatası. 41
Şekil 3.36. Bozucuların bulunduğu gerçekçi koşullar altında lemniskat yörünge için takip performansı: (a) X–Y düzleminde yörünge takibi, (b) Öklid konum hatası. 42
Şekil 3.37. Bozucuların bulunduğu gerçekçi koşullar altında elmas yörünge için takip performansı: (a) X–Y düzleminde yörünge takibi, (b) Öklid konum hatası. 43
Şekil 3.38. Bozucuların bulunduğu gerçekçi koşullar altında yıldız yörünge için takip performansı: (a) X–Y düzleminde yörünge takibi, (b) Öklid konum hatası. 44

GİRİŞ

Delta paralel robotlar, düşük hareketli kütleleri ve paralel kinematik düzeneklerinin sağladığı rijitlik sayesinde özellikle hızlı paketleme, ayıklama ve yerleştirme gibi çevrim süresinin kritik olduğu üretim hatlarında öne çıkmaktadır. Buna karşın, aynı paralel yapı; eklemler arası kuplaj, konfigürasyona bağlı etkin kütle/kuvvet iletimi değişimleri ve sürtünme gibi etkiler nedeniyle belirgin doğrusal olmayan davranışlar sergiler. Bu durum yörünge takip probleminde tek bir kontrol ayarıyla her durumda iyi performans beklentisini zorlaştırır. Yörüngenin eğriliği, yön değişimlerinin keskinliği ve çalışma uzayı içindeki konum, takip hatasının büyüklüğünü ve hata sönümleme karakterini doğrudan etkileyebilir. Endüstride yaygın kullanılan PID denetleyiciler ise basit yapıları ve uygulanabilirlikleri nedeniyle tercih edilmekle birlikte, kazançların uygun seçilmemesi halinde gecikmeli hata sönümleme, aşım/salınım ve özellikle köşe içeren yörüngelerde takip bozulmaları gibi sorunlar doğabilmektedir. Kural-tabanlı klasik ayar yaklaşımları çoğu zaman sistemin genel dinamik karakterine dayanır; bu nedenle farklı geometrilere sahip yörüngeler arasında aynı tutarlılıkla çalışmaları her zaman beklenemez.

Bu bağlamda kontrol parametrelerini doğrudan performans hedefi üzerinden ayarlayabilen öğrenme tabanlı yaklaşımlar pratik bir alternatif haline gelmektedir. Pekiştirmeli öğrenme, kontrolörün çevre ile etkileşiminden elde edilen geri bildirimi bir "ödül" sinyaline dönüştürerek, deneme-yanılma yoluyla performansı artırmayı amaçlar. Bu tez çalışmasında, delta paralel robotun yörünge takip kontrolü için PID kazançlarının otomatik ayarlanması hedefiyle, sürekli eylem uzayına uygun bir aktör–kritik mimarisi kullanan DDPG tabanlı bir yaklaşım ele alınmaktadır. Robotun kinematik ve dinamik modeli üzerinden oluşturulan benzetim ortamında, ajan; durum vektöründe normalize edilmiş kazanç bilgileri ile takip hatasını temsil eden özet bir büyüklüğü birlikte değerlendirir, eylem olarak ise kazançları sınırlar içinde güncelleyen bir çıktı üretir.

Önerilen yaklaşımın pratik değerini ortaya koymak için, farklı geometrik özelliklere sahip dört farklı düzlemsel referans yörünge (daire, lemniskat, elmas ve yıldız) üzerinde karşılaştırmalı bir değerlendirme yapılmıştır. Klasik ayar kurallarıyla (Ziegler–Nichols ve Cohen–Coon) elde edilen PID kazançlarının yörüngeden bağımsız sabit kalmasına karşın, öğrenme tabanlı yöntemin yörünge karakteristiğine bağlı olarak kazançları farklılaştırabildiği gözlemlenmiştir. Performans değerlendirmesi; ortalama hatayı, hatanın birikimini ve zamana bağlı cezalandırmayı farklı bakış açılarından yakalayan birden fazla metrik (RMSE, IAE, ISE, ITAE ve maksimum hata) ile yapılmış ve DDPG-PID ile yörünge takibinin üstün performansının sonuçları karşılaştırmalı grafikler ile ortaya konumuştur.

Tez çalışması 4 bölümden oluşmaktadır. 1. bölümde çalışmanın amacı açıklanmış ve literatür çalışması anlatılmıştır. “Yöntem ve Materyal” başlıklı 2. bölümde ise, kontrol tasarımında kullanılan delta paralel robotun matematiksel modeli, PID kontrol yapısı ve geleneksel parametre belirleme yöntemleri olan Ziegler–Nichols ile Cohen–Coon teknikleri hakkında bilgiler verilmiştir. Ayrıca derin takviyeli öğrenme ve çalışmamıza konu olan DDPG algoritmasının PID parametre optimizasyonundaki uygulama süreçleri detaylı bir şekilde açıklanmıştır. Çalışmanın 3. bölümünde; daire, lemniskat, elmas ve yıldız olmak üzere dört farklı yörünge için kontrol çalışmaları gerçekleştirilmiş; DDPG-PID ile elde edilen bulgular hata metrikleri ve yörünge takip grafikleri üzerinden klasik yöntemlerle karşılaştırmalı olarak sunulmuştur. Son olarak 4. bölümde ise sonuç ve öneriler üzerinde durulmuştur.

1. BÖLÜM

TEZİN AMACI VE LİTERATÜR ÇALIŞMASI

1.1. Tezin Amacı

Robot manipülatörler, kinematik yapılarına göre iki ana kategoriye ayrılır: seri ve paralel. Seri manipülatörlerde eklemler ardışık olarak bağlanırken, paralel manipülatörlerde uç-efektör tabana birden fazla kinematik zincir aracılığıyla bağlanır. Bu kapalı-zincirli yapı, paralel manipülatörlere seri muadillerine kıyasla daha yüksek rijitlik, daha iyi doğruluk, daha yüksek taşıma kapasitesi ve özellikle daha yüksek hız kabiliyeti gibi önemli avantajlar sağlar.

Paralel manipülatörler arasında delta robot, ilk kez 1988 yılında Clavel [1] tarafından tanıtılmış olup endüstride en yaygın kullanılan paralel kinematik yapılardan biridir. Delta robot, üç serbestlik dereceli (3-DOF) öteleme hareketine imkân veren ayırt edici tasarımıyla öne çıkar. Yapısal olarak sabit bir üst platform, hareketli bir alt platform (uç-efektör) ve bu platformları birbirine bağlayan üç paralel kol zincirinden oluşur. Her bir kol zinciri, bir motor tarafından tahrik edilen üst koldan ve paralelkenar mekanizmasına sahip alt koldan meydana gelir. Bu tasarım sayesinde motorlar sabit platform üzerine yerleştirilebilir; böylece hareketli kütle en aza indirilir ve çok yüksek hızlara ulaşılabilir.

Seri ve paralel manipülatörlerin karşılaştırmalı analizi, delta robotun avantajlarını daha belirgin hâle getirir. Seri manipülatörler geniş bir çalışma uzayı sunarken, paralel yapılar daha sınırlı fakat daha hassas bir çalışma hacmi sağlar. Rijitlik açısından, yüklerin birden fazla kol tarafından paylaşılması nedeniyle paralel konfigürasyonlarda çok daha yüksek rijitlik elde edilir. Hız kabiliyeti bakımından ise motorların sabit platformda konumlandırılması ve hareketli kütlenin azalması sayesinde paralel manipülatörler belirgin bir üstünlük sergiler. Bu özellikler, delta robotun yüksek hızlı al-bırak (pick-and-

place) operasyonlarında; ayrıca gıda işleme, ilaç endüstrisi, elektronik montaj ve 3B yazıcı uygulamalarında tercih edilmesinin başlıca nedenleridir.

PID (Oransal–İntegral–Türev) denetleyiciler, basit yapıları ve uygulama kolaylıkları nedeniyle robot kontrol sistemlerinde en yaygın kullanılan kontrol yöntemleridir. Åström ve Hägglund [2] tarafından gerçekleştirilen kapsamlı çalışmada, PID denetleyicilerin endüstriyel kontrol yaklaşımlarının büyük çoğunluğunda kullanıldığı belirtilmiştir. Bununla birlikte, PID parametrelerinin (K_p, K_i, K_d) en uygun şekilde belirlenmesi, kontrol performansını doğrudan etkileyen kritik bir süreçtir. Özellikle paralel manipülatörlerin karmaşık dinamikleri dikkate alındığında, bu parametre ayarlama problemi daha da kritik hâle gelir. Geleneksel PID ayar yöntemleri arasında, Ziegler ve Nichols'un [3] 1942 yılında önerdiği yaklaşım uygulamada en yaygın kullanılan yöntemlerden biridir. Bu yöntem, açık çevrim (proses reaksiyon eğrisi) veya kapalı çevrim (sürekli salınım) deneylerinden elde edilen parametrelere dayalı ampirik formüller kullanır. Cohen ve Coon [4] ise 1953 yılında ölü zaman içeren birinci dereceden sistemler için alternatif bir ayarlama yöntemi geliştirmişlerdir.

Tez çalışmasında ise delta paralel robotların yörünge takip kontolünde PID parameterlerinin belirlenmesinde Ziegler–Nichols ve Cohen–Coon gibi kural bazlı yöntemler ile pekiştirmeli öğrenmenin karşılaştırılması yapılmıştır. DDPG ile parametreleri belirlenen kontrolcünün performans çıktıları bu iki geleneksel yaklaşım ile karşılaştırılmıştır. Bu çalışmanın temel katkıları şu şekilde özetlenebilir: (i) delta robot için yeni bir DDPG tabanlı PID ayarlama çerçevesi geliştirilmiştir, (ii) klasik ve pekiştirmeli öğrenme (Reinforcement Learning – RL) tabanlı ayar yöntemlerinin karşılaştırmalı performans analizi sunulmuştur, (iii) paralel robot kontrol yöntemlerinin etkinliği farklı geometrik yörüngeler üzerinde değerlendirilmiştir ve (iv) bozucu etkiler altında kontrolörlerin dayanıklılık analizi yapılmıştır.

1.2. Literatür Çalışması

Delta robotun kinematik ve dinamik modellenmesine ilişkin çalışmalar incelendiğinde, Pierrot ve Company [5] paralel manipülatörlerin tasarım ve kontrol stratejilerini kapsamlı biçimde ele almışlardır. Hernández ve ark. [6] çalışmalarında paralel robotların kinematik ve dinamik modellenmesini ele almış ve delta tipi robotlar için gerçek zamanlı kontrol uygulamalarına uygun bir modelleme yaklaşımı önermişlerdir. Codourey [7], delta robot

için dinamik modelleme ve kontrol yaklaşımları üzerine çalışmalar yürütmüştür. Stamper ve ark. [8], üç serbestlik dereceli öteleme hareketine sahip bir paralel platformun tasarımına yönelik iki optimizasyon çalışması gerçekleştirmiş ve sonuçları karşılaştırmışlardır. Yörünge planlama ve kontrol alanında Biagiotti ve Melchiorri [9], robot yörünge planlamasına dair temel bir başvuru kaynağı olacak bir çalışma sunmuşlardır. Merlet [10], paralel robotların analizi ve tasarımına ilişkin kapsamlı bir çalışma ortaya koymuştur. Tsai [11] ise robot analizinin matematiksel temellerini ortaya koymuştur. Azmoun ve ark. [12] yaptıkları çalışmada delta paralel manipülatörün simülasyonunu gerçekleştirilerek kontrolörlerin performanslarını incelemişlerdir. Rahmani ve ark. [13] yaptıkları çalışmada, paralel robotun hareketli plakasını yönlendirmek için bir projeksiyon sinir ağı ile bağlantılı olarak ikinci denetleyicili bir yaklaşım kullanmışlardır. Kontrol algoritmasının çok yönlülüğünü arttırmak için, Lyapunov kararlılık teorisi kullanılarak anahtarlama kazancı için uyarlanabilir bir kural belirlemişlerdir. Önerilen algoritmanın, sinir ağı tarafından oluşturulan yolu takibinde yüksek performansa sahip olduğu ortaya konmuştur. Thanh ve ark. [14], PID parametrelerinin çevrimiçi güncellenmesine olanak tanıyan doğrusal nöron yapısı ile tekrarlayan bulanık sinir ağı tabanlı Jacobian kestirimi kullanan bir kontrol yaklaşımı geliştirerek delta robotlar için gelişmiş yörünge takip performansı elde etmişlerdir. Haas ve ark. [15] makine öğrenimi yardımıyla delta kinematik robotun kontrol devresinin optimizasyonu ve yol planlamasını yapmışlardır. Pak ve ark. [16] delta paralel robotun yörünge takibi için hesaplamalı tork kontrolü (CTC) stratejisi kullanarak PID kontrol cihazının optimum parametrelerini ayarlamaya yönelik bir yaklaşım önerisinde bulunmuşlardır. Boudjedir ve ark. [17] paletleme için çeşitli tekrarlayan görevleri gerçekleştiren paralel delta robotun yörünge takibi için hizalama koşulu altında bir yinelemeli öğrenme kontrolörü önermişlerdir.

Son yıllarda, RL tabanlı kontrol yöntemleri [18] robot kontrol sistemlerinde önemli ilerlemeler göstermiştir. Lillicrap ve ark. [19] tarafından 2015 yılında önerilen DDPG algoritması, sürekli eylem uzaylarında derin pekiştirmeli öğrenme açısından çığır açıcı bir yöntem olmuştur. Aktör–Eleştirmen (Actor–Critic) mimarisini derin sinir ağlarıyla birleştiren DDPG, karmaşık kontrol problemlerinin çözümünde etkili sonuçlar üretmiştir. Vu ve Alsmadi [20] iki serbestlik dereceli bir kablo askılı bir paralel robotu (Cable-Suspended Parallel Robot – CSPR) al-bırak (pick-and-place) yörüngesini gerçekleştirmek

üzere eğitmek için Soft Actor-Critic (SAC) adlı bir RL algoritmasının kullanılmasını önermişlerdir.

Pekiştirmeli öğrenmenin robot kontrolündeki uygulamaları da hızla artmaktadır. Kober ve ark. [21], robotikte pekiştirmeli öğrenme uygulamalarını kapsamlı bir biçimde derlemişlerdir. Gu ve ark. [22], robot manipülasyonunda derin pekiştirmeli öğrenme uygulamalarını incelemişlerdir. Lawrence ve ark. [23], RL tabanlı PID otomatik ayarlama sistemleri üzerine çalışmalar yürütmüşlerdir. Carlucho ve ark. [24], sualtı araçları için derin RL tabanlı kontrol sistemleri geliştirmişlerdir. dos Santos Lima ve ark. [25], delta robot uç-efektörünü uzaydaki hedef bir noktaya hassas biçimde yönlendirmek için derin pekiştirmeli öğrenme kontrol yaklaşımlarını karşılaştırmalı olarak değerlendirmişlerdir. Yadavari ve ark. [26], ROS–Gazebo ortamında parametrik bir benzetim çerçevesi içinde derin pekiştirmeli öğrenme algoritmalarını kullanarak bir Stewart platformunun kontrolünü gerçekleştirmiş ve model-tabanlı ile model-özgür RL yaklaşımlarının performanslarını karşılaştırmışlardır. Lu ve ark. [27], tam kısıtlı kablo-tahrikli paralel robotların kontrolünde kablo esnekliği ve sürtünme gibi belirsizlikleri telafi etmek üzere Lyapunov tabanlı bir derin pekiştirmeli öğrenme denetleyicisi önermiş ve kapalı çevrim kararlılığını kanıtlamışlardır. Huang ve Chen [28], 6-DOF Stewart platformunun zamana bağlı yörünge takip kontrolü için evrimsel optimizasyonla ayarlanmış bulanık Q-öğrenme yöntemini geliştirmiş ve gerçek zamanlı performansını deneysel olarak doğrulamışlardır. Zhu ve ark. [29], delta paralel robotların doğrusal olmayan dinamik yapısını dikkate alarak PID parametrelerinin ayarlanması için DDPG tabanlı bir pekiştirmeli öğrenme çerçevesi önermişlerdir. Çalışma sonuçları, öğrenme tabanlı bu yaklaşımın klasik PID ayarlama yöntemlerine kıyasla daha üstün yörünge takip doğruluğu ve daha güçlü bozucu bastırma performansı sunduğunu ortaya koymuştur.

Jalali ve ark. [30], delta robotun dinamik modelini türetmedeki zorlukların üstesinden gelmek üzere al-bırak (pick-and-place) uygulaması için model-özgür DDPG tabanlı bir kontrol stratejisi geliştirmiştir. Grimshaw ve Oyekan [31], sekiz kablolu paralel bir robotta dengesiz bir bilye–plaka yükünü dengelemek için DDPG tabanlı bir yaklaşım uygulamış ve iç içe PID yapısına sahip entegre bir sinir ağı referans denetleyicisini eğitmişlerdir. Louette ve ark. [32], hurda metal ayrıştırmada bir delta robot için RL tabanlı al-fırlat (pick-and-throw) stratejisi geliştirmiş; yüksek doğruluk ve verimlilikte ciddi artış raporlamış ve simülasyondan gerçek ortama aktarımını (sim-to-real) başarıyla

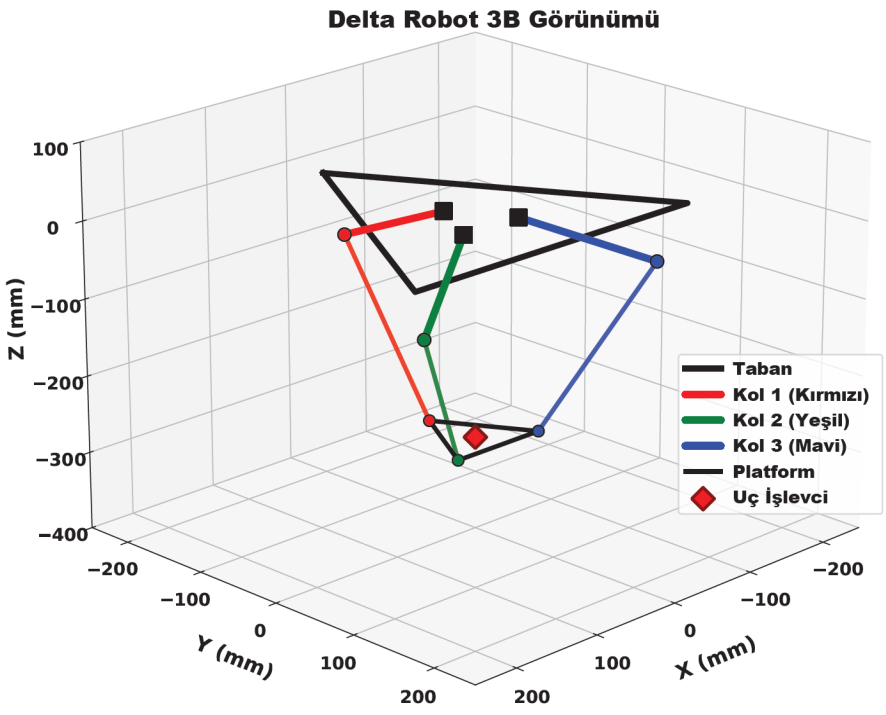
göstermişlerdir. Sancak ve ark. [33], gerilim dağıtım algoritmasına ihtiyaç duymadan hem noktadan noktaya hem de dinamik referans takip görevlerinde başarılı olan, düzlemsel bir kablo-tahrikli paralel robotun konum kontrolü için DDPG tabanlı bir pekiştirmeli öğrenme yöntemi önermişlerdir. Chen ve ark. [34], kablo-tahrikli paralel robotlarda uç-efektör konumunu kestirmek ve telafi edilmiş hareket/konum kontrolü sağlamak için Derin Pekiştirmeli Öğrenme (Deep Reinforcement Learning, DRL) kullanan bir yaklaşım geliştirmiş; eşzamansız durum gözlemi–eylem yürütme problemini ele almışlardır. Azad ve ark. [35] ise inşaat uygulamaları için 3-DOF delta paralel robotta, her kontrol adımında en uygun dış dinamik modeli seçmek üzere Q-öğrenme tabanlı akıllı model seçimini kullanarak geri-adımlama/kayan kip (back-stepping/sliding-mode) tabanlı bir kontrol yöntemi geliştirmiştir. Yang ve ark. [36], delta robotun kinematik ve matematiksel modelini Jacobi matrisi aracılığıyla tanımlayarak, bilinmeyen bozucular altında PID kazançlarının ayarlanması için Q-öğrenme tabanlı bir optimizasyon yaklaşımı geliştirmişlerdir. Çalışmada, öğrenme tabanlı kontrol stratejisinin yörünge takip hatasını minimize ederek sistem performansını önemli ölçüde artırdığını ortaya koymuşlardır. Ma ve ark. [37] ilk kez kablo tahrikli paralel bir robotu (Cable-Driven Parallel Robot – CDPR) kontrol etmek için bir DRL algoritması olan DDPG yaklaşımını uygulamışlardır. Bu çalışma, CDPR'nin kontrolünün yanı sıra, DDPG'nin CDPR'nin optimum gerilim dağılımını öğrenme yeteneğini ve DDPG'nin CDPR'nin belirli model belirsizliklerine karşı sağlamlığını da araştırmaktadır. Çalışma sonuçları, DDPG'nin sadece CDPR'yi kontrol etmekle kalmayıp aynı zamanda CDPR'nin optimum gerilim dağılımını da öğrenebildiğini göstermektedir. Bouaouda ve ark. [38] kablo tahrikli paralel robotların kontrolünde, simüle edilmiş yörüngelerden bir kontrolcü öğrenen yapay zekâ tabanlı bir yaklaşım önerisinde bulunmuşlardır. Hu ve ark. [39] yörünge planlama algoritmasını oluşturmak için Verimli İleri Kinematik (Efficient Forward Kinematics – EFK) ile DDPG'yi birleştirmişlerdir. Simülasyon ve deneysel sonuçlar, EFK algoritmasının yakınsama hızının ve başarı oranının ciddi şekilde iyileştirildiğini göstermektedir.

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1. Delta Robotun Matematiksel Modeli

Şekil 2.1'de gösterildiği üzere delta robot, paralel kinematik yapıya sahip bir manipülatördür [10]. Sabit platform (taban) ile hareketli platform (uç-efektör) arasında üç paralel kinematik uzuvdan oluşur ve her bir uzuv, motorla tahrik edilen bir üst kol (r_f) ile paralelkenar mekanizmasına sahip bir alt koldan (r_e) meydana gelir. Bu kapalı-zincirli kinematik yapı yüksek rijitlik ve doğruluk sağlarken, paralelkenar mekanizması hareketli platformun yönelimini sabit tutarak esasen öteleme hareketi üretir. Sabit platform yarıçapı ve hareketli platform yarıçapı sırasıyla r_b ve r_p olarak tanımlanmıştır.



