

## Kablo İle Sürülen Eksik Sınırlandırılmış Ortamsal Bir Paralel Robotta Derin Pekiştirmeli Öğrenme ile Kablo Gerilim Kuvveti Optimizasyonlu Yörünge Planlama: Benzetim Temelli Bir Yaklaşım

Kadir İbrahim ERTÜRK<sup>1, a)</sup> ve Caner SANCAK<sup>1, b)</sup>

<sup>1</sup>Karadeniz Teknik Üniversitesi, Mühendislik Fakültesi, Makina Mühendisliği Bölümü 61080, TRABZON

<sup>a)</sup>kadiribrahimerturk@ktu.edu.tr, <sup>b)</sup>csancak@ktu.edu.tr

Bu çalışmada, kablo ile sürülen eksik sınırlandırılmış ortamsal bir paralel robotun toplam kablo gerilim kuvvetlerini en aza indirecek şekilde optimize edilmiş yörünge planlaması bir pekiştirmeli öğrenme yöntemi olan Derin Q-Ağı kullanılarak yapılmıştır. Yapılan çalışmada eşkenar üçgen bir çerçeveye sahip ve çalışma hacmi düzgün üçgen prizmadan oluşan üç kablo ile sürülen ortamsal bir paralel robot kullanılmıştır. Benzetim ortamında tasarlanan robot modeli üzerinde pekiştirmeli öğrenme tabanlı Derin Q-Ağı algoritması kullanılarak uç işlemci konumuna bağlı kablo gerilim kuvvetleri, pekiştirmeli öğrenme ajanının eğitiminde ödül fonksiyonu olarak değerlendirilmiştir. Sonuç olarak geliştirilen yöntem uç işlemcinin referans konuma ulaşırken kabloların toplam gerilim kuvvetini en aza indirgeyen optimal bir yol izlenmesini sağlamıştır. Bu çalışma, kablo ile sürülen paralel robotlarda enerji/verimlilik odaklı yörünge planlamasına katkı sağlamaktadır.

**Anahtar Kelimeler:** Derin pekiştirmeli öğrenme, kablo ile sürülen paralel robot, yörünge planlama, optimizasyon.

## Energy-Efficient Trajectory Planning in an Underconstrained Cable-Driven Parallel Robot Using Deep Reinforcement Learning

### ABSTRACT

In this study, trajectory planning optimized to minimize the total cable tension forces of an under-constrained spatial cable-driven parallel robot is performed using a reinforcement learning method, the Deep Q-Network. In the study, a spatial cable-driven parallel robot with three cables, having an equilateral triangular frame and a working volume in the form of a regular triangular prism, is used. On the robot model designed in the simulation environment, cable tension forces depending on the end-effector position are evaluated as the reward function in the training of the reinforcement learning agent by using the reinforcement learning-based Deep Q-Network algorithm. As a result, the developed method ensures that the end-effector follows an optimal path minimizing the total cable tension force of the cables while reaching the reference position. This study contributes to energy/efficiency-oriented trajectory planning in cable-driven parallel robots.


**Keywords:** Deep reinforcement learning, cable-driven parallel robot, trajectory planning, optimization.

### 1. GİRİŞ

#### 1.1. GENEL BİLGİLER

Paralel robotların özel bir türü olan kablo ile sürülen paralel robotlar (KSPR), rijit uzuvlar yerine kabloların kullanıldığı bir robot tipidir ve bundan dolayı sadece çekme kuvvetini iletebilirler [1]. Yapılarına göre

düzlemsel ve ortamsal olarak ikiye ayrılırlar. Şekil 1’de genel düzlemsel bir hareket yapan KSPR gösterilmiştir.



Şekil 1. Kablo ile sürülen düzlemsel paralel robot

Şekil 2’de görülen ortamsal KSPR’ler altı serbestlik derecesine sahiptirler ve üç boyutlu çalışma alanı içerisinde hareket ederler.



Şekil 2. Kablo ile sürülen ortamsal paralel robot

Ortamsal KSPR’lerin yapısal özelliklerinden dolayı, uç işlemci yüksekliği arttıkça kablo açıları  $\alpha$  küçülmekte, böylece her kablo üzerindeki kablo gerilim kuvvetleri artmaktadır. Bunun sonucunda uç işlemcinin hareketi için gerekli olan tork miktarları üstel olarak artmakta; bu durum hem enerji tüketimini yükseltmekte hem de aşırı kablo gerilim kuvveti nedeniyle kabloların ömrünü azaltmakta veya kopmalara yol açabilmektedir. Bu nedenle, çalışma alanı içerisinde bir noktadan başka bir noktaya hareket ederken, kablo gerilim kuvvetlerini göz önünde bulundurarak yörünge planlamak oldukça önemli bir problem haline gelmektedir. Yörünge ve hareket planlama çalışmalarında,

kablo gerilimi hem bir güvenlik kriteri hem de enerji tüketimi, verimlilik ve donanım ömrü açısından kritik bir optimizasyon parametresi olarak ele alınmıştır [2].

Literatürdeki çalışmalarda, Trevisani eksik sınırlandırılmış düzlemsel bir KSPR için geliştirdiği yönteminde, kablo kuvvetlerinin pozitif ve üst sınırlı kalmasını sağlamak üzere kablo gerilimi koşullarını uç işlemci hız ve ivme kısıtlarına dönüştürmüş, bu kısıtları trapezoidal hız profilleriyle birleştirerek minimum süreli yörünge planlaması önermiştir [3]. Barnett ve Gosselin [4], kablo gerilimi kısıtlarını doğrudan zaman-optimal yörünge planlama problemine entegre etmiş ve Minimum-Time Trajectory Shaping (MTTS) algoritmasını kabloyla sürülen düzlemsel paralel robota uyarlamışlardır. Bu sayede, uç işlemcinin önceden tanımlı yolları izlerken minimum ve maksimum gerilim koşullarını ihlal etmeden, hız, ivme ve sarsı kısıtları altında neredeyse zaman-optimal çözümler üretilebilmiştir.

Özellikle kabloların gerilimini optimize etme amacıyla yapılan güncel çalışmalar, toplam kablo gerilimini veya maksimum kablo gerilim kuvvetlerini minimize eden doğrudan optimizasyon teknikleri içermektedir. Örneğin Badrikouhi ve Bamdad [5], üç kablo ve uç platformun ağırlığını dengeleyen ek bir prizmatik aktüatörle yapılandırılmış üç serbestlik derecesine sahip bir KSPR için, Hermite–Simpson doğrudan kolokasyon yöntemini kullanarak optimal yörünge planlama gerçekleştirmiştir. Yöntemde, kabloların her zaman gergin kalması sağlanmış; toplam kablo gerilimi ile kablo gerilimi değişim hızını doğrudan maliyet fonksiyonuna ekleyerek tüm hareket boyunca düşük ve sürekli kablo kuvvetleri elde edilmiştir. Çalışma, ayrıca GPOPS-II ve B-spline interpolasyon yöntemleriyle karşılaştırmalı olarak test edilmiş ve Hermite–Simpson yaklaşımı doğruluk ve hesaplama süresi açısından en uygun çözüm olarak belirlenmiştir. Zhao ve ark. [6] ise, artıksıl sınırlandırılmış bir KSPR için maksimum kablo gerilimini minimize eden bir tasarım ve hareket optimizasyon stratejisi geliştirmiştir. Korayem ve ark. [7], 6 serbestlik dereceli ve 6 kablolu ortamsal bir kablo ile asılı paralel robot üzerinde, kapalı çevrim optimal yörünge

planlama yöntemi geliştirmiştir. Çalışmada doğrusal olmayan sistem dinamiği geri besleme lineerleştirme ile lineerleştirilmiş, LQR denetleyici ile kararlılık ve izleme başarımı sağlanmıştır. Ayrıca önerilen hareketli sınır stratejisi sayesinde hedef noktanın sınır üzerinde çevrim-içi seçilmesiyle, dinamik yük taşıma kapasitesi maksimize edilmiştir.