Şekil 2.1. Delta paralel robot 3B modeli

Ters kinematik probleminde, uç-efektörün kartezyen koordinatları $\mathrm{p} = (x_0, y_0, z_0)$ verildiğinde motor açıları $(\theta_1, \theta_2, \theta_3)$ hesaplanır. Simetri nedeniyle her bir kol için dönüşüm, $120°$'lik bir faz kaymasıyla aynıdır ($\phi_1 = 0°, \phi_2 = 120°, \phi_3 = 240°$). i. kol için $(i = 1, 2, 3)$, (x_i, y_i) değerleri Denklem 2.1'deki gibi elde edilir.

$$\begin{bmatrix} x_i \\ y_i \end{bmatrix} = \begin{bmatrix} \cos\phi_i & \sin\phi_i \\ -\sin\phi_i & \cos\phi_i \end{bmatrix} \begin{bmatrix} x_0 \\ y_0 \end{bmatrix} \tag{2.1}$$

Sabit platform üzerindeki motor montaj noktasının y-koordinatı Denklem 2.2'de verilirken, hareketli platform üzerindeki uç-efektör ekleminin y-koordinatı Denklem 2.3'te elde edilmektedir.

$$y_1 = -\frac{r_b}{\sqrt{3}} \tag{2.2}$$

$$y_2 = y_i + \frac{r_p}{\sqrt{3}} \tag{2.3}$$

Yardımcı değişkenler a ve b Denklem 2.4'te verilmiş, bu değişkenlere bağlı diskriminant ifadesi ise Denklem 2.5'te sunulmuştur.

$$a = \frac{x_i^2 + y_2^2 + z_0^2 + r_f^2 - r_e^2 - y_1^2}{2z_0}, b = \frac{y_1 - y_2}{z_0} \tag{2.4}$$

$$d = -(a + by_1)^2 + r_f^2(b^2 + 1) \tag{2.5}$$

Çalışma uzayı uygunluk kontrolü sonucunda $d < 0$ ise çözüm yoktur, $d \geq 0$ ise çözüm vardır. Dirsek noktası Denklem 2.6 ile hesaplanır ve motor açısı Denklem 2.7 ile bulunur.

$$y_j = \frac{y_1 - ab - \sqrt{d}}{b^2 + 1}, z_j = a + by_j \tag{2.6}$$

$$\theta_i = \operatorname{atan2}\left(-z_j,\ y_1 - y_j\right) \tag{2.7}$$

Delta robotun dinamik davranışı [10], Newton–Euler formülasyonu kullanılarak modellenmiştir. Etkin kütle (m_{eff}) ve viskoz sürtünme katsayısı (b_v) dikkate alındığında, hareket denklemi Denklem 2.8'deki gibi elde edilir.

$$m_{eff}\ddot{p} = F - b_v\dot{p} - m_{eff}g \tag{2.8}$$

Burada $F = [F_x, F_y, F_z]^T$ kontrol kuvvetini, $g = [0,0,g]^T$ yerçekimi ivmesi vektörünü, p konum vektörünü ve $\dot{p}$ hız vektörünü ifade eder. Denklem 2.9'da görüldüğü üzere etkin kütle, platform kütlesi (m_p) ile kol kütlesinin (m_a) toplamından oluşur.

$$m_{eff} = m_p + m_a \tag{2.9}$$

2.2. PID Denetleyici ve Kazanç Ayarı

PID denetleyici [2], Denklem 2.10'da verildiği gibi, konum hatası $e(t) = r(t) - y(t)$ (referans ile çıktı arasındaki fark) üzerinden kontrol sinyali $u(t)$ üretir.

$$u(t) = K_p e(t) + K_i \int_0^t e(\tau)\, d\tau + K_d \dot{e}(t) \tag{2.10}$$

Burada K_p, K_i ve K_d sırasıyla oransal, integral ve türev kazançlarıdır. İntegral terimi, hata sürdükçe birikerek büyür. Bu birikim sınırlandırılmazsa integral doyumu (integral windup) oluşabilir; sistem hatayı telafi etmeye başladığında aşırı aşım ve hatta kararsızlık gözlenebilir. Bu etkiyi azaltmak için Denklem 2.11'deki gibi anti-windup (integral taşması önleme) uygulanır ve integral terimi, birikimin kontrolsüz büyümesini önlemek üzere $[-L, +L]$ aralığında sınırlandırılır [40]. Tez çalışmasında $L = 50$ alınmıştır.

$$I(t) = clip\left(\int_0^t e\,(\tau)\, d\tau, -L, +L\right) \tag{2.11}$$

2.2.1. Ziegler-Nichols Yöntemi

Bu tez çalışmasında, Ziegler–Nichols [3,41] kapalı çevrim (röle geri besleme) yöntemi kullanılarak sistem sürekli salınıma sürülmekte ve nihai kazanç (K_u) ile nihai periyot (T_u) belirlenmektedir. Nihai kazanç Denklem 2.12'de verilmektedir.

$$K_u = \frac{4d}{\pi a} \tag{2.12}$$

Bu denklem, Tanımlayıcı Fonksiyon (Describing Function) analizinden türetilmiştir. Burada d, röle genliğidir; mekanik sınırları aşmadan yeterli salınım sağlayacak şekilde seçilir (bu çalışmada 100 seçilmiştir). a parametresi ise sürekli salınım altında çıktıdaki

maksimum ve minimum değerler arasındaki farkın yarısıdır; yani salınım genliğini temsil eder. a ifadesi Denklem 2.13'te verilmiştir.

$$a = \frac{y_{\text{maks}} - y_{\text{min}}}{2} \tag{2.13}$$

T_u, sistemin kritik (nihai) salınım periyodudur. Uygulamada yarım periyot $T_{\text{yarım}}$, ardışık tepe zaman damgaları arasındaki zaman farklarının ortalaması olarak hesaplanır; tam periyot ise Denklem 2.14'te gösterildiği gibi $T_u = 2 \cdot T_{\text{yarım}}$ alınır.

$$T_u = 2\,T_{\text{yarım}} = 2 \cdot \frac{1}{n}\sum_{i=1}^{n}(t_{i+1} - t_i) \tag{2.14}$$

Ardından PID parametreleri Denklem 2.15-2.17 kullanılarak hesaplanır. Bu denklemlerde T_i integral zamanı, T_d ise türev zamanıdır.

$$K_p = 0.6\,K_u \tag{2.15}$$

$$K_i = \frac{K_p}{T_i} = \frac{0.6\,K_u}{T_u/2} = \frac{1.2\,K_u}{T_u} \tag{2.16}$$

$$K_d = K_p\,T_d = 0.6\,K_u \cdot \frac{T_u}{8} = 0.075\,K_u\,T_u \tag{2.17}$$

2.2.2. Cohen-Coon Yöntemi

Cohen–Coon [4] yöntemi, açık çevrim basamak yanıtı analizine dayanır. Sisteme sabit bir giriş (basamak) uygulanır ve çıkış yanıtı gözlenerek dinamik karakteristikler belirlenir. Bu çalışmada uygulanan basamak testi girdisi, başlangıç konumu $(0{,}0, -280)$ mm için x yönünde 2 saniye boyunca uygulanan $F_{\text{step}} = 50N$ kuvvetidir. Birçok endüstriyel proses, Denklem 2.18'de verilen Ölü Zamanlı Birinci Derece (First-Order Plus Dead Time – FOPDT) modeli ile yaklaşık olarak temsil edilebilir.

$$G(s) = \frac{K\,e^{-\theta s}}{\tau s + 1} \tag{2.18}$$

Burada K proses kazancı, τ zaman sabiti ve θ ölü zamandır. Bu parametreleri basamak yanıtından belirlemek için İki Nokta Yöntemi (Two-Point Method) [42] kullanılmıştır. Değerler, yanıtın %28.3 ve %63.2 seviyelerindeki noktalardan elde edilir. Parametreler sırasıyla Denklem 2.19-2.21'de verilmiştir.

$$K = \frac{y_{final}}{F_{adım}} = \frac{Kararlı\ durum\ çıkışı}{Adım\ girişi} \tag{2.19}$$

$$\tau = 1.5\ (t_{63.2} - t_{28.3}) \tag{2.20}$$

$$\theta = t_{63.2} - \tau \tag{2.21}$$

Gecikme oranı (r) da Denklem 2.22'deki gibi belirlenir.

$$r = \frac{\theta}{\tau} \tag{2.22}$$

Bu oran, sistemin "ne kadar gecikmeli" olduğunu gösterir; r küçükse sistem hızlı, r büyükse sistem yavaş/gecikmelidir. Cohen–Coon yöntemi, belirlenen K, τ, θ ve r değerlerini kullanarak PID parametrelerini hesaplar. Bu çalışmada kullanılan PID formülleri, Cohen–Coon'un özgün yönteminin değiştirilmiş bir versiyonudur ve Denklem 2.23-2.25'te verilmiştir.

$$K_p = \frac{1.35}{K\,r}\left(1 + \frac{0.18\,r}{1-r}\right) \tag{2.23}$$

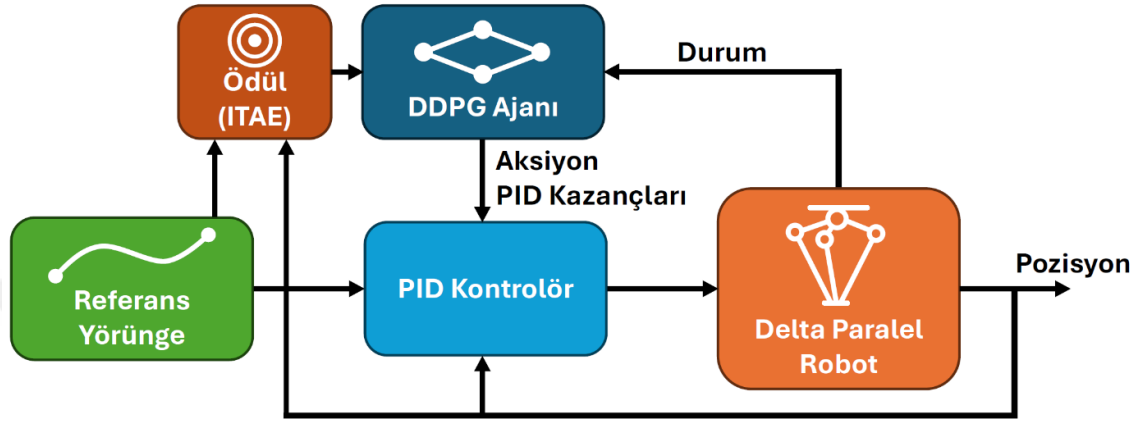
$$T_i = \theta\ \frac{2.5 - 2r}{1 - 0.39r} \tag{2.24}$$

$$T_d = \frac{0.37\,\theta}{1 - 0.81r} \tag{2.25}$$

2.2.3. Önerilen DDPG-PID Yöntemi

DDPG [19], sürekli eylem uzayları için tasarlanmış, off-policy (politika-dışı) bir aktör–eleştirmen algoritmasıdır; aktör deterministik bir politikayı temsil ederken, eleştirmen $Q(s,a)$ eylem-değer fonksiyonunu tahmin eder. Bu çalışmada aktör, PID kazanç güncellemelerine karşılık gelen sürekli eylemler üretir; bu eylemler, afin ölçekleme kuralı aracılığıyla sınırlandırılmış (K_p, K_i, K_d) değerlerine eşlenir. Standart DDPG

formülasyonunu izleyerek öğrenmeyi kararlı hâle getirmek için deneyim tekrar belleği (experience replay memory) ve yavaş güncellenen hedef ağlar (target networks) kullanılır. Şekil 2.2'de önerilen DDPG tabanlı PID ayarlama yapısının blok diyagramı gösterilmektedir.



Şekil 2.2. Delta paralel robotun yörünge takibi için önerilen DDPG tabanlı PID ayarlama yapısına ait blok diyagram

Durum vektörü s, Denklem 2.26'da normalize edilmiş PID parametreleri ve normalize edilmiş ortalama takip hatasından oluşacak şekilde tanımlanmıştır.

$$s = \left[\frac{K_p - K_{p,\min}}{K_{p,\text{maks}} - K_{p,\min}}, \frac{K_i - K_{i,\min}}{K_{i,\text{maks}} - K_{i,\min}}, \frac{K_d - K_{d,\min}}{K_{d,\text{maks}} - K_{d,\min}}, \frac{e_{\text{avg}}}{20}\right] \tag{2.26}$$

Burada e_{avg}, bir bölüm (episode) boyunca hatanın ortalama büyüklüğünü ifade eder. Değişken ölçekleri farklı olduğunda ağların daha kararlı öğrenebilmesi için normalizasyon uygulanır. Eylem vektörü a, $\tanh$ aktivasyonu aracılığıyla PID parametrelerini $[-1,1]$ aralığına normalize edecek şekilde içerir. Gerçek parametreler, Denklem 2.27'de alt ve üst sınırlar lb ve ub kullanılarak yapılan aşağıdaki afin dönüşümle elde edilir.

$$\text{PID} = a \odot \frac{\text{ub} - \text{lb}}{2} + \frac{\text{ub} + \text{lb}}{2} \tag{2.27}$$

Burada $\odot$ Hadamard (eleman-bazlı) çarpımı gösterir. Bu sayede ajanın eylemleri her zaman fiziksel/işletimsel açıdan anlamlı kazanç aralıkları içinde tutulur. Ödül

fonksiyonu, Denklem 2.28'de gösterildiği gibi ITAE (Zaman Ağırlıklı Mutlak Hata İntegrali) ölçütüne dayalı olarak tanımlanmıştır.

$$r = -\frac{ITAE}{10} = -\frac{1}{10}\sum_{k=0}^{N-1} t_k \left\| e(t_k) \right\| \Delta t \tag{2.28}$$

Buna göre ajan, daha küçük ITAE değerleri üreten PID parametrelerini seçerek daha yüksek (yani daha az negatif) ödül elde eder. ITAE, zaman arttıkça hataları daha ağır cezalandırdığı, özellikle geçici rejimde (transient) geç kalan hataları öne çıkardığı için PID ayarında yaygın bir performans indisidir.

DDPG'de aktör ağı $\mu(s \mid \theta_\mu)$ durumu eyleme eşlerken, eleştirmen ağı $Q(s, a \mid \theta_Q)$ eylem-değer fonksiyonunu tahmin eder. Hedef ağlar, Denklem 2.29'daki gibi τ yumuşak güncelleme oranı ile güncellenir.

$$\theta' \leftarrow \tau\theta + (1-\tau)\theta' \tag{2.29}$$

Burada $\tau \in (0,1)$ yumuşak güncelleme katsayısıdır.

Sürekli eylem uzayında keşif (exploration) için Ornstein–Uhlenbeck sürecine dayalı korelasyonlu gürültü kullanılmıştır. Bu seçim, fiziksel kontrol problemlerinde daha pürüzsüz eylem değişimleri üretme eğilimi nedeniyle DDPG literatüründe yaygındır. Eğitim sırasında gürültü şiddeti Denklem 2.30'daki gibi kademeli olarak azaltılır.

$$\sigma \leftarrow \text{maks}\left(\sigma_{\min}, \sigma \cdot \sigma_{\text{decay}}\right) \tag{2.30}$$

Böylece eğitimin erken aşamalarında geniş keşif teşvik edilirken, ilerleyen aşamalarda daha fazla sömürü (exploitation) davranışı desteklenir.

2.3. Bozucu Modelleri

Çalışmanın son kısmında gerçek çalışma koşulları simüle edilerek dayanıklılık analizi gerçekleştirilmiştir. Bu amaçla aşağıdaki bozulma modelleri tasarlanmıştır.

- **Sensör Gürültü Modeli:** Ölçülen konum ve hız sinyallerine, Denklem 2.31 ve 2.32'de tanımlandığı gibi eklemeli Gauss gürültüsü eklenir.

$$p_{meas}(t) = p(t) + n_p(t), \qquad n_p \sim \mathcal{N}\left(0, \sigma_p^2 I_3\right) \tag{2.31}$$

$$\dot{p}_{meas}(t) = \dot{p}(t) + n_v(t), \qquad n_v \sim \mathcal{N}(0, \sigma_v^2 I_3) \tag{2.32}$$

burada $\sigma_p$ve σ_v sırasıyla konum ve hız gürültüsünün standart sapmalarıdır ve I_3 özdeş matristir.

- **Parametre Belirsizlik Modeli:** Gerçek sistem parametreleri, Denklem 2.33 ve 2.34'te tanımlandığı gibi rastgele ölçeklendirme faktörleri ile nominal değerlerden saptırılır.

$$m_{eff,real} = \left(m_{eff} + m_{load}\right) \cdot (1 + \delta_m), \qquad \delta_m \sim \mathcal{U}(-0.2,0.2) \tag{2.33}$$

$$b_{v,real} = b_v \cdot (1 + \delta_b), \qquad \delta_b \sim \mathcal{U}(-0.2,0.2) \tag{2.34}$$

burada m_{load} ek yük, δ_m, ve δ_b ise sırasıyla kütle ve sürtünme katsayısındaki ±%20 belirsizliği temsil eder.

- **Dışsal Bozulma Modeli:** Denklem 2.35'te tanımlandığı gibi, her zaman adımında uç-efektöre rastgele dışsal kuvvetler uygulanır.

$$F_{dist}(t) \sim \mathcal{N}(0, \sigma_F^2 I_3) \tag{2.35}$$

burada σ_F bozucu kuvvetin standart sapmasıdır.

- **Değiştirilmiş Dinamik:** Gerçekçi koşullar altında hareket denklemi, Denklem 2.36'da gösterildiği gibi olur.

$$m_{eff,real}\ddot{p} = F + F_{dist} - b_{v,real}\dot{p} - m_{eff,real}g \tag{2.36}$$

burada F kuvveti, gürültülü ölçümler p_{meas} ve $\dot{p}_{meas}$ temel alınarak hesaplanan PID kontrol sinyalidir.

2.4. Performans Metrikleri

Bu çalışmada kullanılan performans metrikleri; ortalama karesel kök hata RMSE (Root Mean Squared Error), birikimli mutlak hatayı ölçen IAE (Integral of Absolute Error), büyük hataları daha fazla cezalandıran ISE (Integral of Squared Error), geç kalan hataları giderek daha fazla cezalandıran ITAE (Integral of Time-weighted Absolute Error) ve en

kötü durum sapmasını raporlayan Maks. Hata (maksimum hata)'dır. Bu metriklerin matematiksel tanımları Denklem 2.37-2.41'te verilmiştir.

$$\text{RMSE} = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\|\text{e}_i\|^2} \tag{2.37}$$

$$\text{IAE} = \int_0^T \|\text{e}(t)\|\, dt \tag{2.38}$$

$$\text{ISE} = \int_0^T \|\text{e}(t)\|^2\, dt \tag{2.39}$$

$$\text{ITAE} = \int_0^T t\ \|\text{e}(t)\|\, dt \tag{2.40}$$

$$\text{Maks. Hata} = \max_{1\le i\le N}\|\text{e}_i\| \tag{2.41}$$

Bu denklemlerde N örnek sayısını, T değerlendirme ufkunu, $e_i = r(t_i) - y(t_i)\ \ i.$ örnekteki takip hatasını ve $e(t) = r(t) - y(t)$ sürekli-zaman hata sinyalini ifade eder. Öklid normunu da $\|\cdot\|$ göstermektedir.

2.5 Simülasyon Parametreleri

Bu alt bölümde simülasyon ortamı, robot model parametreleri ve öğrenme/eğitim hiperparametreleri özetlenmektedir. Delta robot, Tablo 2.1'de listelenen geometrik ve çalışma uzayı parametreleriyle modellenmiş; DDPG eğitim ayarları (bölüm sayısı, ağ boyutu, tekrar havuzu, iskonto faktörü, yumuşak güncelleme oranı, öğrenme oranları ve keşif gürültüsü zamanlaması) Tablo 2.2'de verilmiştir. Ayrıca öğrenilen denetleyicinin güvenli ve uygulanabilir sınırlar içinde kalmasını sağlamak üzere eylem ölçekleme için kullanılan K_p, K_i ve K_d aralıkları açıkça tanımlanmıştır.

Tablo 2.1. Delta robot parametreleri

Parametre	**Sembol**	**Değer**
Sabit platform yarıçapı	r_b	200 mm
Hareketli platform yarıçapı	r_p	60 mm
Üst kol uzunluğu	r_f	150 mm
Alt kol uzunluğu	r_e	350 mm
Platform kütlesi	m_p	0.5 kg
Kol kütlesi	m_a	0.2 kg
Viskoz sürtünme katsayısı	b_v	5 Ns/m
Yerçekimi ivmesi	g	9810 mm/s²
Zaman adımı	dt	0.001 s
Yörünge periyodu	T	4 s

Tablo 2.2. DDPG eğitim hiperparametreleri

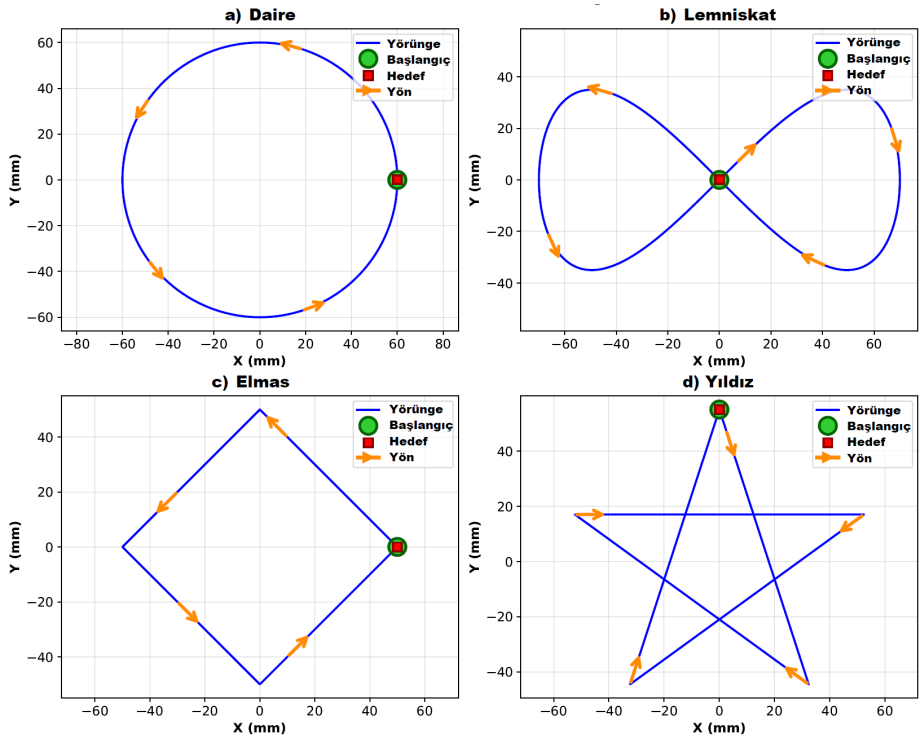
Parametre	**Değer**
Bölüm (episode) sayısı	300
Gizli katman boyutu	64
Deney tekrar havuzu (replay buffer) kapasitesi	5000
Mini-yığın (batch) boyutu	32
İskonto (discount) faktörü (γ)	0.95
Yumuşak güncelleme oranı (τ)	0.01
Aktör öğrenme oranı	0.001
Eleştirmen öğrenme oranı	0.002
Başlangıç gürültü standart sapması	0.3
Gürültü azalma oranı	0.995
Minimum gürültü	0.05
K_p, K_i, K_d aralığı	[20, 100], [0.5, 30], [5, 40]

3. BÖLÜM

KONTROL ÇALIŞMALARI

3.1. Simülasyon Çalışmaları

Bu bölümde, ZN-PID, CC-PID ve önerilen DDPG ile ayarlanmış PID kullanılarak elde edilen yörünge takip sonuçları sunulmaktadır. Her bir referans yörüngenin bu yöntemlerle izlenmesi, Öklid konum hatasının değişimi, eksen bazlı takip performansı ve DDPG eğitimi sırasında öğrenme eğrisi raporlanmakta; ardından RMSE, IAE, ISE, ITAE ve maksimum hata metrikleri kullanılarak nicel bir karşılaştırma yapılmaktadır. Şekil 3.1'de çalışmada kullanılan daire, lemniskat, elmas ve yıldız referans yörüngeleri gösterilmektedir.



Şekil 3.1. Referans yörüngeler: (a) daire, (b) lemniskat, (c) elmas ve (d) yıldız

Şekil 3.1'de mavi çizgiler referans yörüngeyi, yeşil daire başlangıç noktasını, kırmızı kare bitiş noktasını ve turuncu oklar hareket yönünü göstermektedir. Bu yörüngeler için elde edilen nihai PID kazançları Tablo 3.1'de verilmiş; RMSE, IAE, ISE, ITAE ve maksimum hata metriklerine göre performans karşılaştırması ise Tablo 3.2'de sunulmuştur.