Fazla sayıda kablo içeren artıksal sistemlerde, gerilim kuvveti dağılımı sonsuz çözüm içerdiğinden optimizasyon algoritmaları yaygın olarak kullanılmıştır [8]. Cao ve ark. [9], 6 serbestlik dereceli ve 8 kablolu bir KSPR için, kablo gerilim kuvvetlerinin her zaman sınırlar içinde kalmasını sağlayan hiperbolik tanjant tabanlı sürekli bir gerilim dağılım yöntemi önermiştir.

Literatürdeki bazı çalışmalarda kablo gerilim kuvvetlerinin sınırlar içinde kalmasını garanti etmeye odaklanılmıştır [1,2,3,4,7,8,9]. Diğer bazı çalışmalarda ise, doğrudan kablo gerilimlerinin minimize edilmesi hedeflenmiş; bu kapsamda toplam veya maksimum kablo gerilimi optimizasyon kriteri olarak ele alınmıştır [5,6]. Ancak kablo ile sürülen eksik sınırlandırılmış ortamsal paralel robotlarda toplam kablo gerilim kuvvetlerini derin pekiştirmeli öğrenme (PÖ) ile optimize edecek şekilde yörünge planlama çalışma bulunmamaktadır.

Bu çalışmada PÖ kullanılarak üç kablo ile sürülen eksik sınırlandırılmış ortamsal bir paralel robotun uç işlemcisinin bir noktadan diğerine hareket ederken, kabloların toplam gerilim kuvvetini minimize eden optimal bir yol izlemesi sağlanmıştır.

## 1.2.SİSTEM TASARIMI

Robotun çalışma hacmi, kenar uzunlukları 1 metre olan düzgün üçgen prizmadan oluşan üç kablo ile sürülen ortamsal bir paralel robot olarak modellenmiştir. Modellenen robotta Şekil 2’de görüldüğü gibi uç işlemcinin hareketi, elektrik motorları ile tahrik edilen tamburların döndürülerek kabloların tamburlara sarılıp serbest bırakılmasıyla sağlanmaktadır.

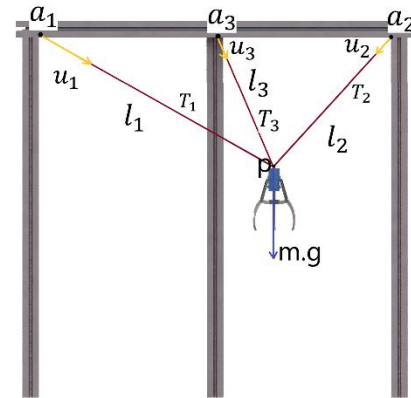


Şekil 3. Üç kablo ile sürülen ortamsal paralel robot

Kablo gerilim kuvvetlerinin optimizasyonu, uç işlemci hareketi için gereken tork miktarlarını azaltacağından motorların enerji tüketimi de optimize edilmiş ve daha verimli bir sistem elde edilmiş olur.

## 1.3.KABLO GERİLİM KUVVET HESABI

Uç işlemci konumuna göre kablo gerilim kuvveti hesabı, Şekil 4’te gösterilen geometrik büyüklükler ve vektörler kullanılarak yapılmıştır.



Şekil 4. Uç işlemci konumuna göre kablo gerilim kuvveti hesabı

Uç işlemci konumu ve ağırlığı bilindiği durumda her bir kablo vektörü Denklem (1) ile gösterilmiştir.

$$l_i = a_i - p \quad (1)$$

Böylece kablo doğrultusunu gösteren birim vektör Denklem (2) ile gösterilmiştir.

$$u_i = \frac{l_i}{\|l_i\|} \quad (2)$$

Birim vektörlerin bir araya getirilmesiyle Denklem (3) elde edilir.