Tablo 3.1. Her bir referans yörünge için ZN-PID, CC-PID ve DDPG-PID ile elde edilen PID kazançları

Algoritma	**Yörünge**	K_p	K_i	K_d
ZN-PID	Tümü	75.1566	30.0000	5.0000
CC-PID	Tümü	20.0000	16.0850	5.0000
DDPG-PID	Daire	100.0000	2.5989	40.0000
	Lemniskat	80.7623	2.5983	40.0000
	Elmas	93.1953	21.4166	35.6688
	Yıldız	90.7431	4.0350	39.9378

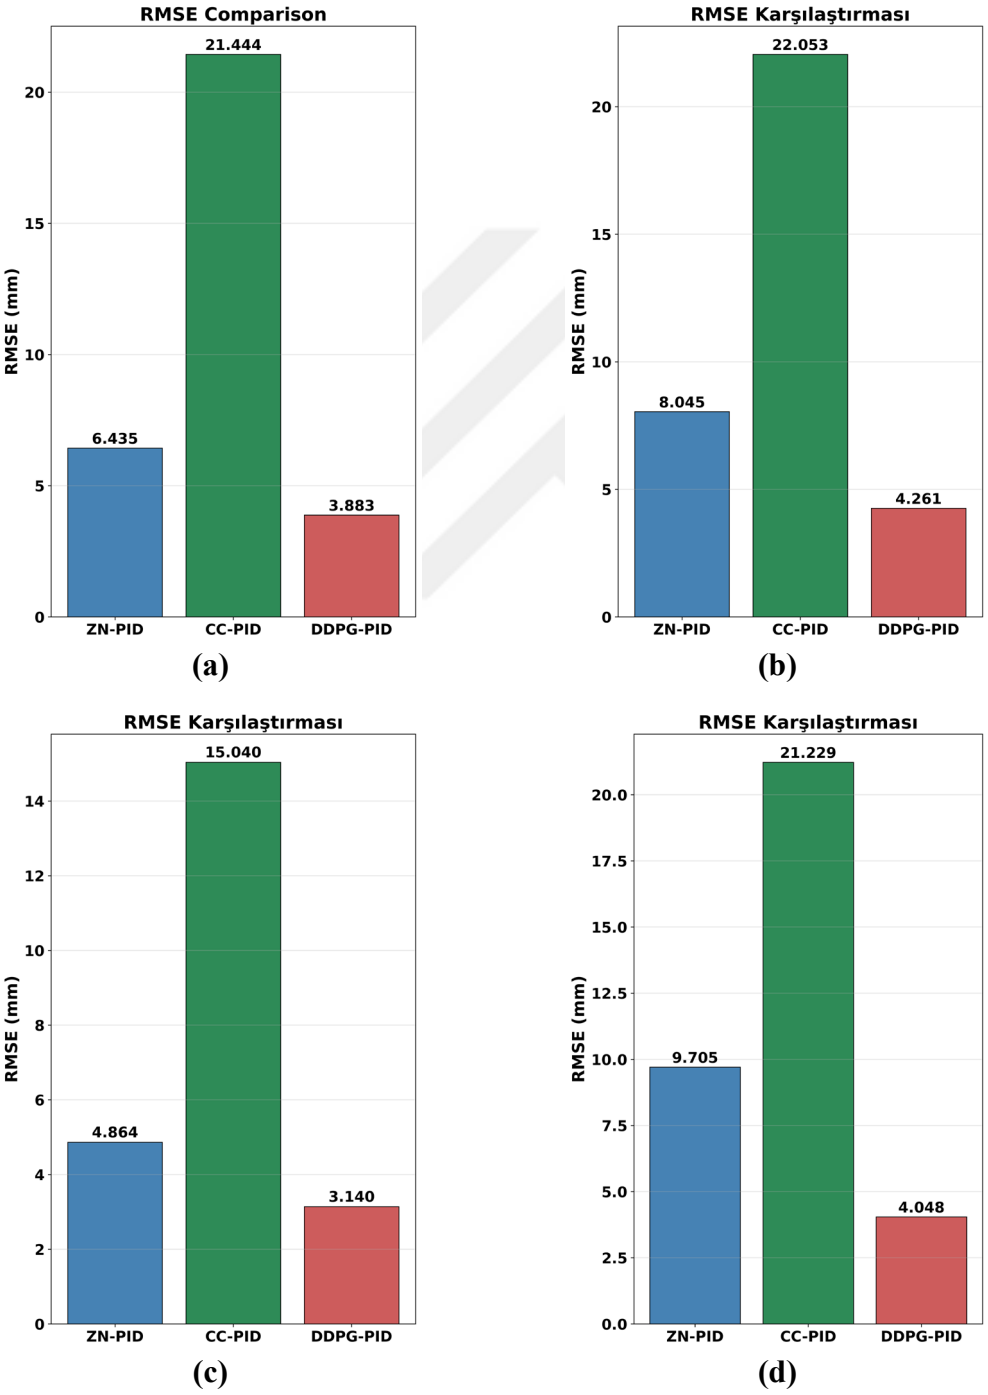
Tablo 3.1'de görüldüğü üzere ZN-PID ve CC-PID yöntemleri, sistem dinamiklerine dayandıkları için tüm yörüngelerde aynı kazanç değerlerini üretmektedir. Buna karşılık DDPG-PID yöntemi, yörüngeye ve mevcut duruma göre kazanç ayarlama davranışı sergilediğinden, her bir yörünge için yaklaşım değişmektedir. Örneğin tabloda görülebileceği gibi, hızlı eğrilik değişimlerinde sönümlemeyi artırma ve aşırı salınımı azaltma hedefiyle tutarlı biçimde daha büyük türev kazançları seçme eğilimindedir.

Tablo 3.2. ZN-PID, CC-PID ve DDPG-PID'nin takip performansı karşılaştırması

Yörünge	**Algoritma**	**RMSE**	**IAE**	**ISE**	**ITAE**	**Maks. Hata**
Daire	ZN-PID	6.4349	25.5508	165.7156	53.1948	7.6029
	CC-PID	21.4438	83.0147	1840.2735	189.0328	26.1163
	DDPG-PID	3.8828	15.3979	60.3345	32.2472	4.0836
Lemniskat	ZN-PID	8.0445	31.0151	258.9859	63.5122	11.8799
	CC-PID	22.0531	84.3503	1946.3296	182.5039	33.5946
	DDPG-PID	4.2609	16.5355	72.6557	33.4048	6.5317
Elmas	ZN-PID	4.8638	18.9247	94.6719	39.2928	7.2689
	CC-PID	15.0398	58.1030	905.2338	131.8042	19.3774
	DDPG-PID	3.1395	12.3587	39.4465	26.7146	3.8342
Yıldız	ZN-PID	9.7045	37.3469	376.9000	76.1837	14.4883
	CC-PID	21.2289	80.6258	1803.5636	165.9283	31.8342
	DDPG-PID	4.0478	15.2534	65.5720	30.3754	6.1379

Tablo 3.2, DDPG-PID'nin tüm yörüngelerde en düşük hata metriklerini sağladığını göstermektedir. ZN-PID'ye kıyasla RMSE azalışı yörüngeye bağlı olarak yaklaşık %35–58 iken, CC-PID'ye göre iyileşme yaklaşık %79–82 düzeyindedir. Bu durum, DDPG

tarafından üretilen kontrol kazançlarının, değişen eğrilik ve köşelenme gereksinimleri altında takip doğruluğunu anlamlı ölçüde artırdığını doğrulamaktadır. Yörüngeler genelinde toplu bir karşılaştırma sunmak amacıyla Şekil 3.2'de, her bir denetleyicinin dört referans yörünge üzerinde elde ettiği RMSE değerleri özetlenmiştir.

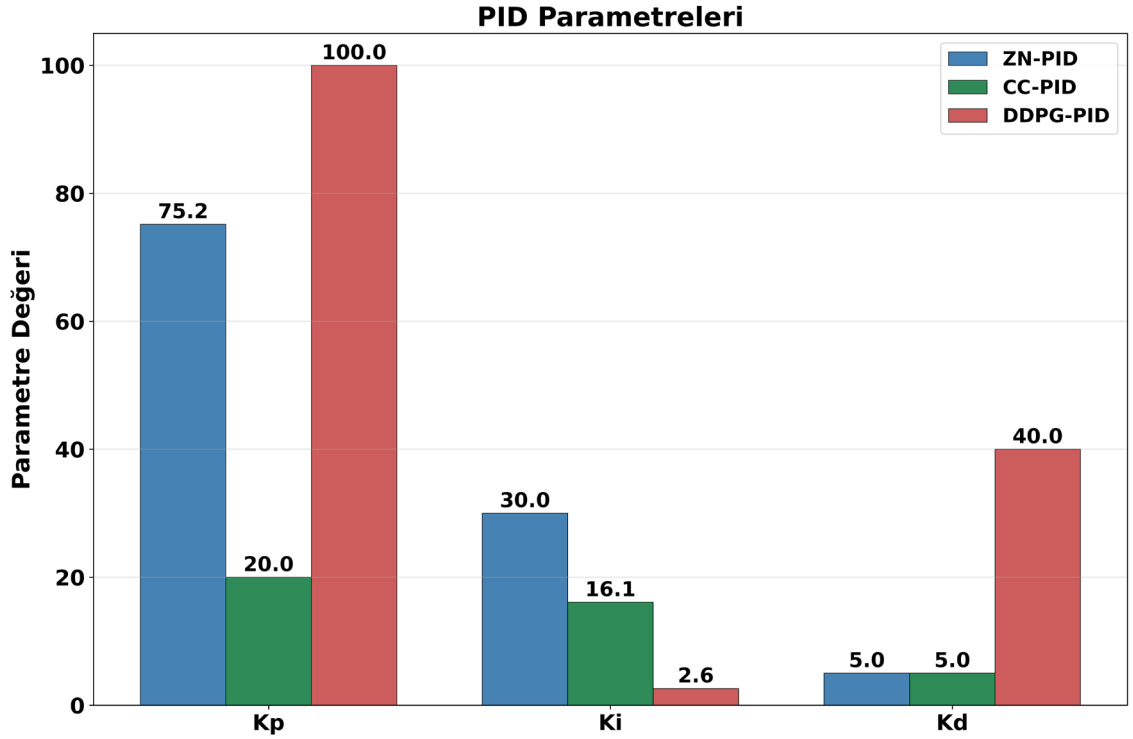


Şekil 3.2. Tüm yörüngeler için ZN-PID, CC-PID ve DDPG-PID RMSE karşılaştırması: (a) daire, (b) lemniskat, (c) elmas ve (d) yıldız

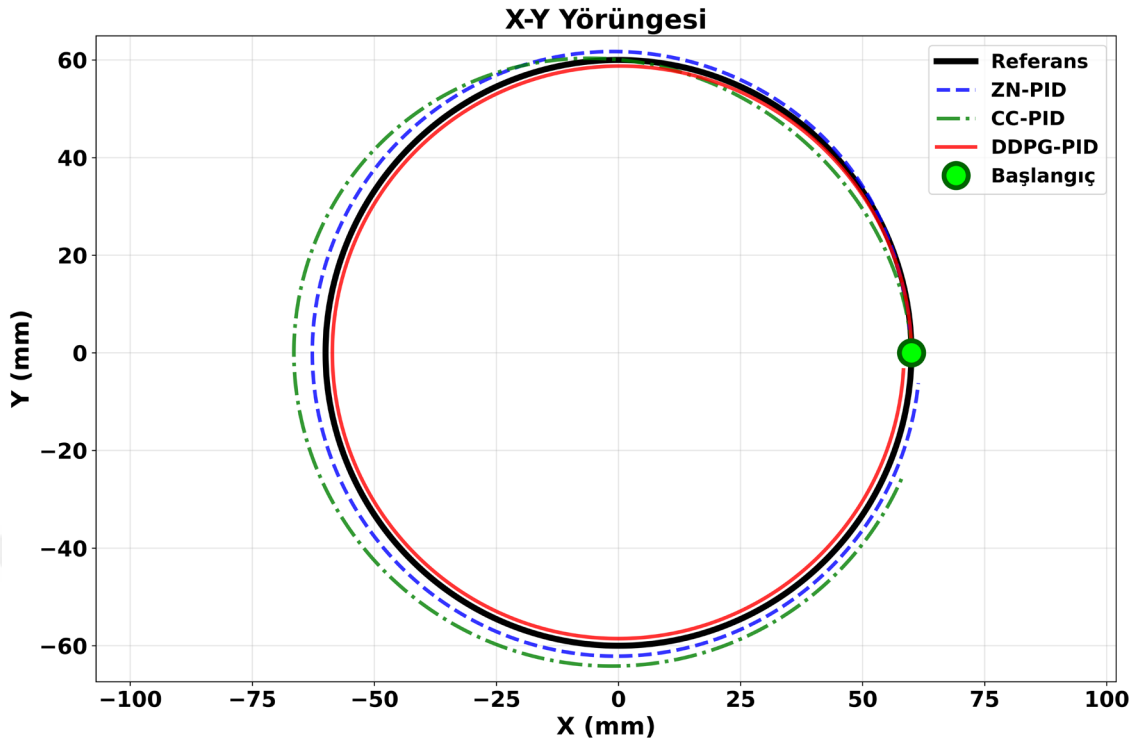
Şekil 3.2, DDPG-PID'nin tüm yörüngelerde tutarlı biçimde en düşük RMSE değerlerini elde ettiğini göstermektedir. Fark özellikle CC-PID'ye karşı belirgindir; bu da CC ayarının, bu çalışmada kullanılan delta robot modelinin doğrusal olmayan ve yörüngeye bağlı dinamikleriyle iyi eşleşmediğine işaret etmektedir.

3.2. Daire Yörünge Sonuçları

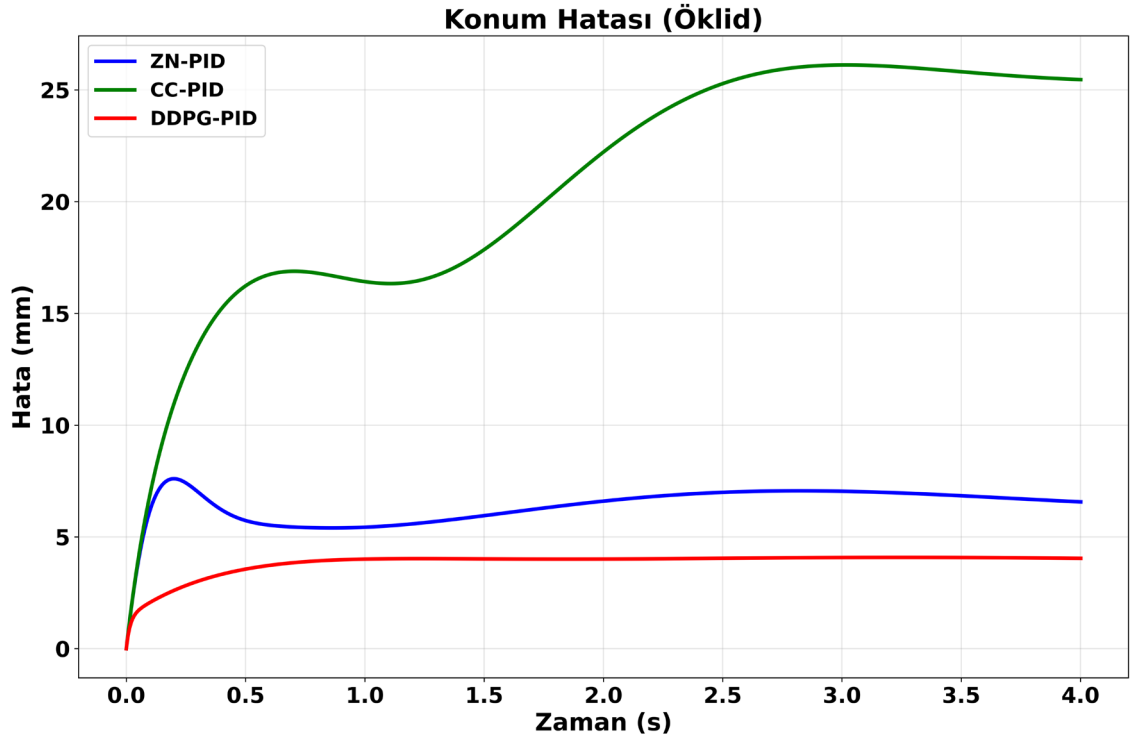
Daire yörünge için elde edilen sonuçlar Şekil 3.3–3.10'da sunulmuştur. Şekil 3.3'te yöntemler ile elde edilen PID parametreleri verilmiştir. Şekil 3.4, X–Y düzlemindeki yörünge takibini; Şekil 3.5, Öklid konum hatasını; Şekil 3.6 ve 3.7 sırası ile X ve Y eksenlerindeki takip sonuçlarını, Şekil 3.8 ve 3.9 ise sırası ile X ve Y eksenlerindeki takip hatalarını; Şekil 3.10 ise DDPG öğrenme eğrisini göstermektedir.



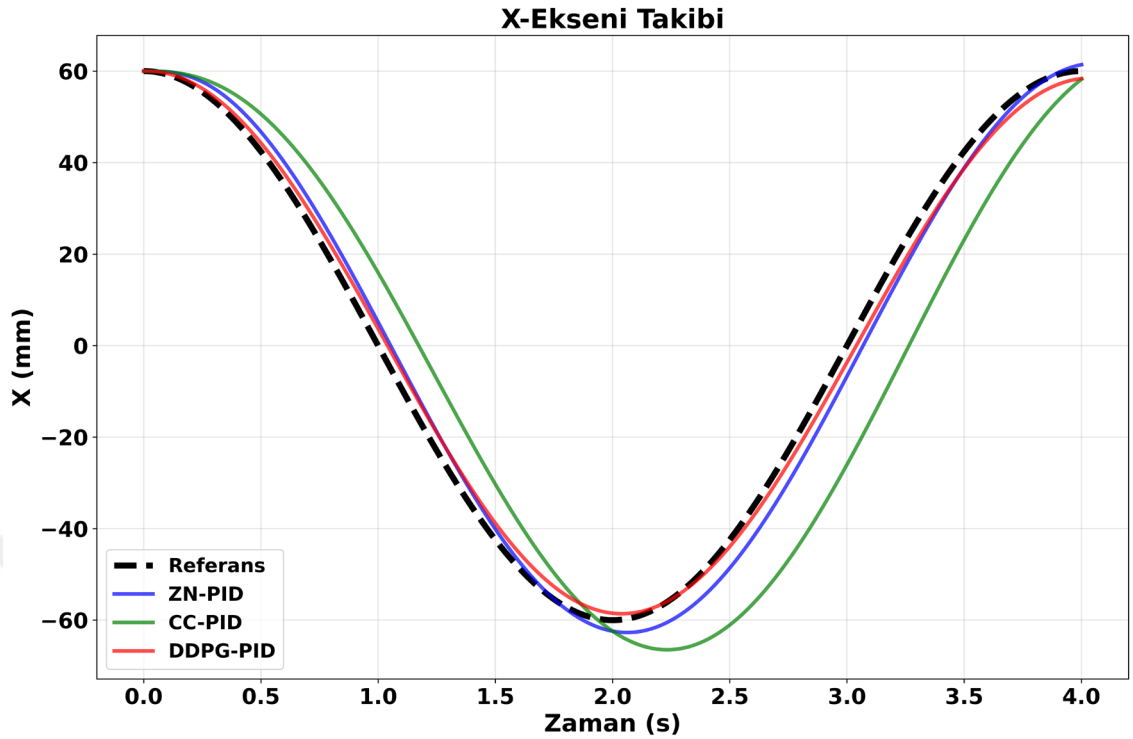
Şekil 3.3. Daire yörünge için yöntemlerin tespit ettiği PID parametrelerinin bar çizelgesi



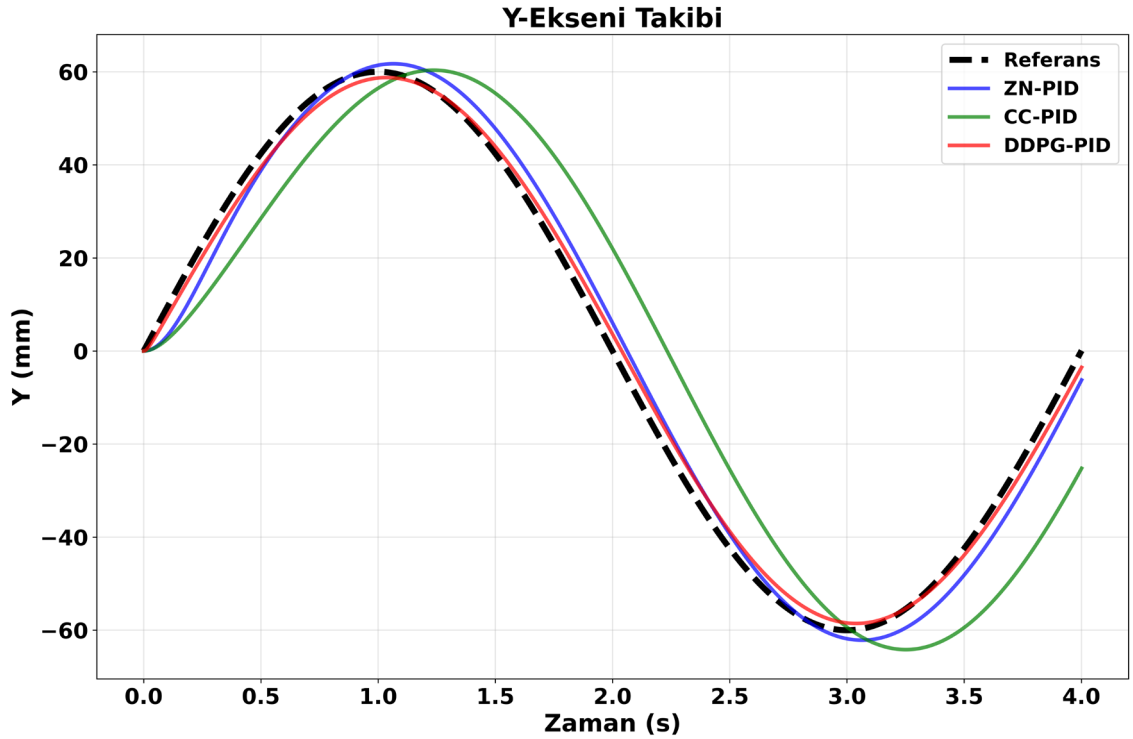
Şekil 3.4. X–Y düzleminde daire yörünge takip performansları



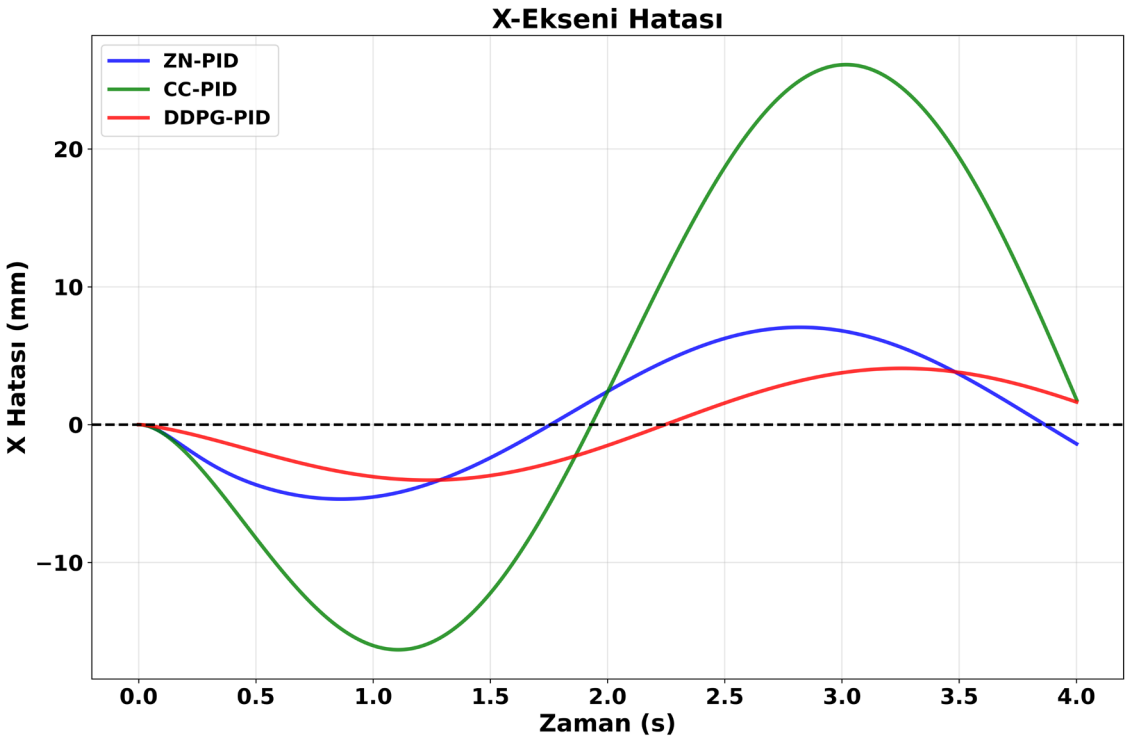
Şekil 3.5. Daire yörünge için Öklid konum hatası



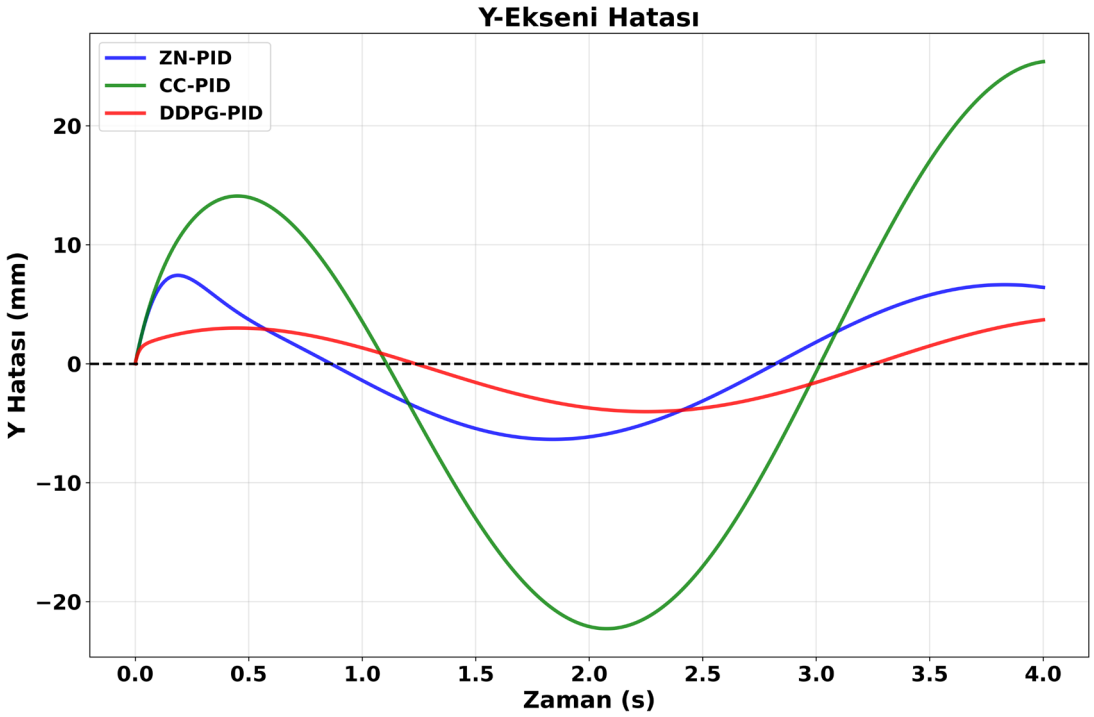
Şekil 3.6. Daire yörünge için X-ekseni takibi



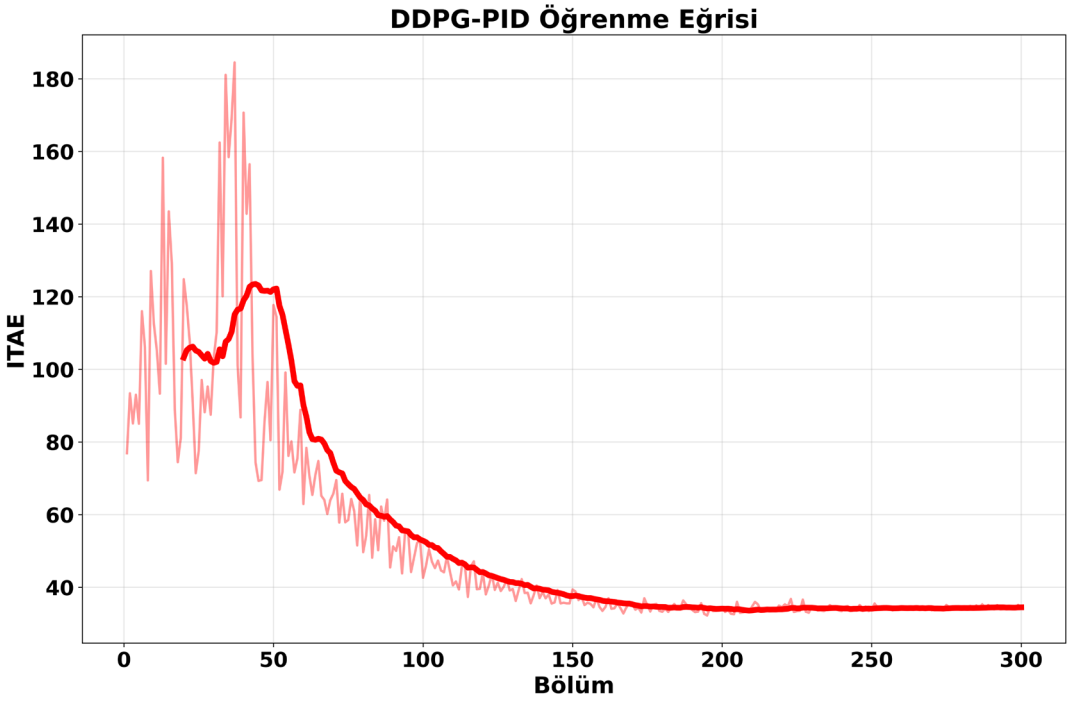
Şekil 3.7. Daire yörünge için Y-ekseni takibi



Şekil 3.8. Daire yörünge için X-ekseni takip hatası



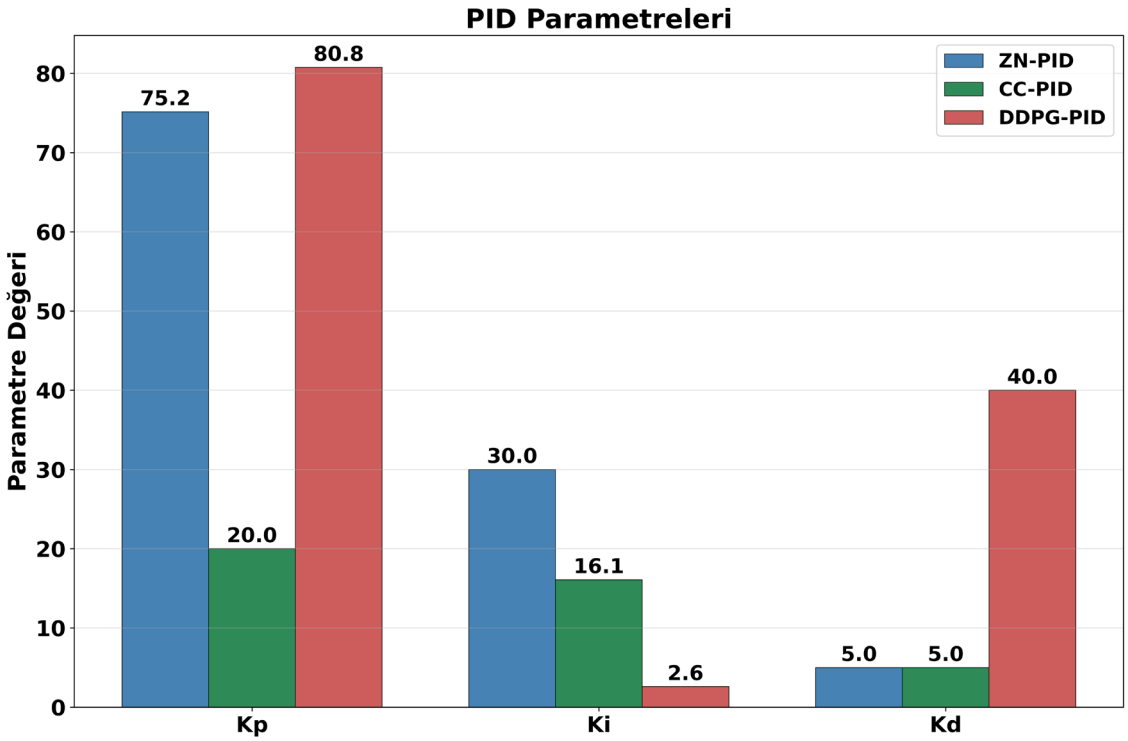
Şekil 3.9. Daire yörünge için Y-ekseni takip hatası



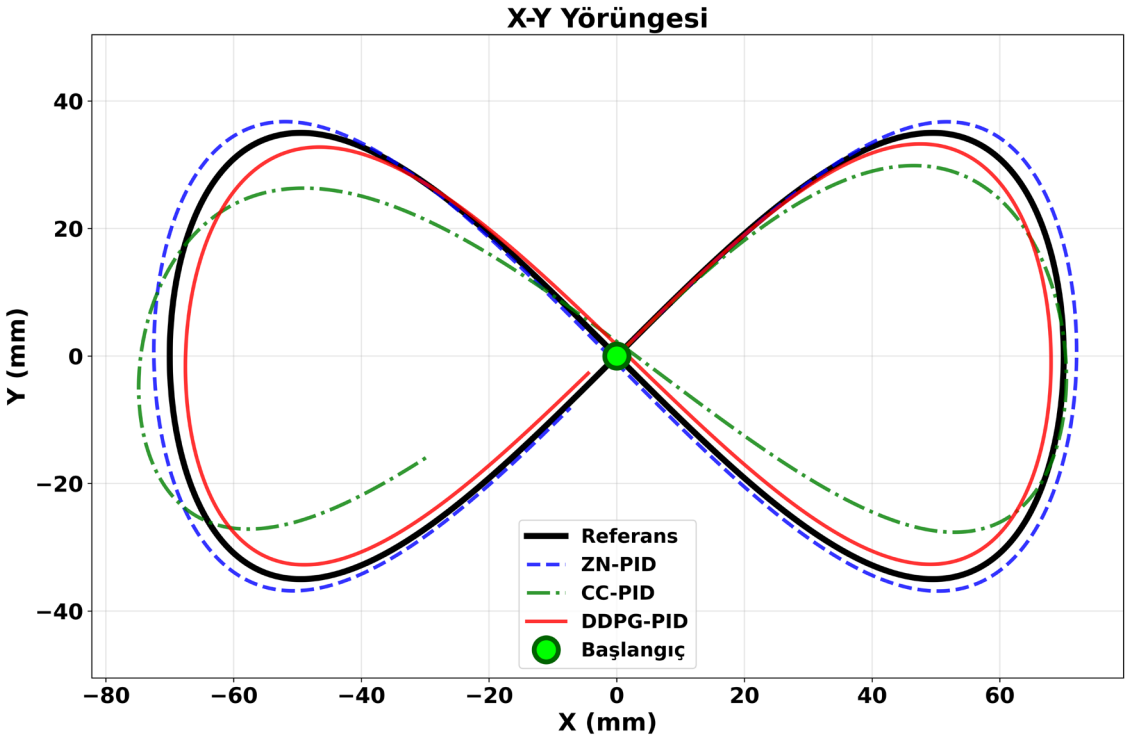
Şekil 3.10. Daire yörünge için DDPG öğrenme eğrisi (ITAE)

3.3. Lemniskat Yörünge Sonuçları

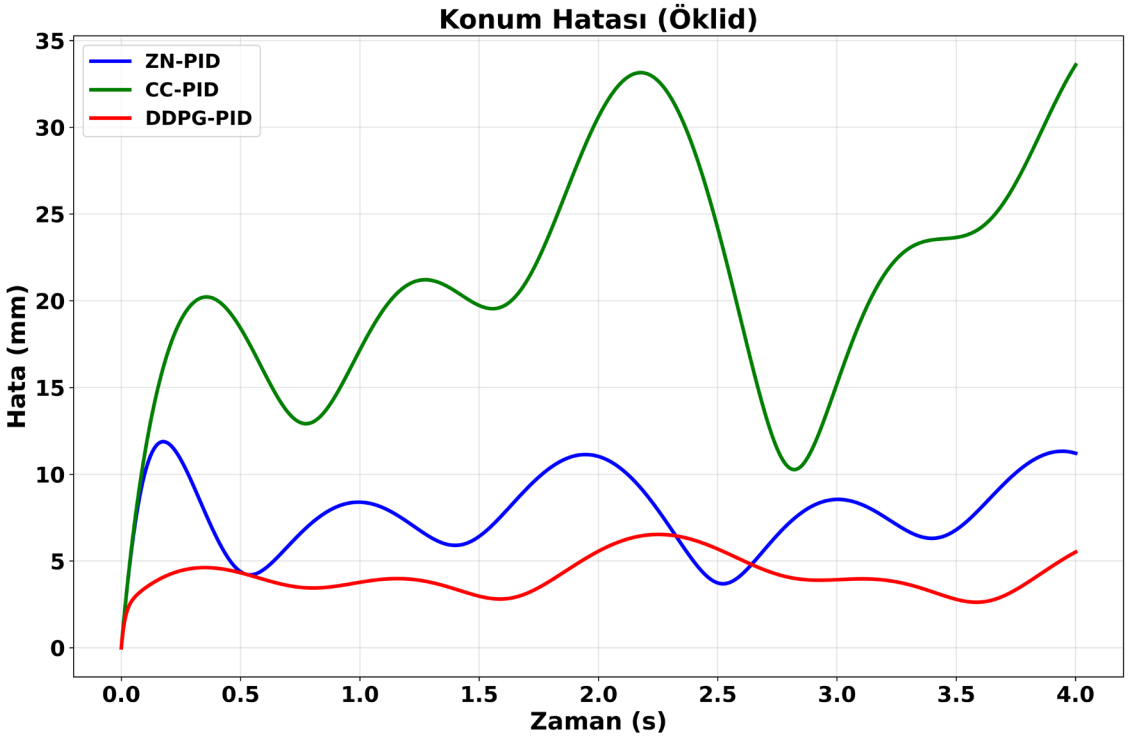
Lemniskat yörünge için elde edilen sonuçlar Şekil 3.11–3.18'de sunulmuştur. Şekil 3.11'de yöntemler ile elde edilen PID parametreleri verilmiştir. Şekil 3.12, X–Y düzlemindeki yörünge takibini; Şekil 3.13, Öklid konum hatasını; Şekil 3.14 ve 3.15 sırası ile X ve Y eksenlerindeki takip sonuçlarını, Şekil 3.16 ve 3.17 ise sırası ile X ve Y eksenlerindeki takip hatalarını; Şekil 3.18 ise DDPG öğrenme eğrisini göstermektedir.



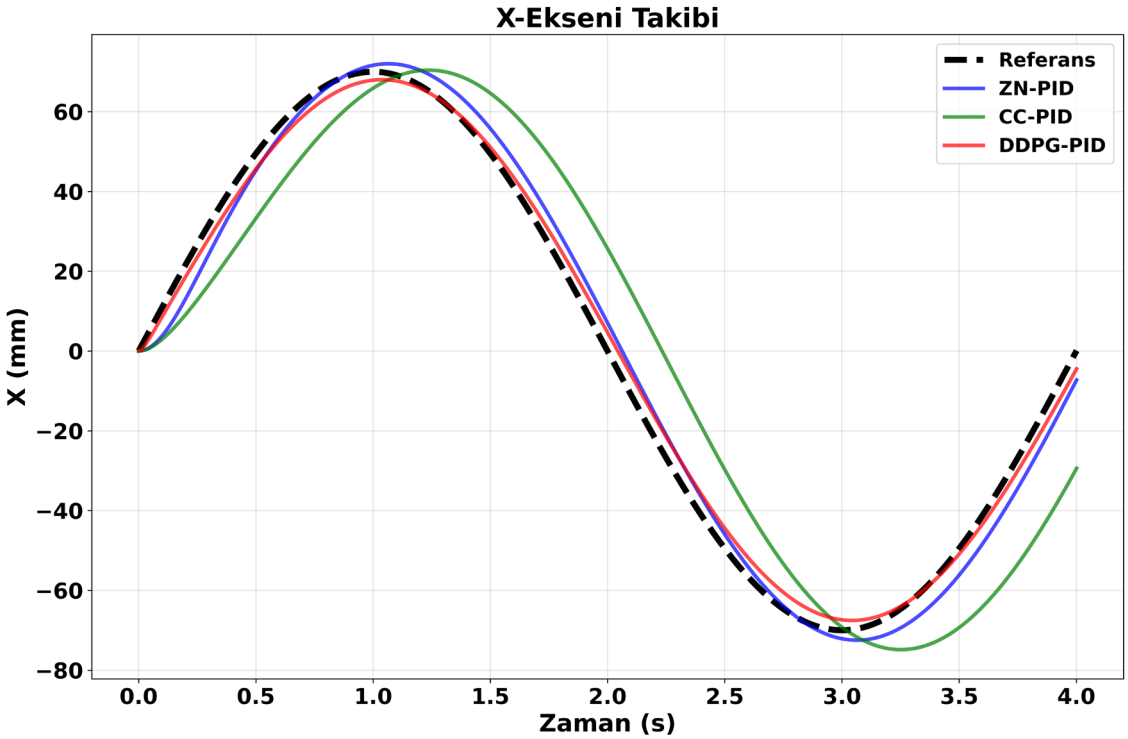
Şekil 3.11. Lemniskat yörünge için yöntemlerin tespit ettiği PID parametrelerinin bar çizelgesi



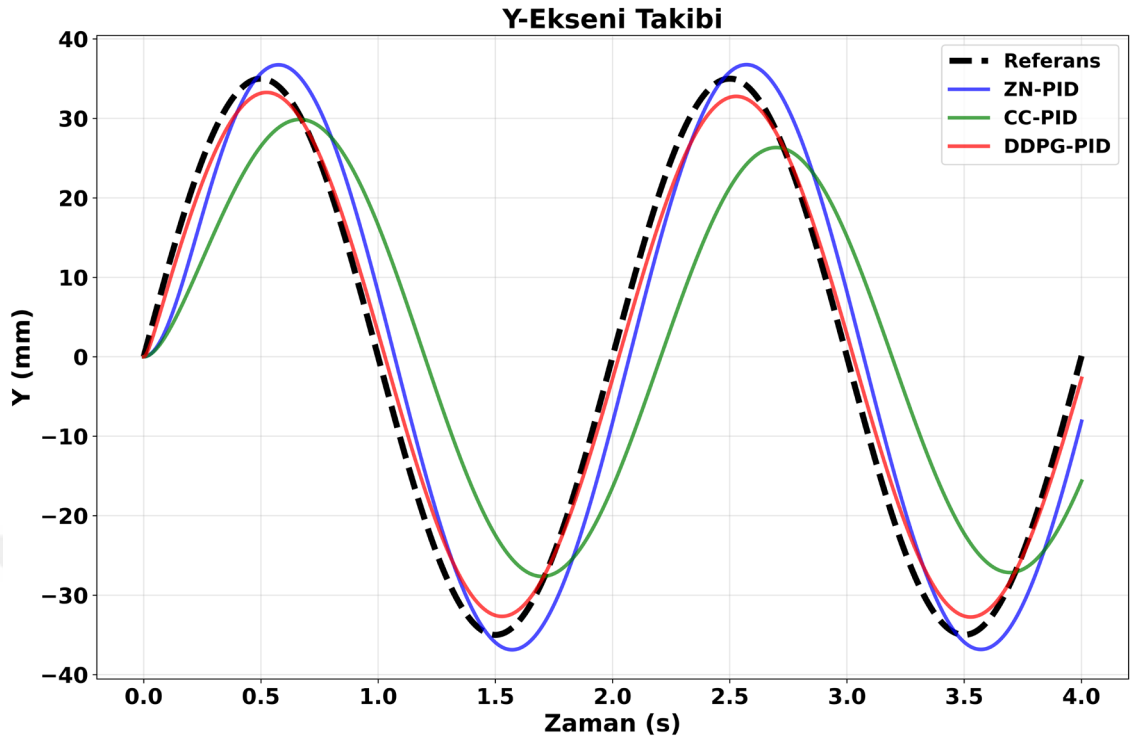
Şekil 3.12. X–Y düzleminde lemniskat yörünge takip performansları



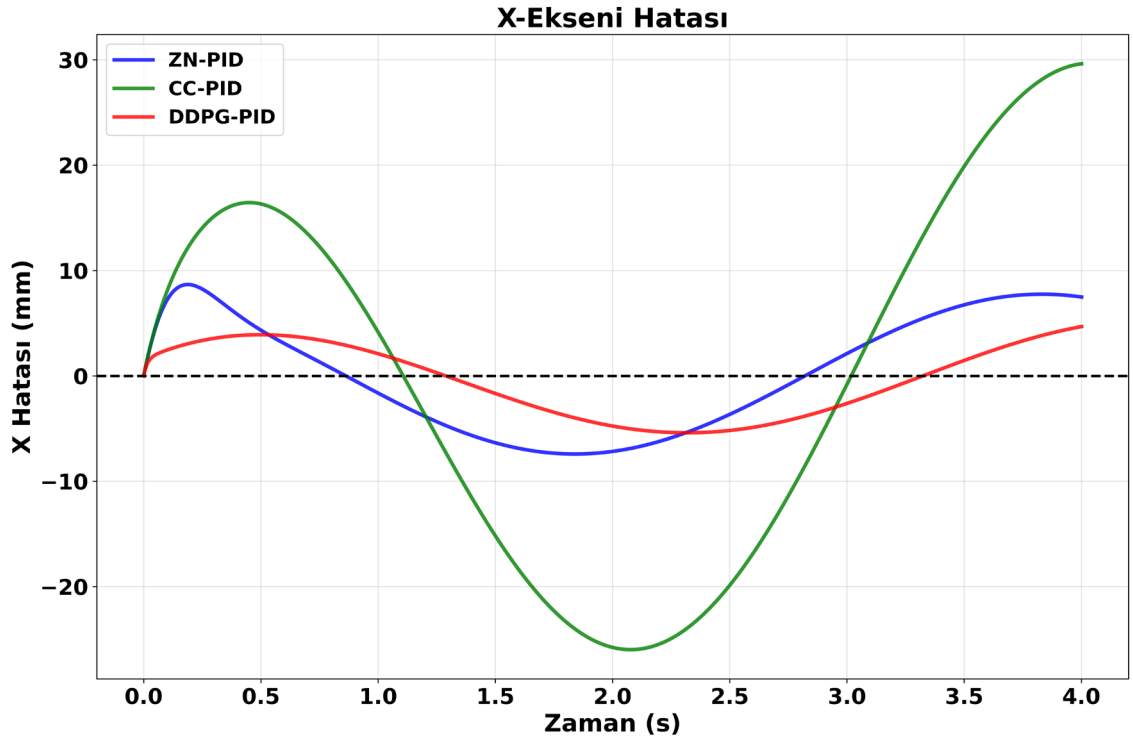
Şekil 3.13. Lemniskat yörünge için Öklid konum hatası



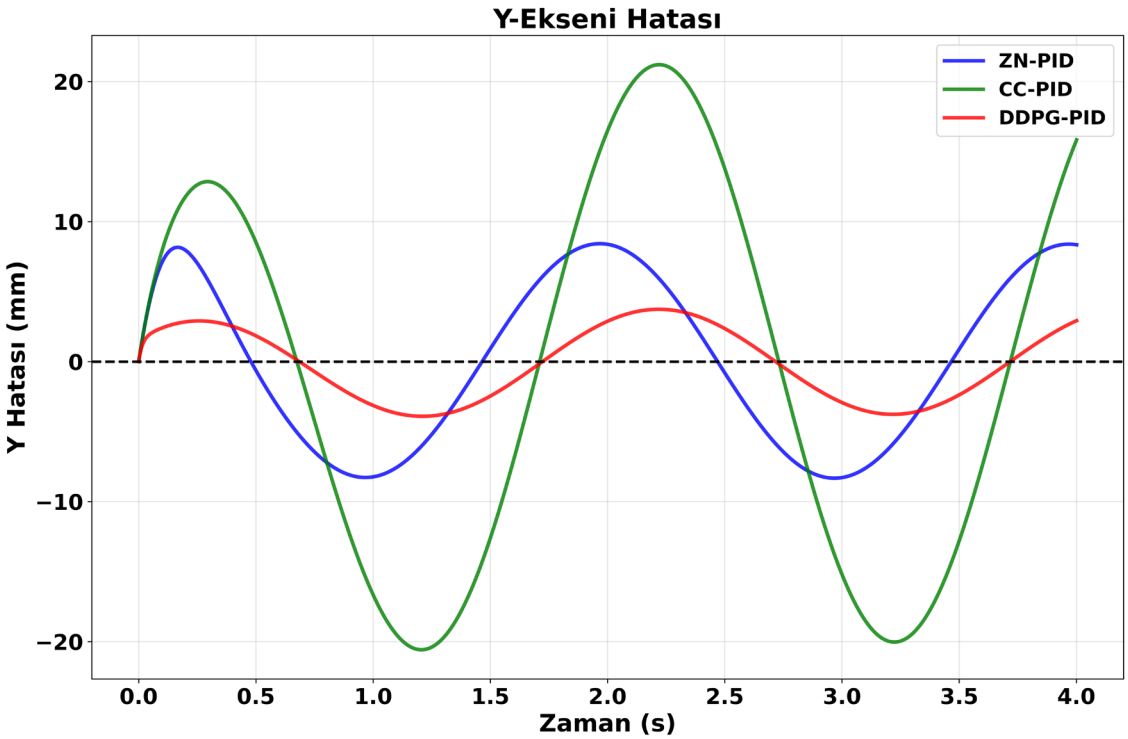
Şekil 3.14. Lemniskat yörünge için X-ekseni takibi