$$U = [u_1 \ u_2 \ u_3] \quad (3)$$

Uç işlemciye etkiyen toplam kuvvetler statik denge koşulunu sağlayacak şekilde Newton denklemlerinden aşağıdaki şekilde ifade edilir.

$$\sum_{i=1}^3 T_i u_i + m g = 0 \quad (4)$$

Bu denklem matris formunda Denklem (5) ile gösterilebilir.

$$U T = -m g \quad (5)$$

Buradan kablo gerilim kuvveti vektörü Denklem (6)'da verildiği gibi çözülebilir.

$$T = U^{-1}(-m g) \quad (6)$$


Her bir kablo için gerilim kuvveti ise Denklem (7) ile gösterilir.

$$T_i = [U^{-1}(-m g)]_i \quad (7)$$

Bu denklemler kullanılarak, uç işlemcinin çalışma hacmindeki herhangi bir konumu için her bir kablo üzerindeki kablo gerilim kuvveti hesaplanabilir.


### 1.3. DERİN PEKİŞTİRMELİ ÖĞRENME

PÖ, bir ajanın çevresiyle etkileşime girerek hangi eylemlerin uzun vadede daha yüksek ödül sağlayacağını keşfetmesini amaçlayan bir makine öğrenmesi yaklaşımıdır. Derin pekiştirmeli öğrenmede ise yapay bir sinir ağı ajan olarak kullanılır. Şekil 5'te görüldüğü gibi ajan, çevre ile sürekli etkileşimde bulunur; her yaptığı eylem sonrasında ödül ve yeni gözlem değerleri elde eder. Zaman içinde, hangi davranışların avantajlı olduğunu öğrenir ve böylece toplam ödülünü maksimize edecek bir politika geliştirir [10].



Şekil 5. Pekiştirmeli öğrenme

Q-öğrenme, çevre modelinden bağımsız bir PÖ algoritmasıdır. Bu yöntemde, çevrenin dinamikleri veya ödül fonksiyonu hakkında ön bilgi gerekmez, sadece etkileşim verileriyle, belirli bir durumda seçilen aksiyonun uzun vadeli en yüksek beklenen ödülünü tahmin eden optimal aksiyon-değer fonksiyonu öğrenilir. Q-Öğrenme, zamansal fark ilkesini temel alır; her deneyimden sonra Q değerlerini güncelleyerek zamanla optimal politika ve değer fonksiyonuna ulaşmayı hedefler. Klasik Q-öğrenmede her bir durum-aksiyon çifti için beklenen toplam ödül, bir Q tablosunda saklanır. Ajan, bulunduğu durumda bu tabloyu kullanarak hangi aksiyonun daha avantajlı olduğunu belirler ve seçim yapar [10]. Klasik Q-öğrenme algoritması, durum-aksiyon çiftlerinin sayısı arttıkça tablo yapısının hem bellek hem de genelleme açısından yetersiz kalmasına neden olur. Bu problemi aşmak için önerilen DQA algoritmasında Q fonksiyonunun doğrudan bir sinir ağı tarafından hesaplandığı bir yapı kullanılır ve bu yapı Şekil 6'da gösterilmiştir. Bu ağ, bir gözlem vektörünü girdisi olarak alır ve tüm olası aksiyonlara karşılık gelen Q değerlerini çıktı olarak üretir. Böylece yüksek boyutlu ve sürekli durum-aksiyon uzaylarında öğrenme mümkün hale gelir [10].