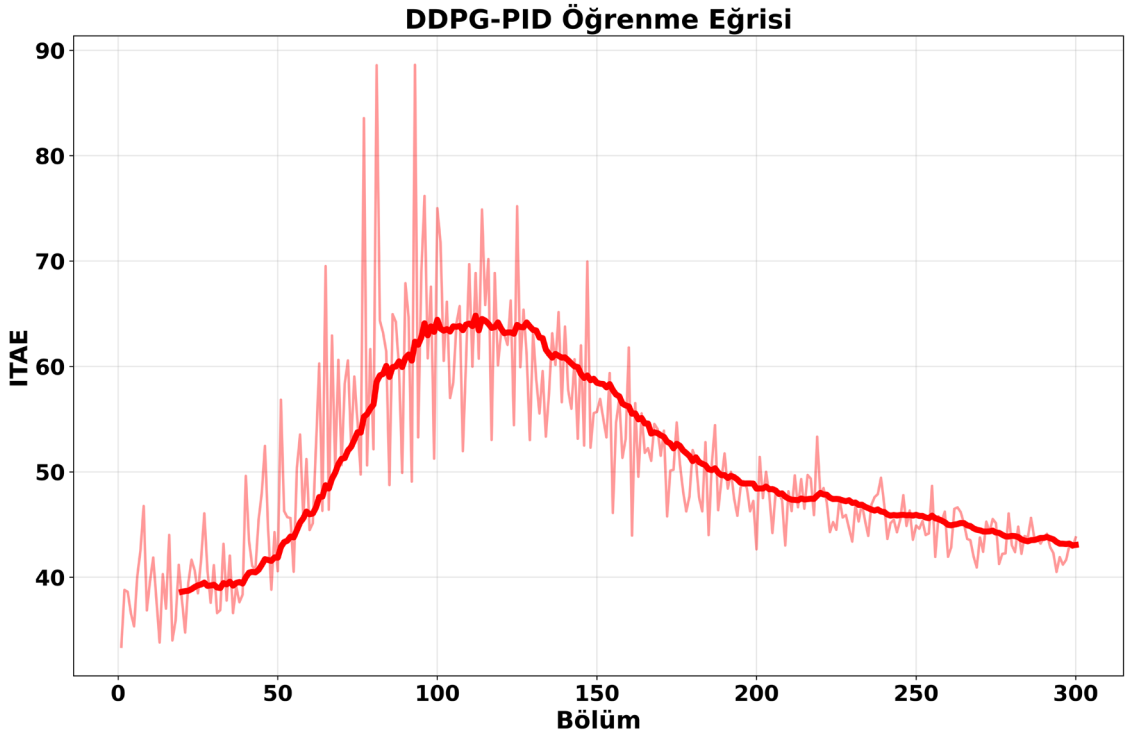
Şekil 3.15. Lemniskat yörünge için Y-ekseni takibi



Şekil 3.16. Lemniskat yörünge için X-ekseni takip hatası



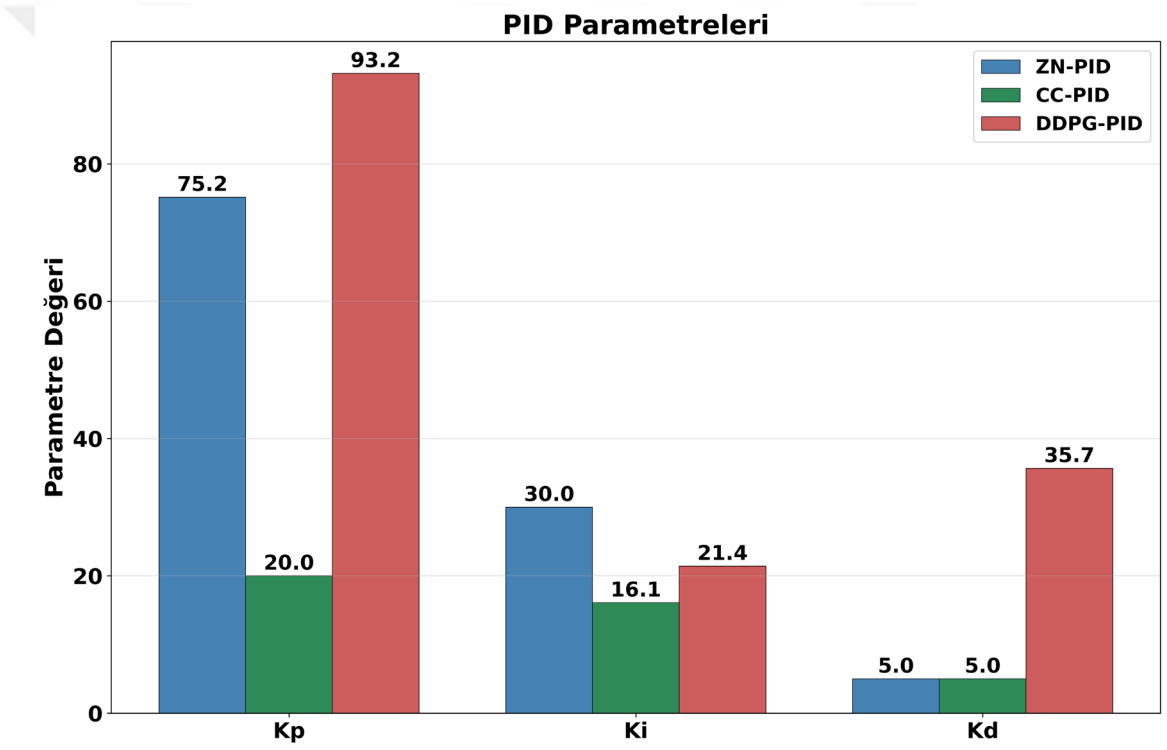
Şekil 3.17. Lemniskat yörünge için Y-ekseni takip hatası



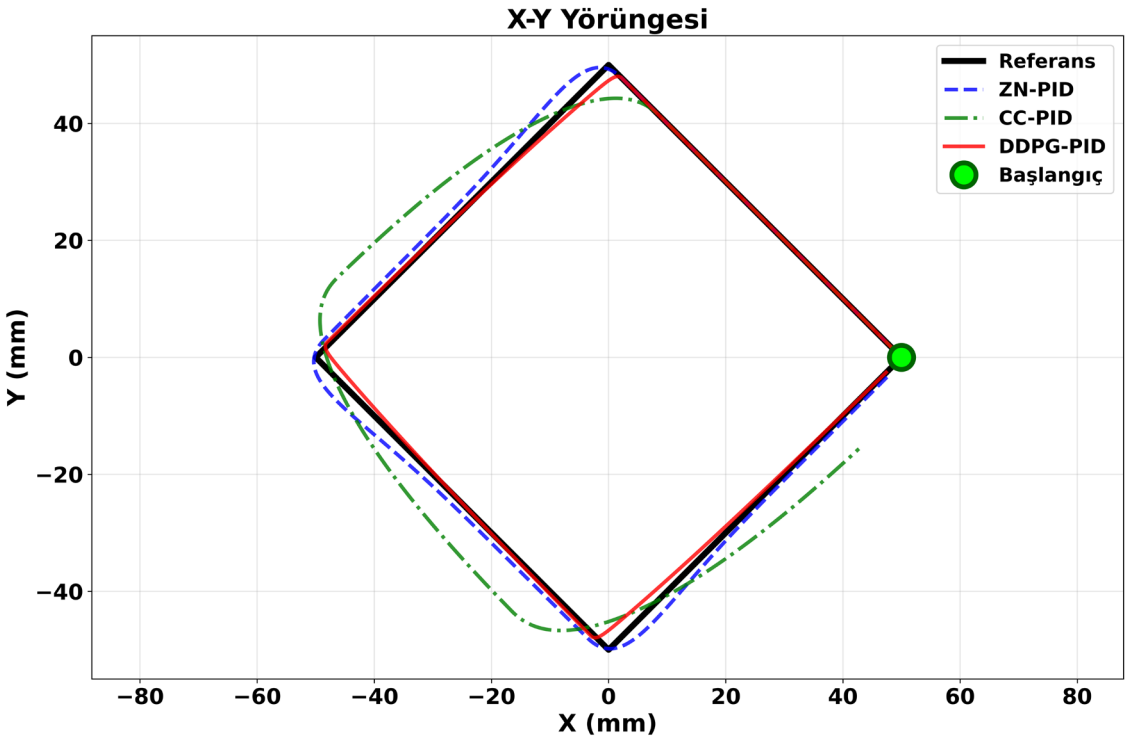
Şekil 3.18. Lemniskat yörünge için DDPG öğrenme eğrisi (ITAE)

3.4. Elmas Yörünge Sonuçları

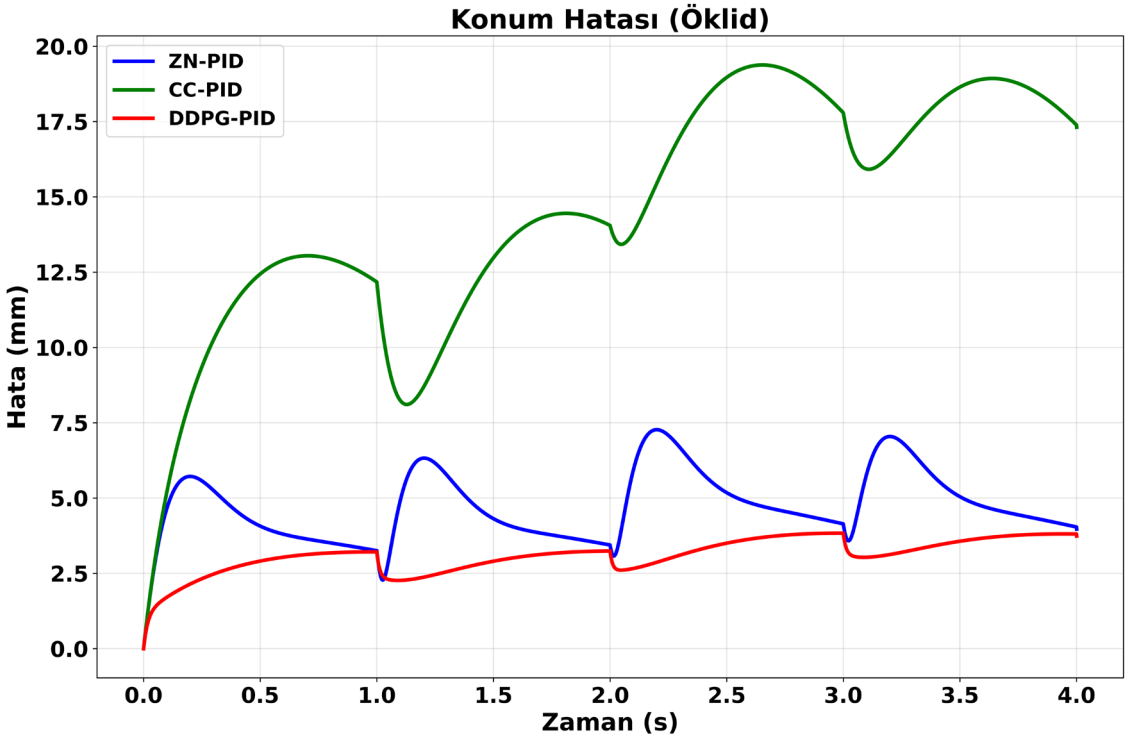
Elmas yörünge için elde edilen sonuçlar Şekil 3.19–3.26'da sunulmuştur. Şekil 3.19'da yöntemler ile elde edilen PID parametreleri verilmiştir. Şekil 3.20, X–Y düzlemindeki yörünge takibini; Şekil 3.21, Öklid konum hatasını; Şekil 3.22 ve 3.23 sırası ile X ve Y eksenlerindeki takip sonuçlarını, Şekil 3.24 ve 3.25 ise sırası ile X ve Y eksenlerindeki takip hatalarını; Şekil 3.26 ise DDPG öğrenme eğrisini göstermektedir.



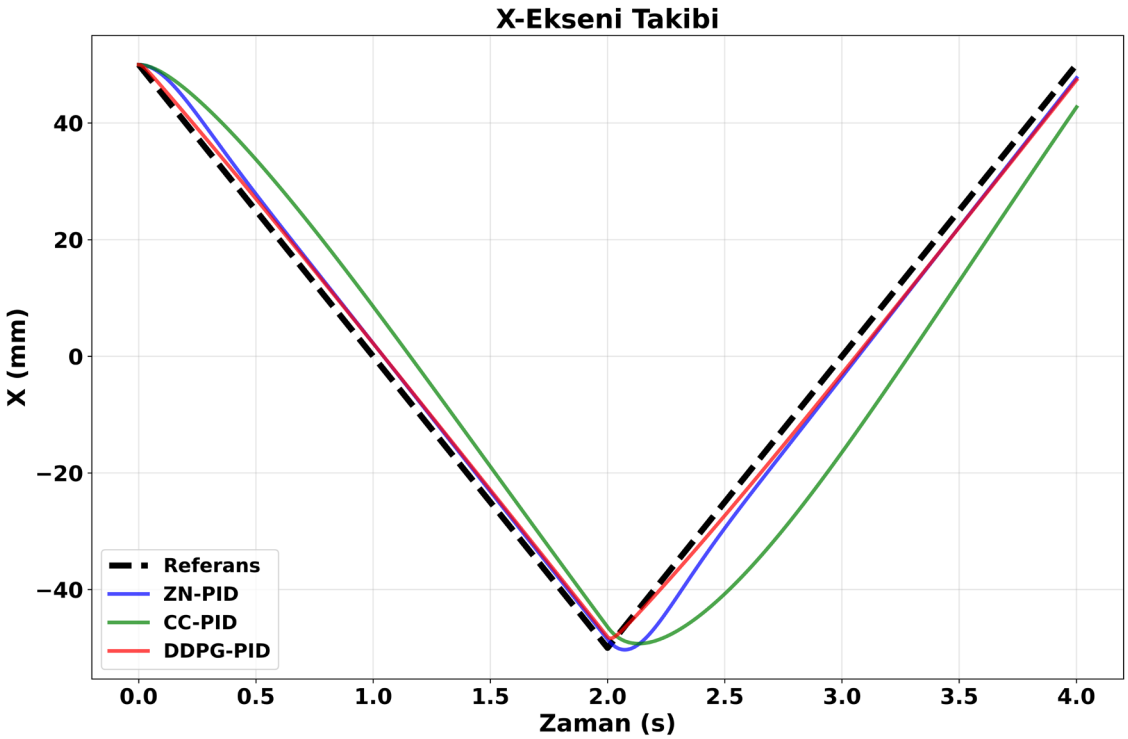
Şekil 3.19. Elmas yörünge için yöntemlerin tespit ettiği PID parametrelerinin bar çizelgesi



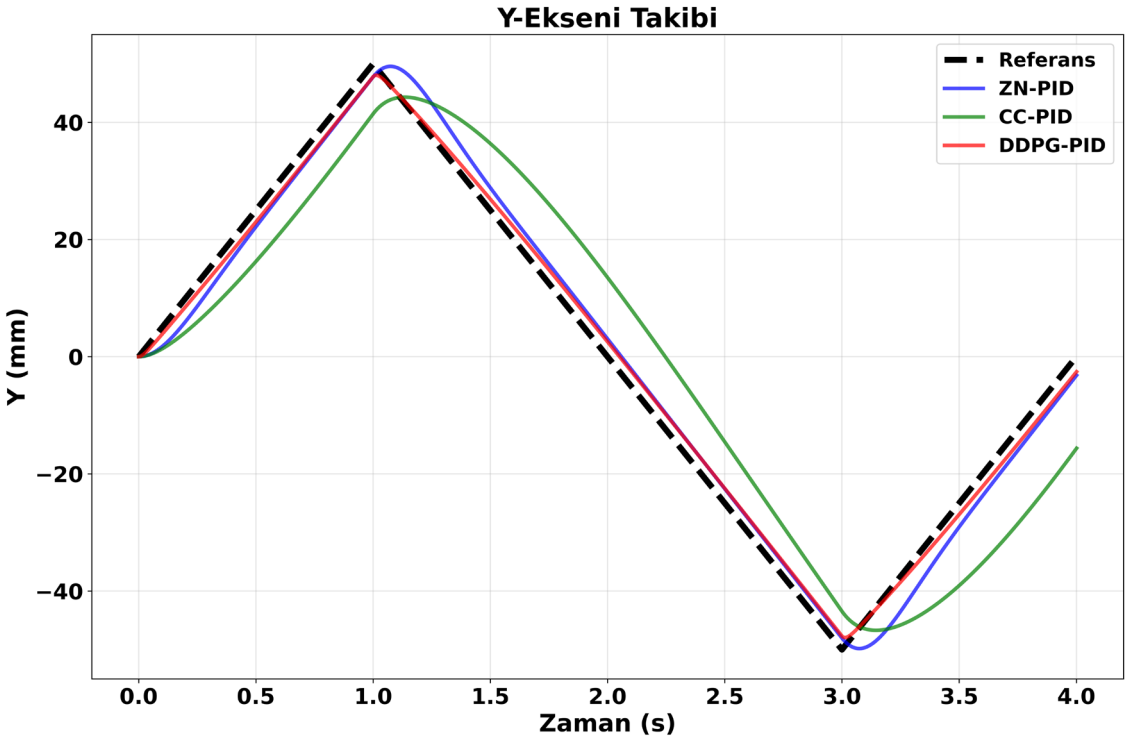
Şekil 3.20. X–Y düzleminde elmas yörünge takip performansları



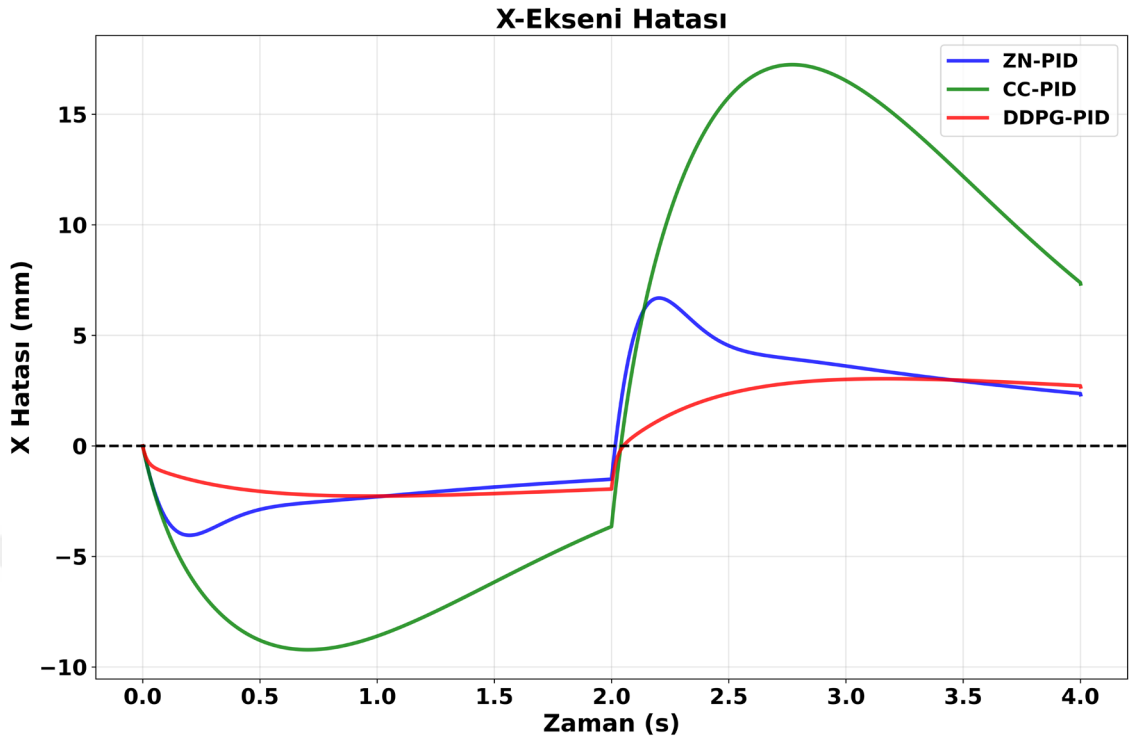
Şekil 3.21. Elmas yörünge için Öklid konum hatası



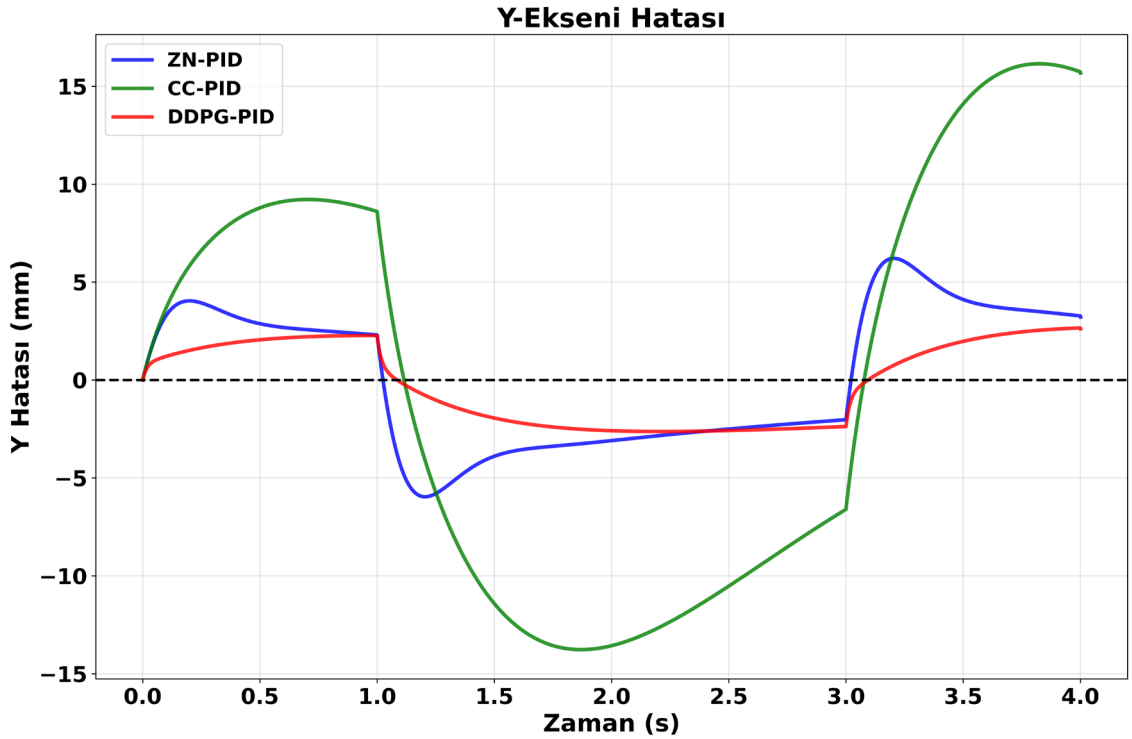
Şekil 3.22. Elmas yörünge için X-ekseni takibi



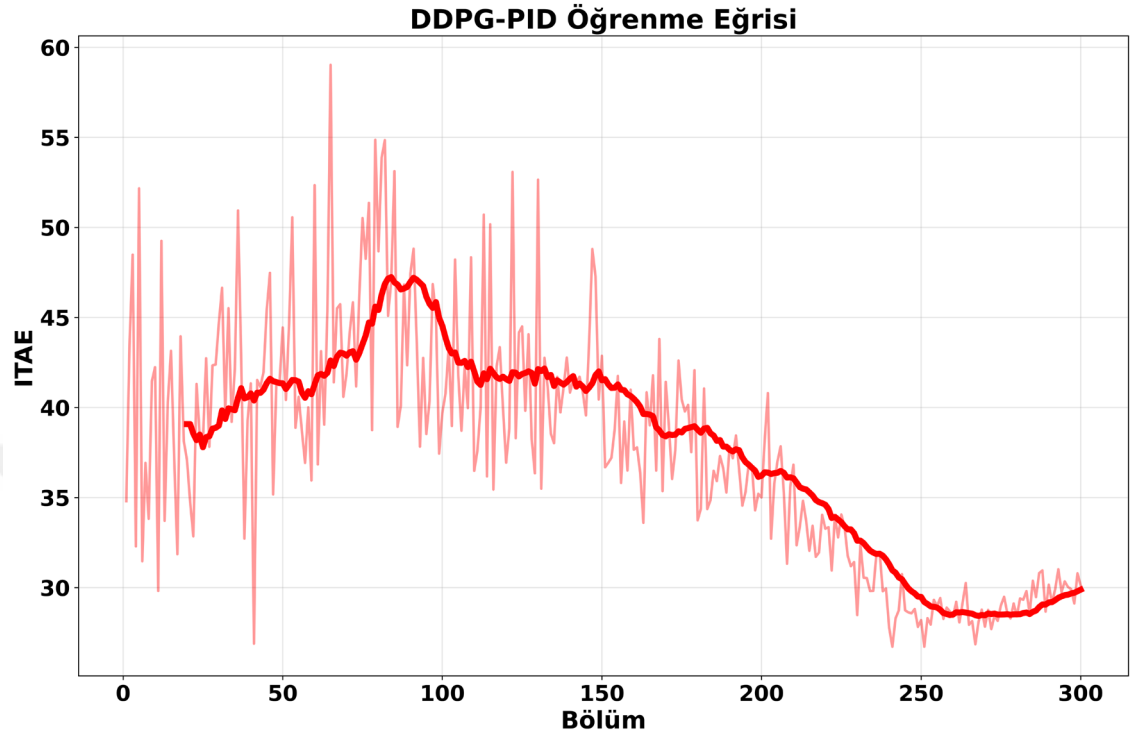
Şekil 3.23. Elmas yörünge için Y-ekseni takibi



Şekil 3.24. Elmas yörünge için X-ekseni takip hatası



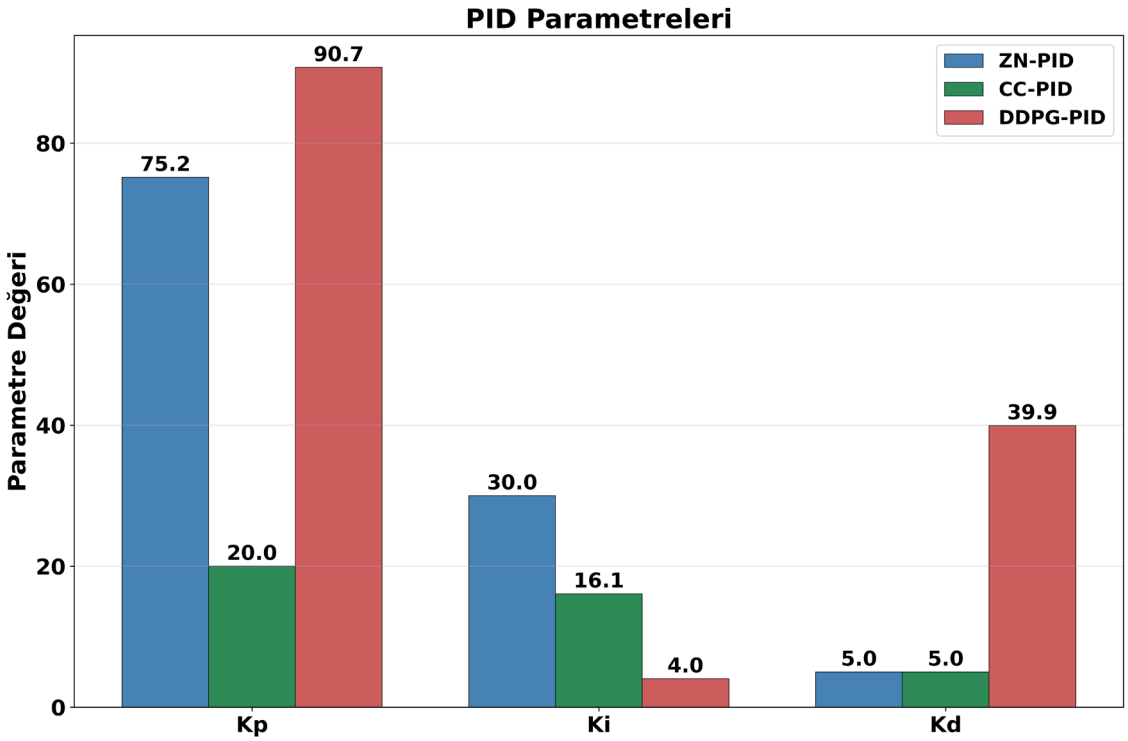
Şekil 3.25. Elmas yörünge için Y-ekseni takip hatası



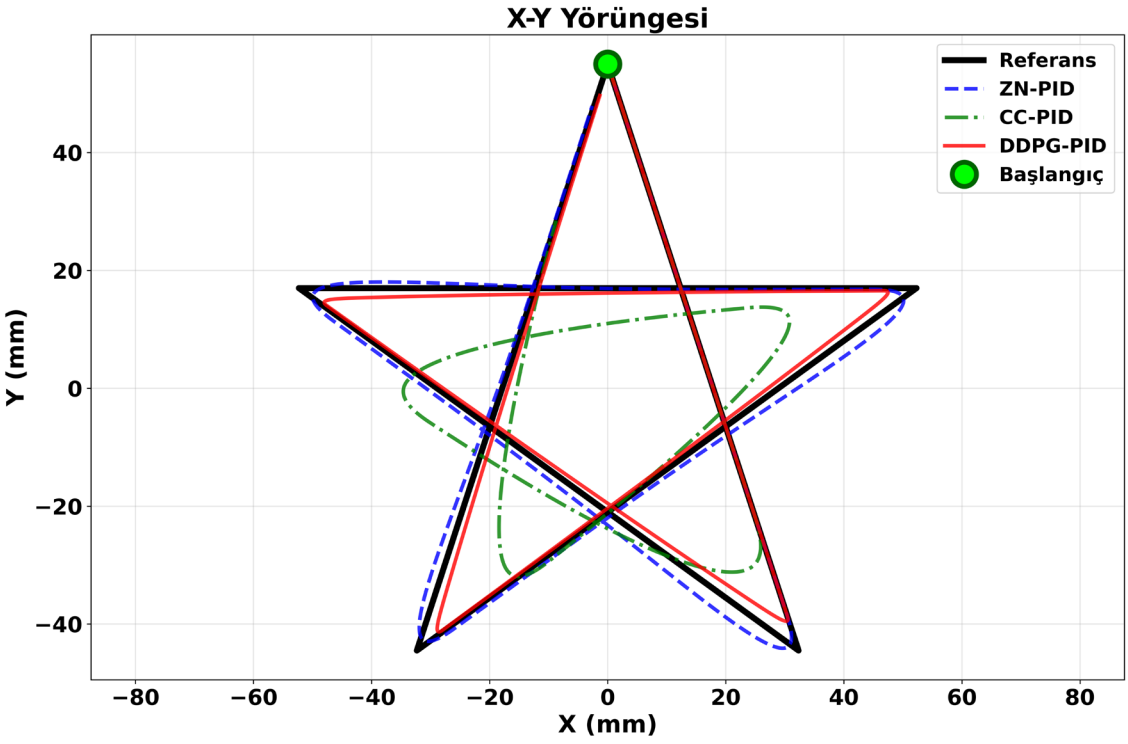
Şekil 3.26. Elmas yörünge için DDPG öğrenme eğrisi (ITAE)

3.5. Yıldız Yörünge Sonuçları

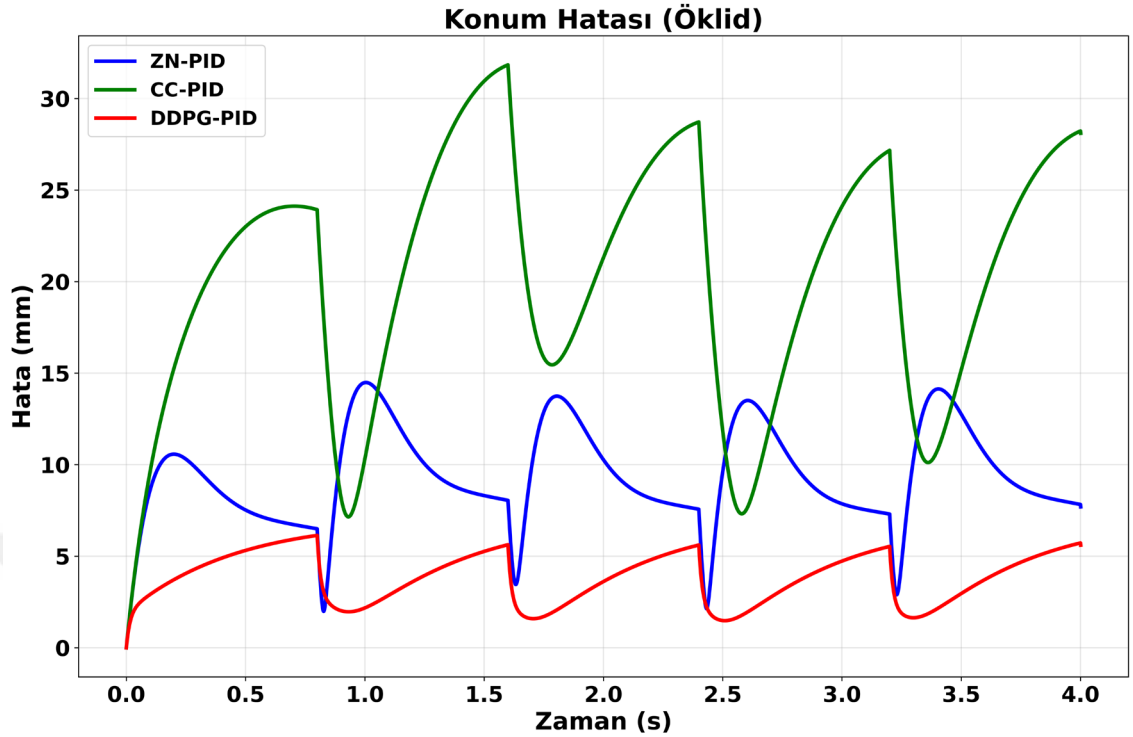
Yıldız yörünge için elde edilen sonuçlar Şekil 3.27–3.34'te sunulmuştur. Şekil 3.27'de yöntemler ile elde edilen PID parametreleri verilmiştir. Şekil 3.28, X–Y düzlemindeki yörünge takibini; Şekil 3.29, Öklid konum hatasını; Şekil 3.30 ve 3.31 sırası ile X ve Y eksenlerindeki takip sonuçlarını, Şekil 3.32 ve 3.33 ise sırası ile X ve Y eksenlerindeki takip hatalarını; Şekil 3.34 ise DDPG öğrenme eğrisini göstermektedir.



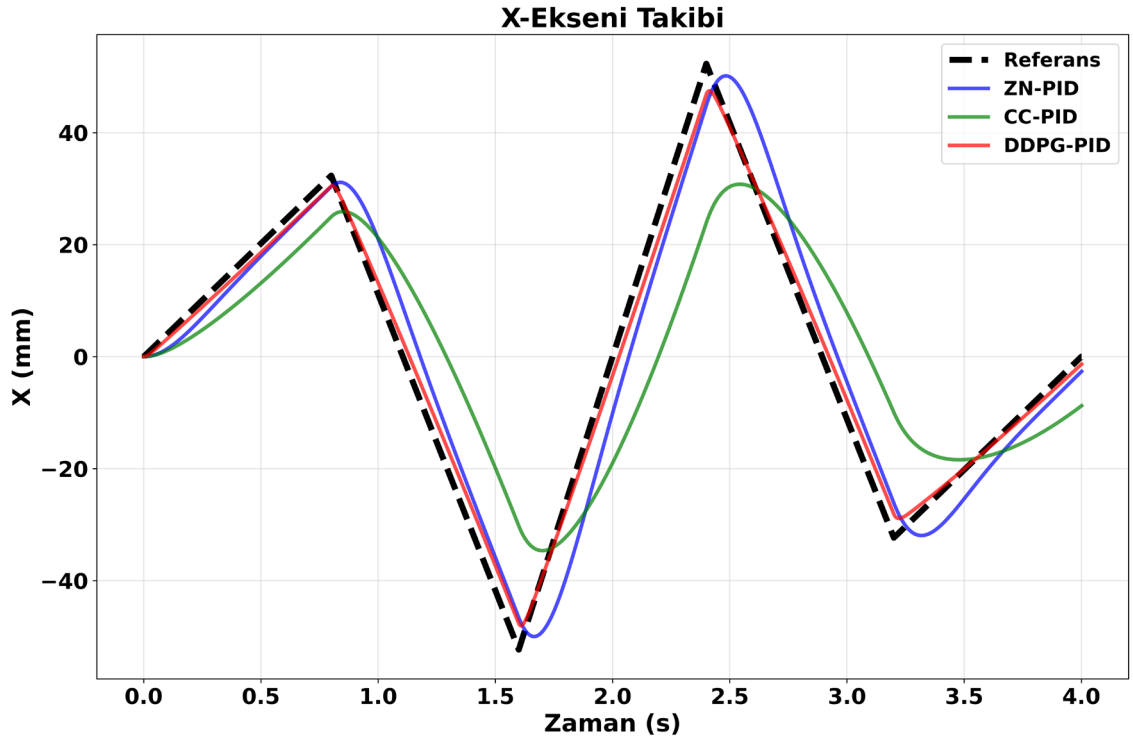
Şekil 3.27. Yıldız yörünge için yöntemlerin tesit ettiği PID parametrelerinin bar çizelgesi



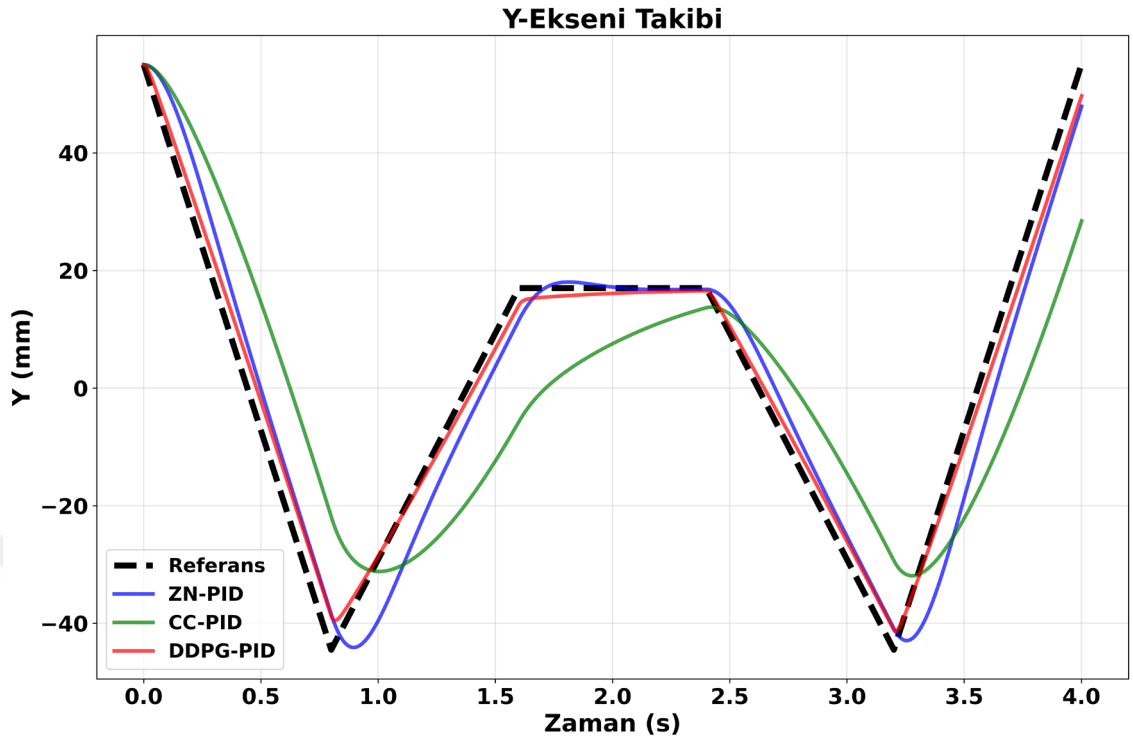
Şekil 3.28. X–Y düzleminde yıldız yörünge takip performansları



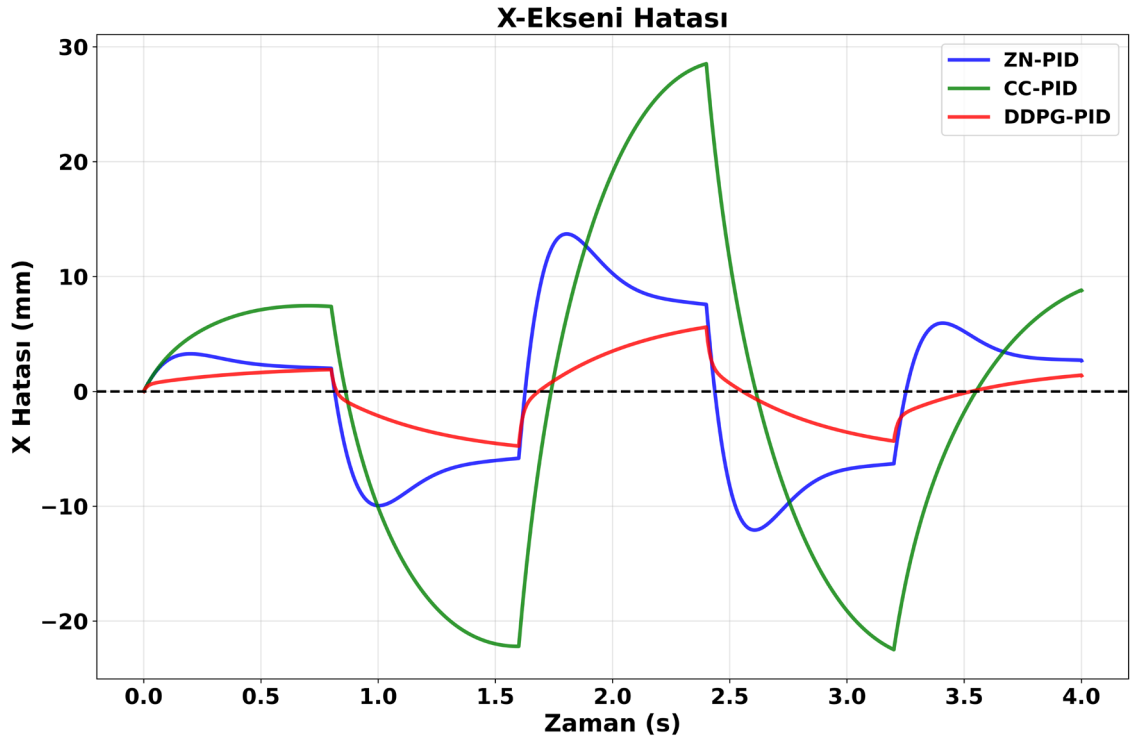
Şekil 3.29. Yıldız yörünge için Öklid konum hatası



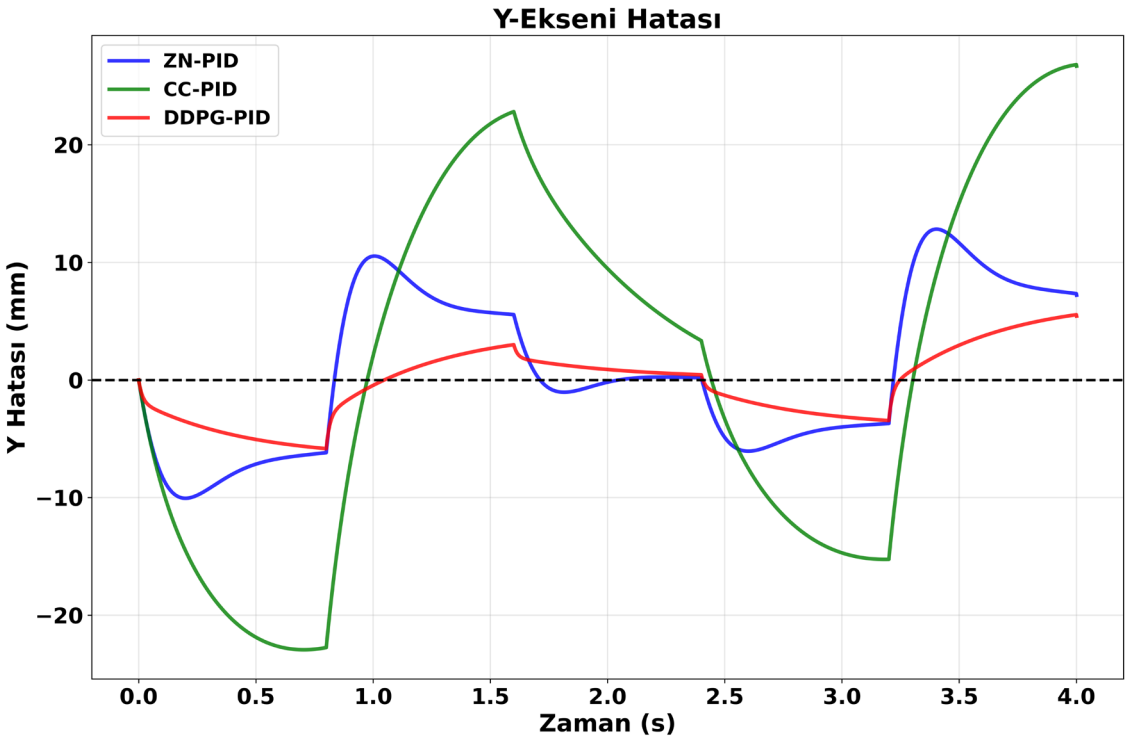
Şekil 3.30. Yıldız yörünge için X-ekseni takibi



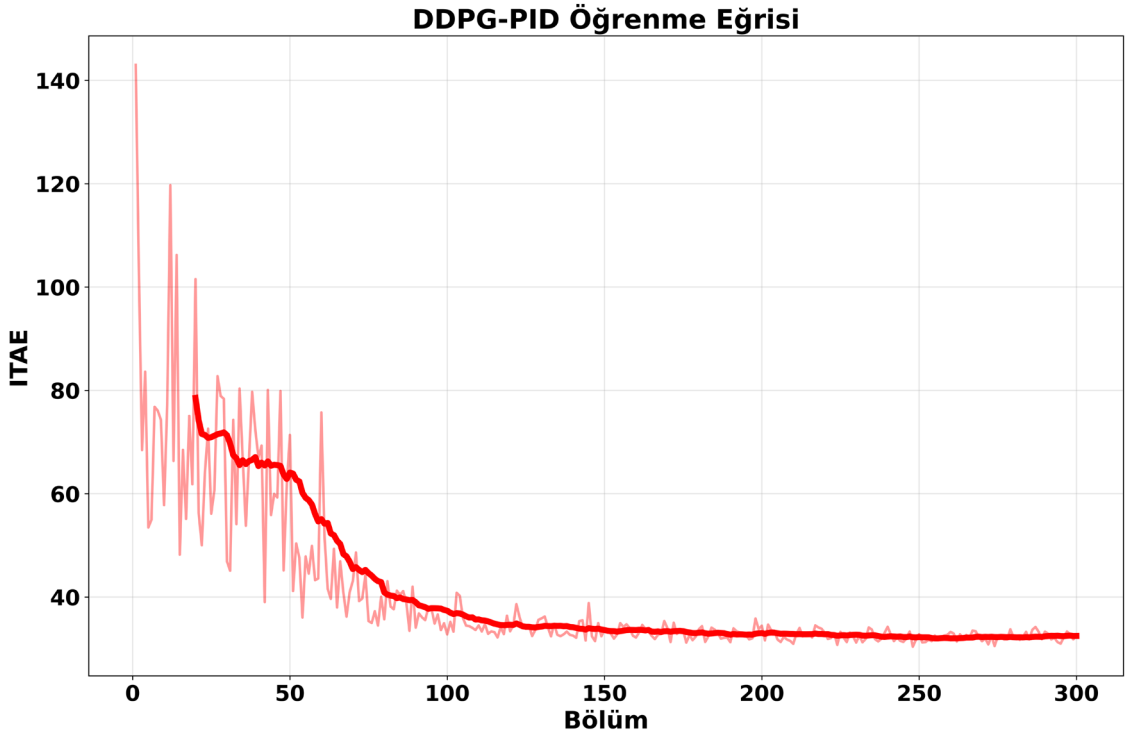
Şekil 3.31. Yıldız yörünge için Y-ekseni takibi



Şekil 3.32. Yıldız yörünge için X-ekseni takip hatası



Şekil 3.33. Yıldız yörünge için Y-ekseni takip hatası



Şekil 3.34. Yıldız yörünge için DDPG öğrenme eğrisi (ITAE)

3.6. Gerçek Çalışma Koşulları Altında Dayanıklılık (Robustluk) Analizi

Önerilen yöntemin pratik uygulanabilirliğini değerlendirmek amacıyla, gerçek dünyadaki uygulamalarda yaygın olarak karşılaşılan fiziksel bozucuları modelleyen gerçekçi koşullar altında ek çalışmalar gerçekleştirilmiştir. Bölüm 3.1–3.5'te sunulan ideal simülasyonlardan farklı olarak, bu deneyler sensör gürültüsü, parametre belirsizlikleri, yük değişimleri ve harici bozucu kuvvetleri eş zamanlı olarak içermektedir.