Şekil 6. DQA algoritması

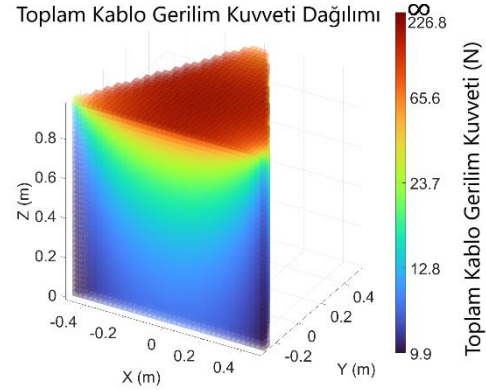
DQA algoritmasında öğrenmenin daha kararlı olabilmesi için iki ayrı sinir ağı kullanılır: ana ağ ve hedef ağ. Ana ağ, ajan tarafından aksiyon seçimi ve tahmini Q değerleri için gerçek zamanlı olarak kullanılır. Hedef ağ ise, Q değerlerinin güncellenmesinde referans olarak kullanılan ve parametreleri daha seyrek aralıklarla güncellenen bir ağıdır. Bu sayede öğrenme sırasında oluşabilecek sapmalar ve dengesizlikler azaltılmış olur. Her öğrenme adımında, ajan ana ağa mevcut durumu ve yaptığı aksiyonu vererek tahmini Q değerini elde eder. Sonrasında, bir sonraki durum hedef ağa verilerek, olası aksiyonlar için Q değerleri hesaplanır ve en yüksek Q değeri hedef olarak belirlenir. Kayıp fonksiyonu, bu hedef Q değeri ile tahmini Q değeri arasındaki farkın karesi şeklinde tanımlanır. Kayıp, geri yayılım ile ana ağın parametrelerinin güncellenmesinde kullanılır. Bu süreç tekrarlandıkça, ağ zamanla optimal Q fonksiyonuna yakınsar ve ajan, ödülünü maksimize eden politikayı öğrenmiş olur [10].

## 2. YAPILAN ÇALIŞMALAR

### 2.1. KONUMA GÖRE TOPLAM KABLO GERİLİM KUVVETİNİN HESAPLANMASI

Hesaplamlarda uç işlemci kütlesi 1 kg olarak alınmıştır. Çalışma alanındaki her bir konum için, giriş bölümünde sunulan statik denge ve vektör denklemleri kullanılarak, her bir kablo üzerindeki gerilim kuvvetleri

hesaplanmıştır. Her bir kablo üzerindeki gerilim kuvveti toplanarak elde edilen toplam kablo gerilim kuvveti çalışma hacminin üç boyutlu dağılımı üzerinde renkli küpler aracılığıyla görselleştirilmiş ve bu dağılım Şekil 7’de sunulmuştur.

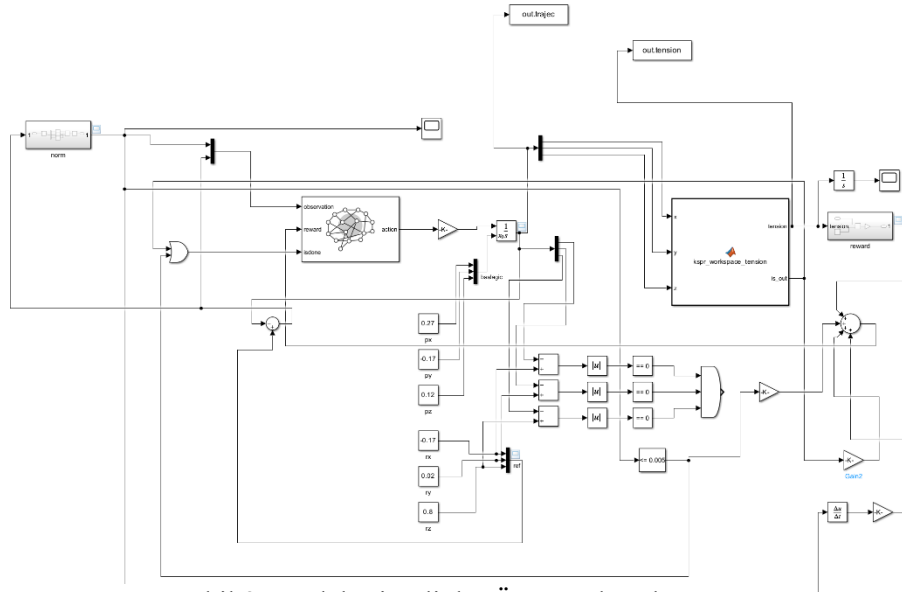


Şekil 7. Toplam kablo gerilim kuvveti dağılımı

Şekilde görüldüğü üzere, uç işlemcinin yüksekliği arttıkça kabloların yatayla yaptığı açı küçülmekte ve buna bağlı olarak kablo gerilme kuvvetleri üstel biçimde artmaktadır. Bu üstel artış, mavi ile kırmızı arasında tanımlanan logaritmik renk dağılımı ile görselleştirilmiştir.

### 2.2. NOKTADAN NOKTAYA PÖ İLE YÖRÜNGE PLANLAMA

Bu bölümde, Şekil 8’de görülen Matlab/Simulink’te oluşturulan PÖ eğitim ortamında, kablo ile sürülen eksik sınırlandırılmış ortamsal bir paralel robotun uç işlemcisinin başlangıç konumundan hedef



Şekil 8. Matlab Simulink PÖ ortam kurulumu

konuma hareketi için kablo gerilim kuvvetlerini en aza indirecek şekilde optimize edilmiş bir yörünge planlaması ele alınmıştır. İlk aşamada, kablo gerilim kuvvetleri dikkate alınmaksızın, uç işlemcinin çalışma alanı dışına çıkmadan referans konuma ulaşması hedeflenmiştir. Benzetim ortamında oluşturulan modelden elde edilen uç işlemci–referans hata vektörü ve bu vektörün normu, gözlem verisi olarak belirlenmiştir. Böylece ajan, referansa olan dik uzaklığı ve yönelimi gözlemleyerek hedefe ulaşabilmektedir. Yapılan eğitimlerde Matlab Reinforcement Learning Toolbox'ta mevcut olan DQN algoritması kullanılmış olup kullanılan sinir ağı 3 katmanlı 200 nöronlu oluşmaktadır ve aktivasyon fonksiyonu olarak LeakyRelu fonksiyonu kullanılmıştır. Azaltma faktörü 0.99, öğrenme oranı  $10^{-4}$ , hedef ağ güncelleme sıklığı 5 adımda bir ve yumuşatma oranı  $10^{-3}$  olarak seçilmiştir. Her eğitim bölümü toplamda en fazla 200 adımdan oluşmaktadır. Ödül fonksiyonu ise Denklem (8)'deki şu şekilde tanımlanmıştır:

$$r(t) = r_1(t) + r_2(t) + r_3(t) \quad (8)$$

Ödül fonksiyonu 3 ayrı kısımdan oluşmaktadır. Burada her adımda hedefe yaklaşmayı teşvik edecek kısım  $r_1(t)$  ile tanımlanmıştır. Uç işlemciyle referans arasındaki dik uzaklığa bağlı olarak her adımda dik uzaklık azaldıkça uç işlemci referansa yaklaşacağından 1 puan ödül, arttıkça 1 puan ceza olacak şekilde belirlenmiştir. Ajanın aldığı aksiyon sonucu uç işlemcinin çalışma alanının dışına çıkmaması için  $r_2(t)$  ödülü tanımlanmıştır. Uç işlemci çalışma alanı dışına çıktığında 100 puan ceza verilerek eğitim bölümü sonlandırılmıştır.  $r_3(t)$  ile uç işlemci hedef konuma ulaştığında ise 150 puan ödül verilerek eğitim bölümü sonlandırılmıştır. Bu ödül yapısı sayesinde, PÖ ajanı uç işlemciyi çalışma hacmi içerisinde tutarak, başlangıç ve hedef noktaları arasında bir yörünge planlamasını başarıyla gerçekleştirmiştir.