Tablo 3.3, dayanıklılık analizinde kullanılan bozucu parametreleri özetlemektedir. Bu değerler tipik endüstriyel koşulları temsil edecek şekilde, konum ölçümleri için ±1.5 mm ve hız ölçümleri için ±15 mm/s enkoder gürültü seviyeleri; üretim toleransları ve aşınmayı hesaba katmak amacıyla kütle ve sürtünme katsayılarında ±%20 belirsizlik; 1 kg ek yük kütlesi; titreşimleri ve modellenmemiş dinamikleri simüle etmek için 8 N standart sapmaya sahip rastgele harici kuvvetler olarak seçilmiştir.

Tablo 3.3. Dayanıklılık analizinde kullanılan bozucu parametreler

Parametre	Sembol	Değer	Birim	Açıklama
Konum gürültüsü	σ_p	1.5	mm	Ölçüm gürültüsü standart sapması
Hız gürültüsü	σ_v	15.0	mm/s	Ölçüm gürültüsü standart sapması
Kütle belirsizliği	δ_m	±20	%	Parametre varyasyon aralığı
Sürtünme belirsizliği	δ_b	±20	%	Parametre varyasyon aralığı
Faydalı yük	m_{load}	1.0	kg	Ek faydalı yük kütlesi
Harici bozucu etki	σ_F	8.0	N	Rastgele kuvvet standart sapması

Sensör gürültüsü, konum ve hız ölçümlerine eklenen sıfır ortalamalı Gauss gürültüsü olarak modellenmiş olup tipik enkoder kuantalama hatalarını ve elektriksel girişimleri temsil etmektedir. Parametre belirsizlikleri, belirtilen aralıklar içinde düzgün (uniform) dağılıma sahip rastgele ölçekleme katsayıları olarak uygulanmış ve her simülasyon çalışması boyunca tutarlı şekilde korunmuştur. Harici bozucu kuvvet ise her zaman adımında uygulanan Gauss tabanlı rastgele bir süreç olarak modellenmiş; böylece çevresel titreşimler, gerilmeler ve modellenmemiş dinamik etkiler simüle edilmiştir.

Adil bir karşılaştırma sağlamak amacıyla, üç kontrolörün (ZN-PID, CC-PID ve DDPG-PID) tamamı aynı rastgele tohum kullanılarak özdeş bozucu dizilerine maruz bırakılmıştır. PID kazançları ideal şartlar altındaki simülasyonlardaki (Tablo 3.1)

değerlerle değiştirilmeden korunmuş, böylece yeniden ayarlama yapılmaksızın her bir ayarlama yönteminin dayanıklılığı doğrudan değerlendirilebilmiştir.

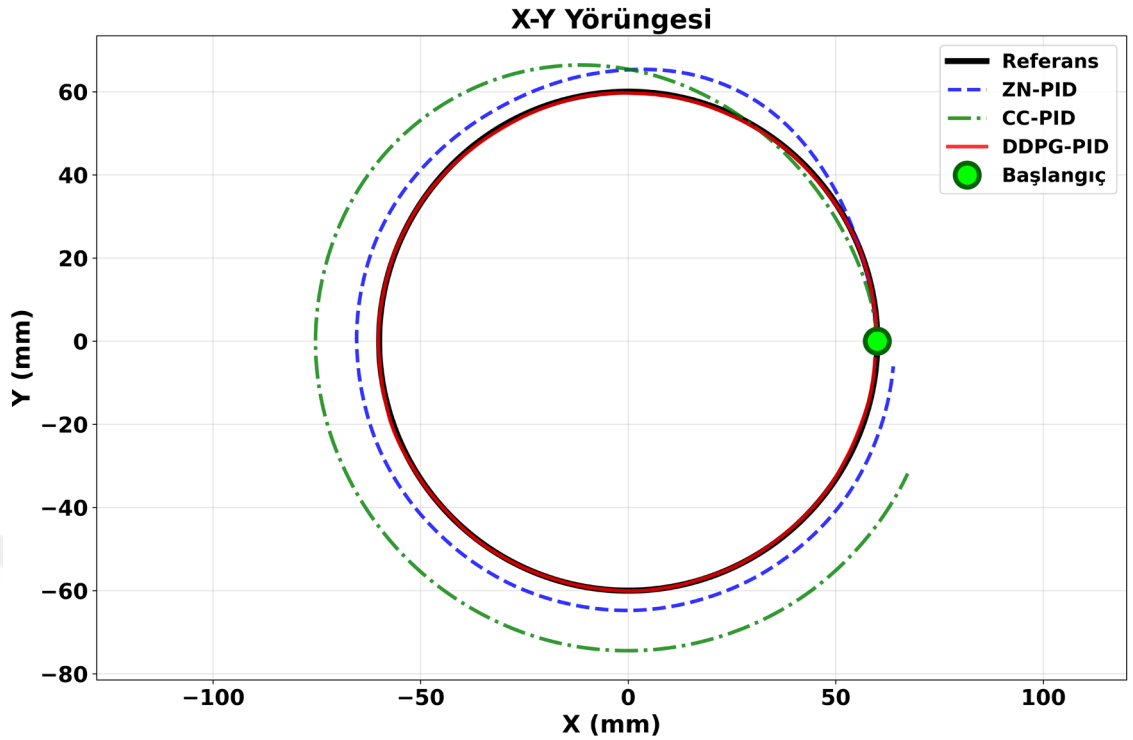
Tablo 3.4, bu gerçekçi koşullar altındaki yörünge takip performansı karşılaştırmasını sunmaktadır. Sonuçlar, önemli bozucuların varlığında dahi DDPG-PID'nin tüm yörüngeler için üstün performansını koruduğunu göstermektedir.

Tablo 3.4. Gerçekçi bozucu koşullar altında yörünge takip performansı karşılaştırması

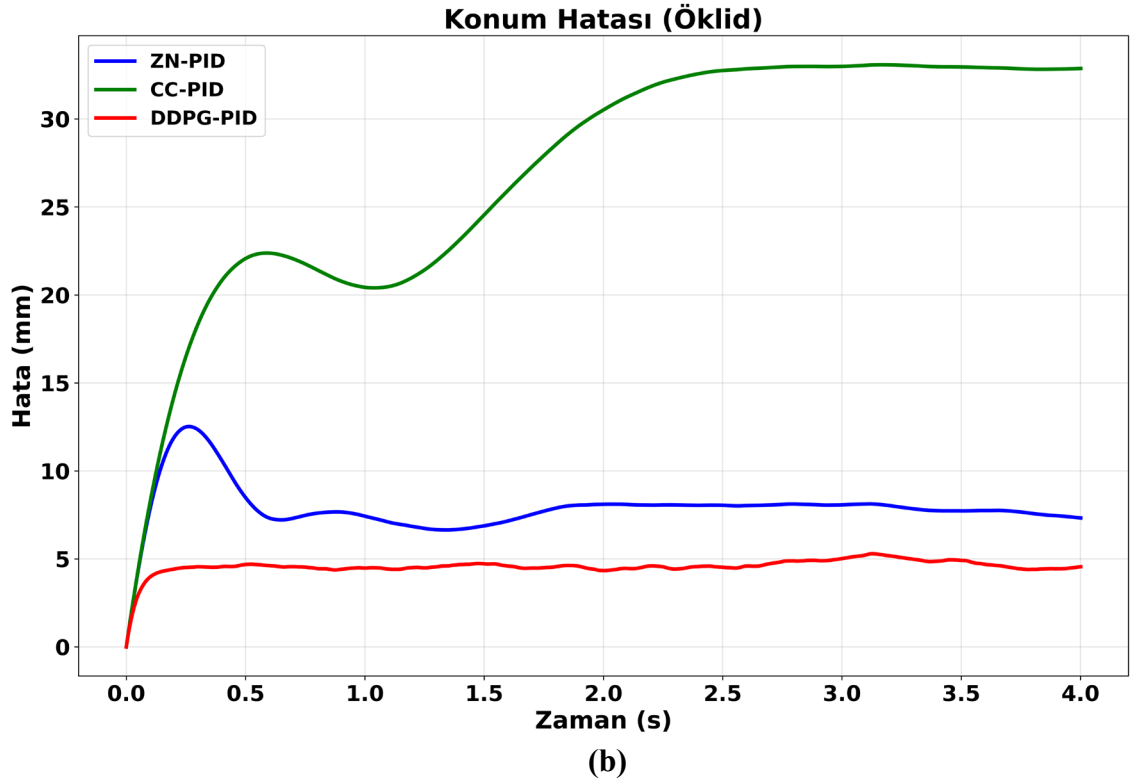
Yörünge	Algoritma	RMSE	IAE	ISE	ITAE	Maks. Hata
Daire	ZN-PID	8.0239	31.6650	257.6579	62.4881	12.5218
	CC-PID	27.9488	108.3421	3126.1046	245.1982	33.0776
	DDPG-PID	4.5947	18.3109	84.4882	37.4675	5.2941
Lemniskat	ZN-PID	12.5076	47.6800	626.0749	94.9757	18.9481
	CC-PID	31.6780	120.0631	4015.9835	263.0705	46.0503
	DDPG-PID	5.5026	21.4102	121.1752	43.0202	8.1046
Elmas	ZN-PID	6.8129	22.9469	185.7575	45.7611	12.5801
	CC-PID	19.6043	75.6154	1538.0793	170.3919	25.6359
	DDPG-PID	3.8624	15.2825	59.7030	32.1782	4.7984
Yıldız	ZN-PID	17.3067	58.6076	1198.6929	119.4032	29.4594
	CC-PID	32.3204	122.6673	4180.5250	259.8748	46.7584
	DDPG-PID	6.0642	23.8265	147.1728	48.0249	7.1775

Gerçekçi bozucu koşullar altında, DDPG-PID dört yörüngenin tamamında en düşük hata metriklerini tutarlı biçimde elde etmektedir. ZN-PID ile karşılaştırıldığında DDPG-PID, RMSE değerini %43–65 oranında azaltırken, CC-PID'ye kıyasla iyileşme oranı %80–84'e ulaşmaktadır. Bu sonuçlar, önerilen yöntemin sensör gürültüsü, parametre belirsizlikleri ve harici bozucuların varlığında dahi üstün yörünge takip performansını koruduğunu doğrulamaktadır.

Şekil 3.35–3.38'de gösterildiği üzere, bozucuların bulunduğu gerçekçi koşullar altında daire, lemniskat, elmas ve yıldız yörüngeleri için takip sonuçları sunulmaktadır. Her bir şekilde, (a) alt şekli X–Y düzlemindeki referans ve takip edilen gerçek yörüngeleri gösterirken, (b) alt şekli karşılık gelen Öklid konum hatasını sunmaktadır.

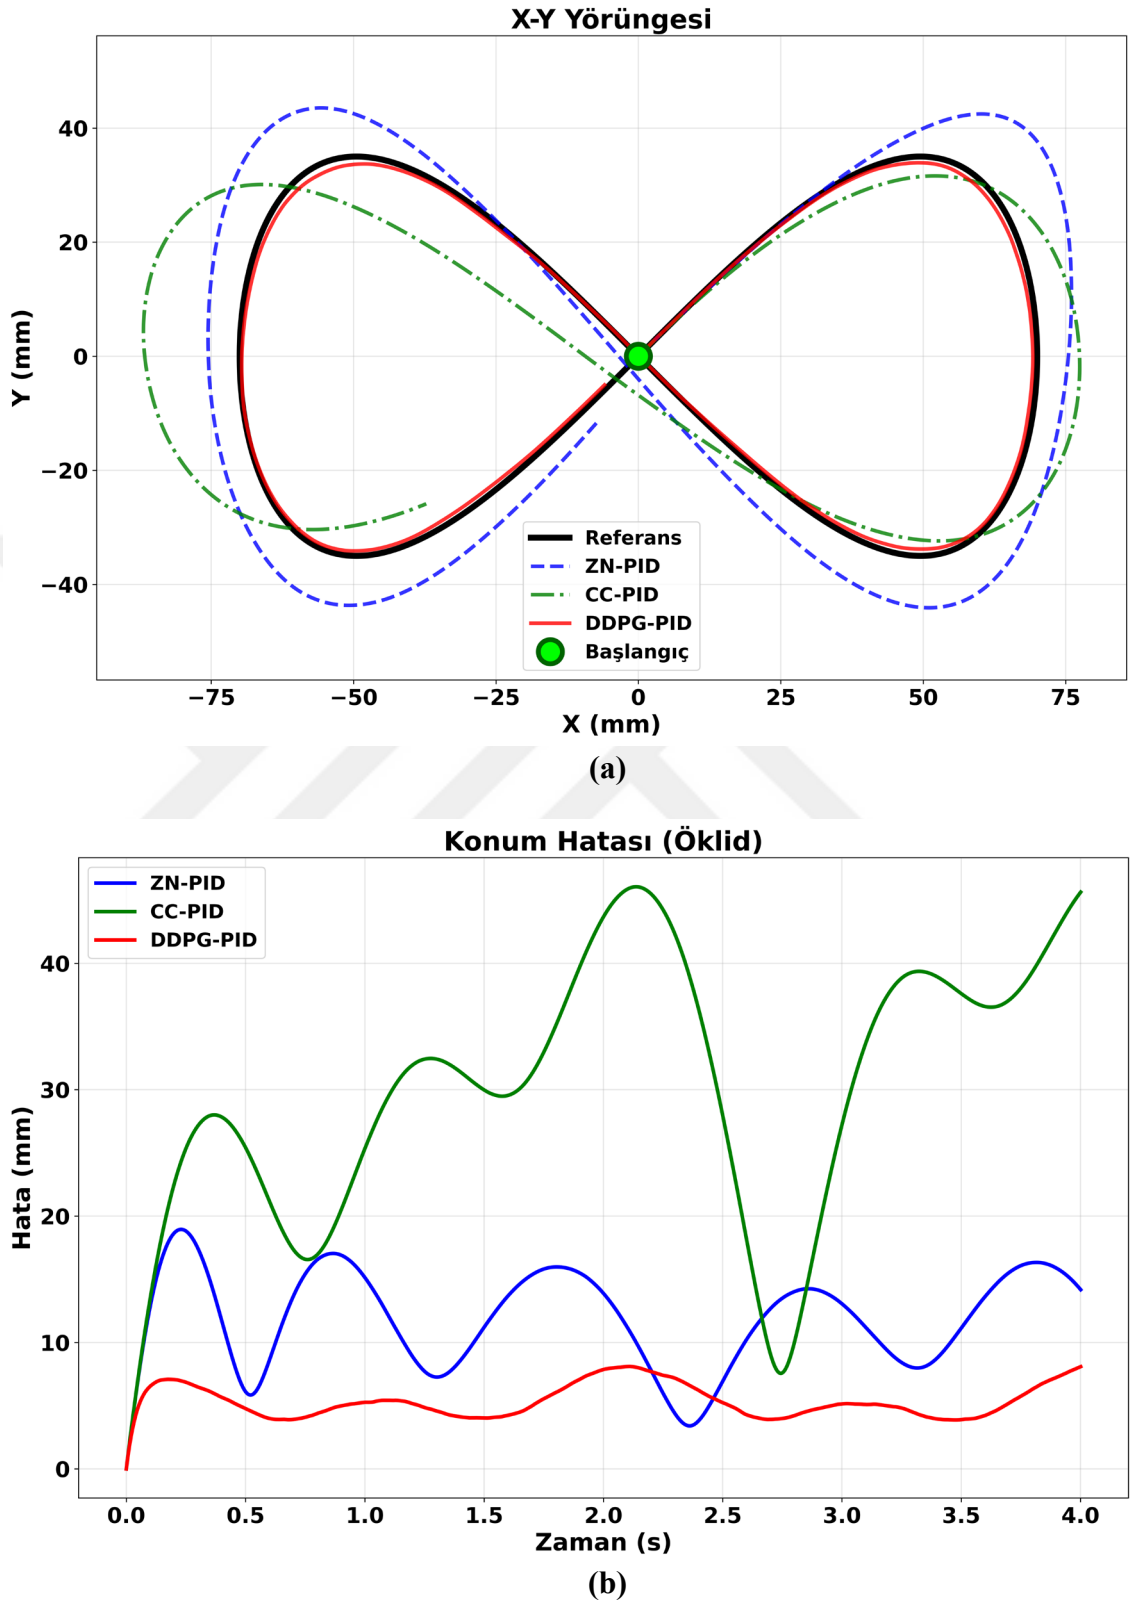


(a)

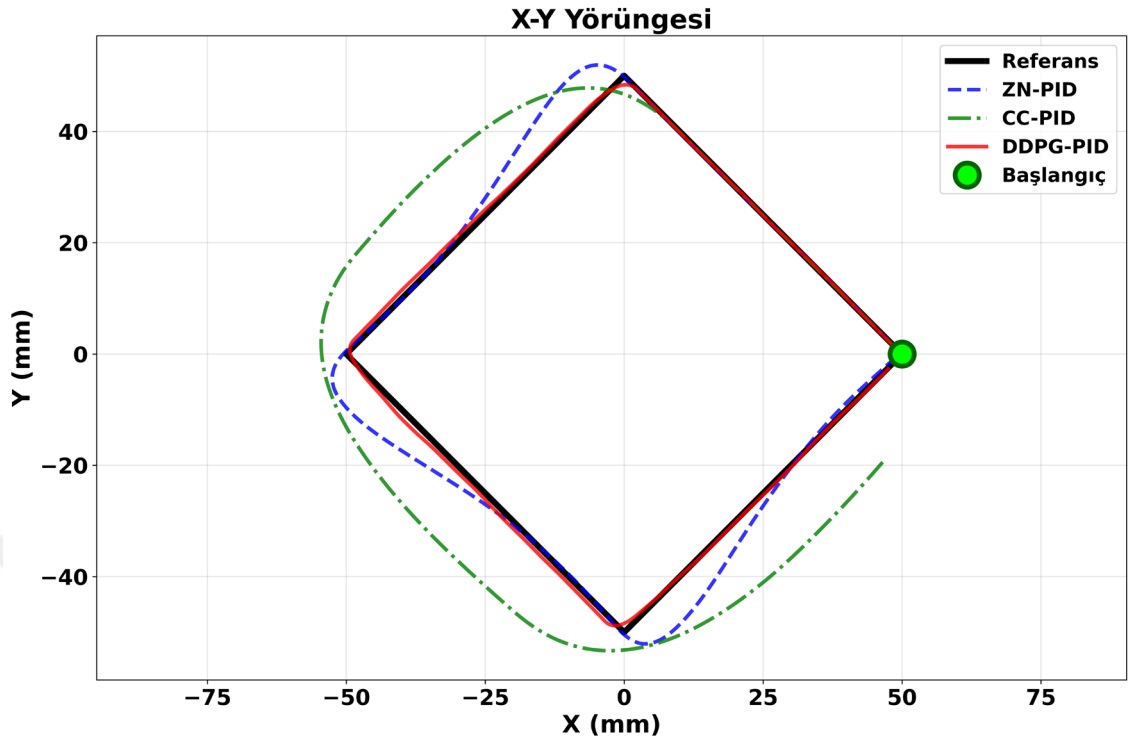


(b)

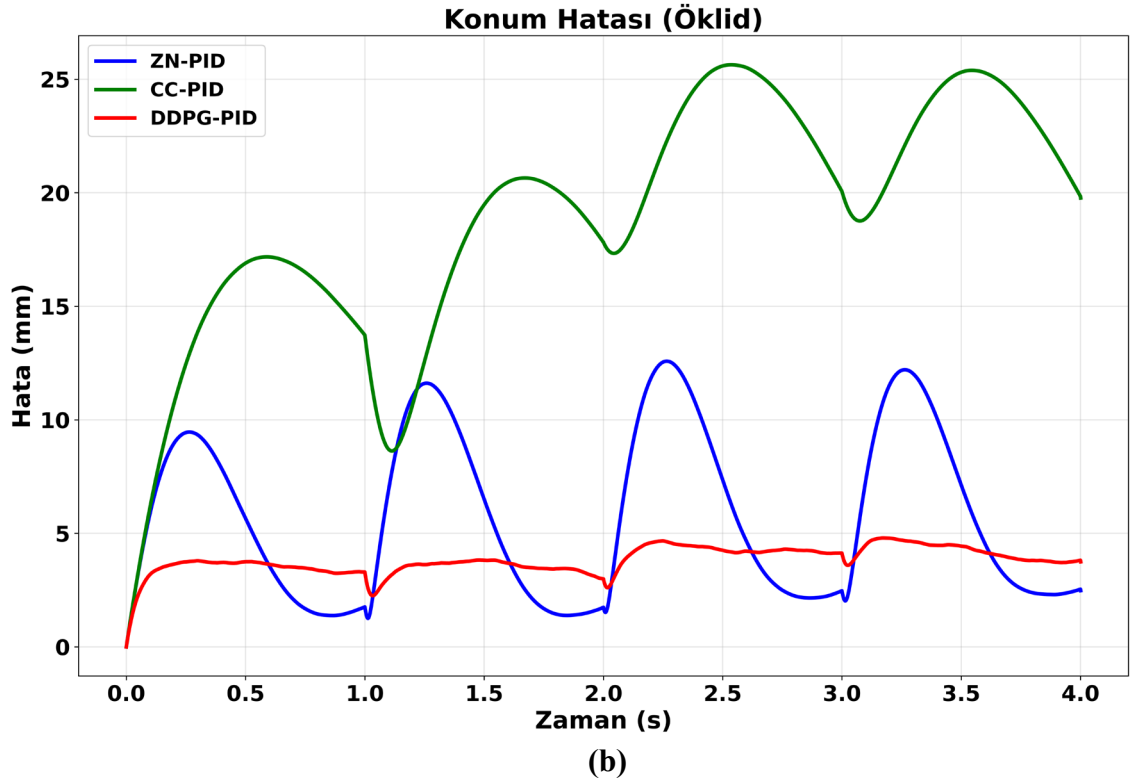
Şekil 3.35. Bozucuların bulunduğu gerçekçi koşullar altında daire yörünge için takip performansı: (a) X–Y düzleminde yörünge takibi, (b) Öklid konum hatası