### 2.3. PÖ İLE KABLO GERİLİM KUVVETİ OPTİMİZASYONUNA DAYALI YÖRÜNGE PLANLAMA

Bu aşamada, bir önceki bölümde kullanılan gözlem ve ödül yapısı değiştirilmeden ödül fonksiyonuna yalnızca uç işlemci konumuna bağlı olarak hesaplanan

anlık toplam kablo gerilim kuvveti  $10^{-1}$  ile çarpılarak ceza terimi olarak eklenmiştir. Ödül fonksiyonuna dahil edilen kablo gerilim kuvveti cezasının öğrenme süreci üzerindeki etkisini doğrudan ve kontrollü biçimde inceleyebilmek amacıyla eğitim ortamı, yalnızca tek bir başlangıç ve tek bir referans konumu ile sınırlandırılmıştır. Bu tercih, farklı başlangıç–hedef çiftlerinden kaynaklanabilecek karıştırıcı etkileri ortadan kaldırarak, ceza teriminin ajan politikasındaki güncellemelere olan katkısının gözlemlenmesini mümkün kılmıştır. Böylece ajanın yalnızca hedef konuma ulaşması değil, aynı zamanda hareket boyunca oluşan toplam kablo gerilim kuvvetini minimize etmesi amaçlanmıştır. Eğitimlerde daha önce noktadan noktaya başarılı bir şekilde yörünge planlayabilen bir ajan seçilerek belirtilen ödül fonksiyonu kullanılmıştır. Eğitim sonucunda, geliştirilen yeni PÖ ajanı, başlangıç ve hedef noktaları arasındaki yörüngeyi daha düşük toplam kablo gerilim kuvveti oluşturacak biçimde optimize etmiştir. Elde edilen veriler bulgular sonuçlar kısmında gösterilmiştir.

### 3. BULGULAR


İlk aşamada noktadan noktaya yörünge planlama için yapılan eğitim yaklaşık 15 dakikada tamamlanmış ve 470 bölüm sürmüştür. 470 bölüm sonunda ortalama ödül değeri maksimum değere ulaştığında eğitim sonlandırılmıştır. Eğitim grafiği Şekil 9'da gösterilmektedir.



Şekil 9. Noktadan noktaya yörünge planlama PÖ eğitim grafiği

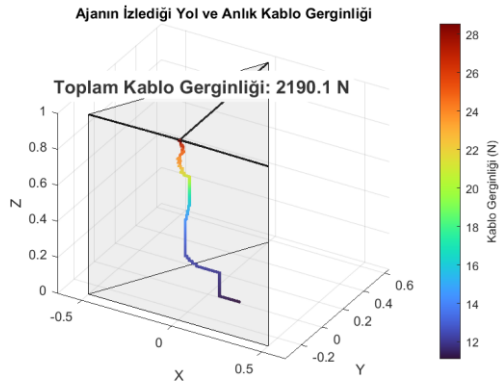
Noktadan noktaya yörünge planlamasında eğitilen PÖ ajanı, %98 başarı oranıyla uç işlemciyi çalışma alanı dışına çıkmadan hedef konuma ulaştırmayı başarmıştır. Aynı gözlem vektörleriyle fakat farklı bir ödül fonksiyonu kullanılarak gerçekleştirilen kablo gerilim kuvvetlerinin optimizasyonunu amaçlayan

diğer çalışmada ise, ajan minimum toplam kablo gerilim kuvveti oluşturacak şekilde hareket etmeyi yaklaşık 50 eğitim bölümünde öğrenmiştir ve eğitim toplam 120 saniyede tamamlanmıştır. Eğitim grafiği Şekil 10'da gösterilmektedir.




Şekil 10. Gerilim optimizasyonlu yörünge planlama için PÖ eğitim grafiği

Karşılaştırmalı olarak; kablo gerilim kuvveti dikkate alınmadan yapılan yörünge planlamasında toplam kablo gerilim kuvveti 2190 N olarak hesaplanırken, kablo gerilim kuvveti optimize edildiği durumda bu değer 1980 N'a kadar düşmüştür. Planlanan yörüngeler Şekil 11 ve Şekil 12'de gösterilmiştir.



Şekil 11. Optimize edilmemiş yörünge



Şekil 12. Optimize edilmiş yörünge

#### 4. SONUÇLAR

Bu çalışma kapsamında düzgün üçgen prizma biçiminde tanımlanmış bir çalışma alanına sahip kablo ile sürülen paralel robot için, öncelikle rastgele seçilmiş noktalar arasında noktadan noktaya yörünge planlama gerçekleştirilmiş ve %98 başarımla elde edilmiştir. Ardından, eğitilen ajarlardan biri, kablo gerilim kuvvetlerinin optimizasyonunu hedeflemek üzere yeniden eğitime tabi tutulmuş ve bu aşamada ödül fonksiyonuna gerilim değerlerini ceza terimi olarak yansıtan ek bir bileşen dâhil edilmiştir. Böylelikle, belirli bir başlangıç ve hedef noktası için uç işlemcinin yalnızca güvenli biçimde hareket etmesi değil, aynı zamanda kablo gerilim kuvvetlerinin daha düşük seviyelerde tutulması sağlanmıştır. Çalışma, pekiştirmeli öğrenmenin KSPR'lerde yörünge planlama problemine uygulanabilirliğini açık biçimde ortaya koyarken, özellikle gözlem uzayının ve ödül fonksiyonunun tasarımının başarı üzerindeki etkisini de göstermektedir. Ayrıca, gözlem vektöründe veya modelde herhangi bir değişiklik yapılmaksızın yalnızca ödül fonksiyonuna eklenen bir terimle kablo gerilimlerinin optimize edilebilmiş olması, yöntemin esneklik ve uyarlanabilirlik açısından önemli bir göstergesidir. Elde edilen sonuçlar önerilen yaklaşımın KSPR'lerde hem güvenli hem de gerilimi gözetten yörünge planlama için uygulanabilir ve genişletilebilir bir çözüm sunduğunu ortaya koymaktadır.

#### 5. KAYNAKLAR

[1] Alp, A. B., & Agrawal, S. K. (2002). Cable Suspend Robots: Feedback controllers with positive inputs. Proceedings of the 2002 American Control Conference (s. 815-820). Anchorage, Alaska, USA: IEEE.

[2] Bamdad, M. (2013). "Time-Energy Optimal Trajectory Planning of Cable-Suspended Manipulators." In Cable-Driven Parallel Robots, pp. 41-51 (Springer). [4] Trevisani, A. (2010). "Underconstrained planar cable-direct-driven robots: A trajectory planning method ensuring positive and bounded cable tensions." Mechatronics 20(1): 113-127.

- [3] Trevisani, A. (2010). "Underconstrained planar cable-direct-driven robots: A trajectory planning method ensuring positive and bounded cable tensions." *Mechatronics* 20(1): 113–127.
- [4] Barnett, E. & Gosselin, C. (2015). "Time-optimal trajectory planning of cable-driven parallel mechanisms for fully-specified paths with G1-discontinuities." *J. Dyn. Sys., Meas., Control* 137(7): 071007.
- [5] Badrikouhi, M. & Bamdad, M. (2024). "Optimal Trajectory Planning of a Cable-Driven Parallel Robot by Direct Collocation Approaches." *Int. J. of Advanced Design and Manufacturing Technology* 17(3): 11–23.
- [6] Zhao, D.J. et al. (2025). "Cable Tension Minimization of a Redundant Cable-Driven Robot with Flexible End Effector." *ASME J. Mechanisms and Robotics* 17(10): 101003.
- [7] Korayem, M.H. et al. (2012). "Analytical design of optimal trajectory with dynamic load-carrying capacity for cable-suspended manipulators." *Int. J. Adv. Manuf. Technol.* 60(1): 317–327.
- [8] Pott, A. (2014). "Cable-Driven Parallel Robots: Theory and Application." Springer Tracts in Advanced Robotics, 120: 173–190.
- [9] Cao, S. et al. (2023). "Real-Time Tension Distribution Design for Cable-Driven Parallel Robot." *Applied Sciences* 13(1): 10.
- [10] Laat, A. (2022). *Deep reinforcement learning*. Singapore: Springer.