Şekil 3.36. Bozucuların bulunduğu gerçekçi koşullar altında lemniskat yörünge için takip performansı: (a) X–Y düzleminde yörünge takibi, (b) Öklid konum hatası

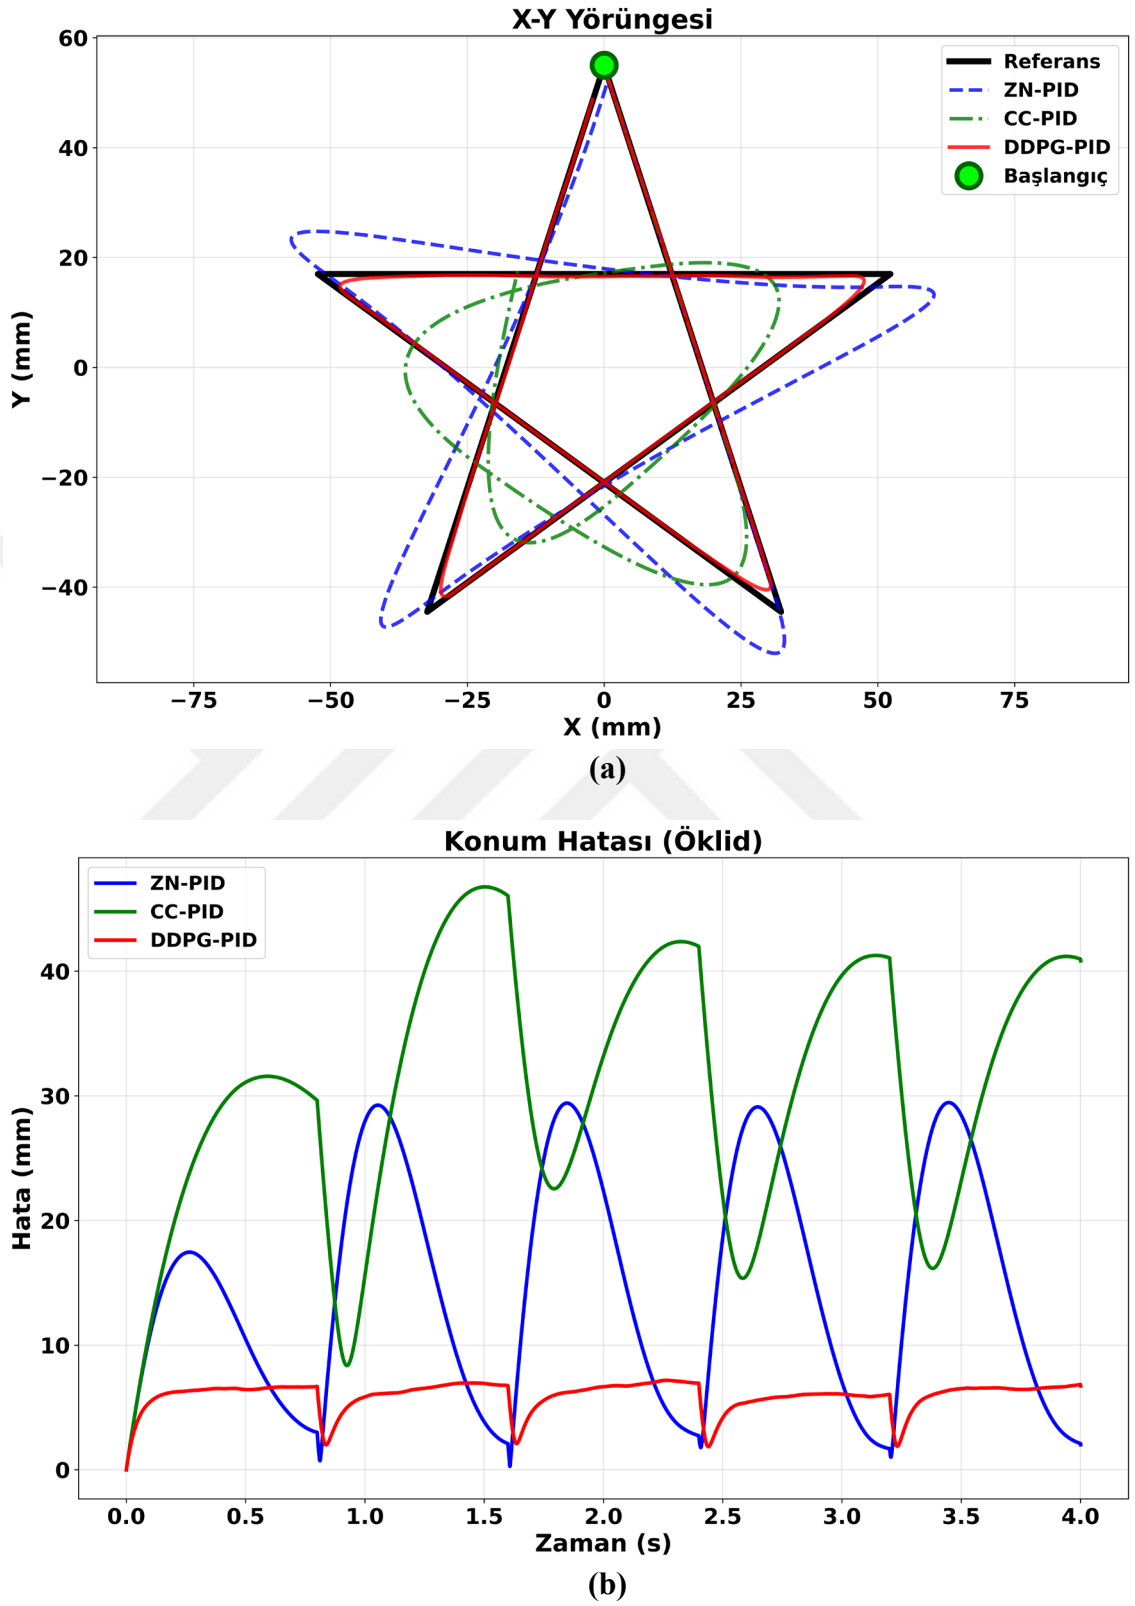


(a)



(b)

Şekil 3.37. Bozucuların bulunduğu gerçekçi koşullar altında elmas yörünge için takip performansı: (a) X–Y düzleminde yörünge takibi, (b) Öklid konum hatası



Şekil 3.38. Bozucuların bulunduğu gerçekçi koşullar altında yıldız yörünge için takip performansı: (a) X–Y düzleminde yörünge takibi, (b) Öklid konum hatası

Dört yörüngenin tamamında DDPG-PID, referans yolu sıkı bir şekilde takip etmeyi tutarlı olarak sürdürürken, klasik yöntemlerde belirgin performans bozulmaları gözlemlenmektedir. CC-PID, parametre belirsizlikleri ve harici bozucuları telafi etmekte yetersiz kalan muhafazakâr kazançları nedeniyle görünür yörünge sapmaları sergileyerek en düşük dayanıklılık performansını göstermektedir. ZN-PID ise özellikle keskin köşelere sahip yörüngelerde yön değişimleri sırasında ortaya çıkan periyodik hata tepe değerleriyle orta düzeyde bir performans sunmaktadır.

Hata-zaman grafikleri, DDPG-PID'nin yörünge süresi boyunca kararlı ve düşük hata seviyelerini koruduğunu; buna karşılık CC-PID hatasının sürekli arttığını ve ZN-PID'nin salınımlı bir davranış sergilediğini ortaya koymaktadır. Bu sonuçlar, DDPG tarafından seçilen daha yüksek türev kazançlarının bozucu etkilere karşı gelişmiş bir bastırma (disturbance rejection) kabiliyeti sağladığını ve zorlu gerçekçi koşullar altında dahi sağlam bir yörünge takip performansını mümkün kıldığını doğrulamaktadır.

4. BÖLÜM

SONUÇ VE ÖNERİLER

Bu tez çalışmasında, delta paralel robotun yörünge takip kontrolü için DDPG tabanlı pekiştirmeli öğrenme ile PID kazançlarının otomatik ayarlanması hedeflenmiş ve önerilen DDPG-PID, klasik ZN-PID ve CC-PID yöntemleriyle dört farklı referans yörünge (daire, lemniskat, elmas, yıldız) üzerinde karşılaştırılmıştır. Elde edilen bulgular, önerilen yaklaşımın yalnızca ortalama takip başarısını değil, aynı zamanda birikimli hata ve en kötü durum sapmalarını da iyileştirdiğini göstermektedir.

Nicel sonuçlar incelendiğinde DDPG-PID'nin tüm yörüngelerde en düşük hata değerlerini ürettiği görülmektedir. RMSE açısından DDPG-PID; daire, lemniskat, elmas ve yıldız yörüngelerinde sırasıyla 3.8828, 4.2609, 3.1395 ve 4.0478 değerlerine ulaşırken, ZN-PID'de bu değerler 6.4349, 8.0445, 4.8638 ve 9.7045, CC-PID'de ise 21.4438, 22.0531, 15.0398 ve 21.2289 olarak elde edilmiştir. Bu karşılaştırma, RMSE'nin yörüngeye bağlı olarak ZN-PID'ye göre yaklaşık %35–58, CC-PID'ye göre yaklaşık %79–82 aralığında azaltıldığını doğrulamaktadır. Benzer üstünlük, integral tabanlı ölçütlerde de korunmaktadır: örneğin yıldız yörüngesinde IAE, 15.2534 (ZN: 37.3469, CC: 80.6258) ve ITAE, 30.3754 (ZN: 76.1837, CC: 165.9283) değerlerine düşmüştür. Bu tablo, iyileştirmenin sadece "ortalama hata" ile sınırlı kalmadığını; geç sönümlenen hataların ve kritik anlarda oluşan sapmaların da etkin biçimde bastırıldığını göstermektedir.

Yörünge geometrisinin zorlayıcılığı arttıkça (özellikle elmas ve yıldız gibi keskin köşe/ani yön değişimi içeren yörüngelerde) DDPG-PID'nin farkı daha belirgin hâle gelmiştir. Öğrenme sonucunda elde edilen kazançların çoğu senaryoda daha yüksek türev kazancı eğilimi göstermesi, hızlı yön değişimlerinde sönümleme artışı ve salınım/aşımın azaltılması ile tutarlı bir denetim karakteri üretmiştir. Buna karşılık ZN-PID'nin aynı

kazançlarla tüm yörüngelere uygulanması, bazı yörüngelerde agresif davranışa ve artan salınıma zemin hazırlarken; CC-PID'nin daha temkinli ayarlarının ise delta robotun doğrusal olmayan ve yörüngeye bağlı dinamikleri altında yeterli uyarlanabilirlik sağlayamadığı görülmüştür.

Ayrıca, sensör gürültüsü, parametre belirsizlikleri, yük varyasyonları ve dış kuvvetler dahil olmak üzere gerçekçi bozucu koşullar altında yapılan dayanıklılık analizi, DDPG-PID'nin üstün takip performansını koruduğunu, klasik yöntemlerin ise önemli ölçüde bozulma gösterdiğini ortaya koymaktadır. Bu bulgular, önerilen yaklaşımın sadece ideal çalışma koşullarında etkili olmakla kalmayıp, aynı zamanda gerçek dünya uygulamalarında pratik olarak uygulanabilecek kadar sağlam olduğunu da göstermektedir.

Sonuç olarak, DDPG-PID yaklaşımı delta paralel robotlarda klasik kural-tabanlı ayarlara göre daha yüksek ve daha tutarlı takip performansı sunmuştur. Çalışmanın temel sınırlılığı, öğrenme sürecinin klasik yöntemlere kıyasla daha fazla hesaplama gerektirmesidir. Ancak eğitimin çevrimdışı yürütülebilmesi, gerçek zamanlı uygulamalar için bu durumun sorun olmasını ortadan kaldırmaktadır. Gelecek çalışmalarda, öğrenilen ayar stratejisinin gerçek donanım üzerinde doğrulanması, yöntemin endüstriyel uygulanabilirliğini daha güçlü biçimde ortaya koyacaktır.

KAYNAKÇA

1. Clavel, R., 1988. DELTA, a fast robot with parallel geometry, 91-100. *Proceedings of the 18th International Symposium on Industrial Robots*, 26-28 April 1988, Lausanne, Switzerland, Springer-Verlag, 515.

2. Åström, K. J., Hägglund, T. 1995. PID controllers: theory, design and tuning (2nd ed.). ISA – The Instrumentation, Systems and Automation Society, Research Triangle Park, NC, USA, 338.

3. Ziegler, J. G., Nichols, N. B., 1942. Optimum settings for automatic controllers. **Trans. ASME**, **64** (8): 759-768. https://doi.org/10.1115/1.4019264

4. Cohen, G. H., Coon, G. A., 1953. Theoretical consideration of retarded control. **Trans. ASME**, **75** (5): 827-834. https://doi.org/10.1115/1.4015451

5. Pierrot, F., Company, O., 1999. H4: a new family of 4-DOF parallel robots, 508-513. *1999 IEEE/ASME International Conference on Advanced Intelligent Mechatronics*, Atlanta, GA, USA. https://doi.org/10.1109/AIM.1999.803222

6. Hernández, J. M. E., Chemori, A., Sierra, H. A., 2023. Modelling and nonlinear robust control of delta-like parallel kinematic manipulators. Academic Press. https://doi.org/10.1016/C2021-0-01645-X

7. Codourey, A., 1998. Dynamic modeling of parallel robots for computed-torque control implementation. **The International Journal of Robotics Research**, **17** (12): 1325-1336. https://doi.org/10.1177/027836499801701205

8. Stamper, R. E., Tsai, L.-W., Walsh, G. C., 1997. Optimization of a three DOF translational platform for well-conditioned workspace, 3250-3255. *Proceedings of International Conference on Robotics and Automation*, 25–25 April 1997, Albuquerque, NM, USA, IEEE. https://doi.org/10.1109/ROBOT.1997.606784

9. Biagiotti, L., Melchiorri, C., 2008. Trajectory planning for automatic machines and robots. Springer: Berlin/Heidelberg, Germany. https://doi.org/10.1007/978-3-540-85629-0

10. Merlet, J.-P., 2006. Parallel robots (2nd ed.) Solid mechanics and its applications, 128. Springer Dordrecht, Netherlands, 402.

11. Tsai, L.-W., 1999. Robot analysis: the mechanics of serial and parallel manipulators. John Wiley & Sons, Etobicoke, ON, Canada, 520.

12. Azmoun, M., Rouhollahi, A., Masouleh, M. T., Kalhor, A., 2018. Kinematics and control of a 4-DOF delta parallel manipulator, 494-500. *Proceedings of the 6th RSI International Conference on Robotics and Mechatronics (IcRoM 2018)*, October 23-25, 2018, Tehran, Iran. https://doi.org/10.1109/ICRoM.2018.8657618

13. Rahmani, R., Mobayen, S., Barhaghtalab, M. H., 2020. Position tracking of parallel robot by an adaptive second order sliding mode control based on projection neural network, 1-5. *2020 28th Iranian Conference on Electrical Engineering (ICEE)*, Tabriz, Iran. https://doi.org/10.1109/ICEE50131.2020.9260594

14. Thanh, L. M., Thuong, L. H., Loc, P. T., Nguyen, C.-N., 2020. Delta robot control using single neuron PID algorithms based on recurrent fuzzy neural network identifiers. **International Journal of Mechanical Engineering and Robotics Research**, **9** (10): 1411-1418. https://doi.org/10.18178/ijmerr.9.10.1411-1418

15. Haas, L., Wölfle, R., Kuba, M., Zeh, T., 2023. Optimization of a delta robot using machine learning, 1-6. *3rd International Conference on Electrical, Computer, Communication, and Mechatronics Engineering (ICECCME)*. Tenerife, Canary Islands, Spain. https://doi.org/10.1109/ICECCME57830.2023.10252507

16. Pak, Y.-J., Kong, Y.-S., Ri J.-S., 2023. Robust PID optimal tuning of a delta parallel robot based on a hybrid optimization algorithm of particle swarm optimization and differential evolution. **Robotica**, **41** (4): 1159-1178. https://doi.org/10.1017/S0263574722001606

17. Boudjedir, C. E., Bouri, M., Boukhetala, D., 2019. Iterative learning control for trajectory tracking of a parallel delta robot. **at - Automatisierungstechnik**, **67** (2): 145-156. https://doi.org/10.1515/auto-2018-0086

18. Sutton, R.S., Barto, A.G., 2018. Reinforcement learning: an introduction (2nd ed.). The MIT Press, Cambridge, MA, USA, London, UK.

19. Lillicrap, T.P., Hunt, J.J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., Wierstra, D., 2015. Continuous control with deep reinforcement learning, *arXiv:1509.02971*. https://doi.org/10.48550/arXiv.1509.02971

20. Vu, D.-S., Alsmadi, A., 2020. Trajectory planning of a cable-based parallel robot using reinforcement learning and soft actor-critic. **WSEAS Transactions on Applied and Theoretical Mechanics, 15**: 165-172. https://doi.org/10.37394/232011.2020.15.19

21. Kober, J., Bagnell, J. A., Peters, J., 2013. Reinforcement learning in robotics: a survey. **International Journal of Robotics Research**, **32** (11): 1238-1274. https://doi.org/10.1177/0278364913495721

22. Gu, S., Holly, E., Lillicrap, T., Levine, S., 2017. Deep reinforcement learning for robotic manipulation with asynchronous off-policy updates, 3389-3396. *Proceedings of the IEEE International Conference on Robotics and Automation*, May 29 - June 3, 2017, Singapore, IEEE: New York, NY, USA. https://doi.org/10.1109/ICRA.2017.7989385

23. Lawrence, N. P., Forbes, M. G., Loewen, P. D., McClement, D. G., Backström, J. U., Gopaluni, R. B., 2022. Deep reinforcement learning with shallow controllers: an experimental application to PID tuning. **Control Engineering Practice**, **121,** 105046. https://doi.org/10.1016/j.conengprac.2021.105046

24. Carlucho, I., De Paula, M., Wang, S., Petillot, Y., Acosta, G. G., 2018. Adaptive low-level control of autonomous underwater vehicles using deep reinforcement learning. **Robotics and Autonomous Systems**, **107**: 71–86. https://doi.org/10.1016/j.robot.2018.05.016

25. dos Santos Lima, M., Kich, V. A., Steinmetz, R., Tello Gamarra, D. F., 2024. Delta robot control by learning systems: harnessing the power of deep reinforcement learning algorithms. **Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology, 46** (2), 4881-4894. https://doi.org/10.3233/JIFS-232795

26. Yadavari, H., Tavakol Aghaei, V., İkizoğlu, S., 2023. Deep reinforcement learning-based control of stewart platform with parametric simulation in ROS and gazebo. **ASME Journal of Mechanisms and Robotics**, **15** (3), 035001. https://doi.org/10.1115/1.4056971

27. Lu, Y., Wu, C., Yao, W., Sun, G., Liu J., Wu, L., 2023. Deep reinforcement learning control of fully-constrained cable-driven parallel robots. **IEEE Transactions on**

Industrial Electronics, **70** (7): 7194-7204. https://doi.org/10.1109/TIE.2022.3203763

28. Huang, H.-C., Chen, Y.-X., 2023. Evolutionary optimization of fuzzy reinforcement learning and its application to time-varying tracking control of industrial parallel robotic manipulators. **IEEE Transactions on Industrial Informatics**, **19** (12): 11712-11720. https://doi.org/10.1109/TII.2023.3248120

29. Zhu, D., He, Y., Li, F., 2024. Trajectory tracking of delta parallel robot via adaptive backstepping fractional-order non-singular sliding mode control. **Mathematics**, **12** (14), 2236. https://doi.org/10.3390/math12142236

30. Jalali, H., Samadi, S., Kalhor, A., Masouleh, M. T., 2022. Model-free dynamic control of a 3-dof delta parallel robot for pick-and-place application based on deep reinforcement learning, 48-54. *Proceedings of the 10th RSI International Conference on Robotics and Mechatronics (ICRoM)*, 22–24 November 2022, Tehran, Iran, Islamic Republic of, IEEE, New York, NY, USA. https://doi.org/10.1109/ICRoM57054.2022.10025269

31. Grimshaw, A., Oyekan, J., 2021. Applying deep reinforcement learning to cable driven parallel robots for balancing unstable loads: a ball case study. **Frontiers in Robotics and AI**, **7**, 611203. https://doi.org/10.3389/frobt.2020.611203

32. Louette, A., Lambrechts, G., Ernst, D., Pirard, E., Dislaire, G., 2024. Reinforcement learning to improve delta robot throws for sorting scrap metal. arXiv:2406.13453v2. https://doi.org/10.48550/arXiv.2406.13453

33. Sancak, C., Yamac, F., Itik, M., 2022. Position control of a planar cable-driven parallel robot using reinforcement learning. **Robotica**, **40** (10), 3378–3395. https://doi.org/10.1017/S0263574722000273

34. Chen, H., Kim, M. C., Ko, Y., Kim, C. S., 2023. Compensated motion and position estimation of a cable-driven parallel robot based on deep reinforcement learning. **International Journal of Control, Automation and Systems**, **21**, 3507–3518. https://doi.org/10.1007/s12555-023-0342-6

35. Azad, F. A., Ansari Rad, S., Arashpour, M., 2022. Back-stepping control of delta parallel robots with smart dynamic model selection for construction applications.

Automation in Construction, **137**, 104211. https://doi.org/10.1016/j.autcon.2022.104211

36. Yang, X., Xiang, Y., Li, J., 2025. Q-learning-based trajectory tracking control of delta robot, 5495-5500. *2025 37th Chinese Control and Decision Conference (CCDC)*, Xiamen, China. https://doi.org/10.1109/CCDC65474.2025.11091044

37. Ma, T., Xiong, H., Zhang, L., Diao, X., 2019. Control of a cable-driven parallel robot via deep reinforcement learning, 275-280. *2019 IEEE International Conference on Advanced Robotics and its Social Impacts (ARSO)*, Beijing, China. https://doi.org/10.1109/ARSO46408.2019.8948792

38. Bouaouda, A., Pannequin, R., Charpillet, F., Martinez, D., Boutayeb, M., 2023. Dynamic modeling and AI-based control of a cable-driven parallel robot. **IFAC-PapersOnLine**, **56** (2): 10021-10026. https://doi.org/10.1016/j.ifacol.2023.10.868

39. Hu, Y., Zhu, B., Li, H., Ouyang, Z., Xu, Y., Su, S., 2025. Trajectory planning algorithm for parallel platforms integrating DDPG and efficient forward kinematics, 555-559. *2025 IEEE 8th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, Guiyang, China. https://doi.org/10.1109/IAEAC65194.2025.11166124

40. Åström, K. J., Hägglund, T., 2006. Advanced PID control. ISA—The Instrumentation, Systems and Automation Society: Research Triangle Park, NC, USA.

41. Åström, K. J., Hägglund, T., 1984. Automatic tuning of simple regulators with specifications on phase and amplitude margins. **Automatica**, **20** (5): 645-651. https://doi.org/10.1016/0005-1098(84)90014-1

42. Sundaresan, K. R., Krishnaswamy, P. R., 1978. Estimation of time delay time constant parameters in time, frequency, and laplace domains. **Can. J. Chem. Eng.**, **56**: 257-262. https://doi.org/10.1002/cjce.5450560215

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Oğuzhan KABAKULAK
Uyruğu: Türkiye (T.C)
Doğum Tarihi ve Yeri:
Medeni Durum:
e-mail:
Yazışma Adresi:

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	Erciyes Üniversitesi, Mekatronik Mühendisliği	2020
Lise	Atatürk Anadolu Lisesi, Çorum	2015

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2026-Halen	TOMTAŞ Havacılık & Teknoloji A.Ş.	1
2022-2026	Ser Dayanıklı Tüketim Malları İç ve Dış Ticaret Sanayi A.Ş. SİMFER	4

YABANCI DİL

İngilizce

YAYINLAR

1. Savaş, S., Kabakulak, O., 2026. Reinforcement learning-based PID gain optimization for delta parallel robot trajectory tracking. **Applied Sciences**, **16** (3), 1453. https://doi.org/10.3390/app16031453