

Dört Kol Mekanizmasında Eklem Aşınmasından Tekrarlanan Pozisyon Hatalarını Minimize Etmek İçin Bir Takviyeli Öğrenme Algoritması

Şakir İmren¹, M. İ. Can Dede², Serhan Özdemir³

¹Makina Mühendisliği Bölümü
İzmir Yüksek Teknoloji Enstitüsü, Gülbahçe
sakirimren@iyte.edu.tr

²Makina Mühendisliği Bölümü
İzmir Yüksek Teknoloji Enstitüsü, Gülbahçe
candede@iyte.edu.tr

³Makina Mühendisliği Bölümü
İzmir Yüksek Teknoloji Enstitüsü, Gülbahçe
serhanozdemir@iyte.edu.tr

Özetçe

Bu çalışmada eklem boşluklu bir dört kol mekanizmasında oluşan pozisyon hatasını minimize etmek amaçlı bir yapay zekâ algoritması oluşturulmuş ve sistemin benzetimi yapılmıştır. Eklemlerinden birinde boşluk olan bir dört kol mekanizmasının CAD modeli SolidWorks ortamında hazırlanmış, MATLAB ortamında yazılan yapay zekâ algoritması kullanılarak Simulink ile benzetimi yapılmıştır. Benzetim sonuçları yöntemin aşınmadan dolayı tekrarlanan pozisyon hatalarının azaltılmasında etkili olduğunu göstermiştir.

1. Giriş

Mekanizmalar istenilen görevleri gerçekleştirebilmek için belirli bir yörünge izlemeli ya da belirli bir pozisyona erişmelidir. Bu nedenle pozisyonlama hassasiyeti mekanizmaların performansını tanımlamak için bir ölçek olarak kullanılabilir. Teorik olarak bir mekanizma, tanımlanan bir işi sürekli olarak kusursuz bir şekilde yerine getirebilir ancak gerçekte kusursuz bir mekanizma üretmek mümkün değildir. Eklem boşluğu da mekanizmaların performansını etkileyen kusurlardan biri olmakla beraber, parçaların bağlı hareketleri için gerekli bir parametredir. Zaman içerisinde parçalarda oluşabilecek mekanik aşınmalardan dolayı pozisyon hatası kabul edilebilir değerlerde olan mekanizmalar bile bir süre sonra eklem boşluğu nedeniyle performans kaybına uğrayacaklardır. Eklem boşluğu etkisinin ayrıca mekanizma yapısına bağlı olduğu da bilinmektedir. [1]

Eklem boşluğunun modellenmesinde üç temel yaklaşım bulunmaktadır. Birincisi, iki uzvu çarpışan kütleler olarak ele

alan momentum değişimi yaklaşımıdır. İkinci yaklaşımda ise eklem boşluğu bir yay-sönüm sistemi olarak modellenmektedir. Son yaklaşımda ise eklem boşluğu kütsüz bir ek uzuv olarak ele alınmaktadır [2]. Bu çalışmada da uygulama kolaylığı göz önüne alınarak son yaklaşım tercih edilmiştir.

Eklem boşluğundan kaynaklanan pozisyon hatasının azaltılmasında uygun uzuv boylarının seçilmesinin etkili olduğu Uzmay ve Erkaya'nın çalışmasında [3] gösterilmiştir. Ancak daha önce de belirtildiği gibi eklem boşluğu zaman içinde değişebilen dinamik bir parametredir, bu yüzden bir kereye mahsus uygun boyların seçilerek mekanizmanın üretilmesi uzun vadede yeterli bir çözüm olmayacaktır. Bu durumda pozisyon hatası kabul edilebilir aralık dışına çıktığı zaman yeni duruma adapte olup uzuv boyutlarını uygun değerlere ayarlayacak akıllı bir sistem ihtiyacı doğmaktadır.

2. Takviyeli Öğrenme

Takviyeli öğrenme, eylemleri durumlara haritalamaya dayanan bir öğrenme algoritmasıdır [4]. Mobil robotlar [5] [6], oyunlar [7] ve motor kontrolü [8] gibi çok farklı alanlarda kullanılmaktadır.

“Etmen”, başlangıçta eylemler ve durumlar hakkında hiçbir bilgiye sahip değildir. Gerçekleştirdiği her eylem bir duruma neden olur. Oluşan yeni durumun istenen ya da istenmeyen bir durum olmasına göre öğrenme gerçekleşir. Karşılaşılan her durum için bir değer fonksiyonu tanımlanır ve bu değer fonksiyonu sayesinde hangi eylemlerin yapılması, hangilerinin yapılmaması gerektiği belirlenir. Bu çalışmadaki örneğimizde istenilen durumlar pozisyon hatasının az olduğu durumlar

olduğu için düşük pozisyon hatasına sahip durum “değerli durum” olacaktır.

Etmen her eylem gerçekleştirdiğinde değer fonksiyonunu şu şekilde güncellemektedir [4]:

$$V(s) \leftarrow V(s) + \alpha [R(s) - V(s)] \quad (1)$$

Burada $V(s)$ değer fonksiyonu olup geçmiş deneyimlere dayanarak belirtilen durumun değerini verir, α öğrenme oranı olup yeni gelen verinin daha önceki veri üzerindeki etkisini belirler, $R(s)$ ödül fonksiyonu olup gerçekleşen durumun istenilen bir durum olması halinde değer fonksiyonuna pozitif etkide bulunur.

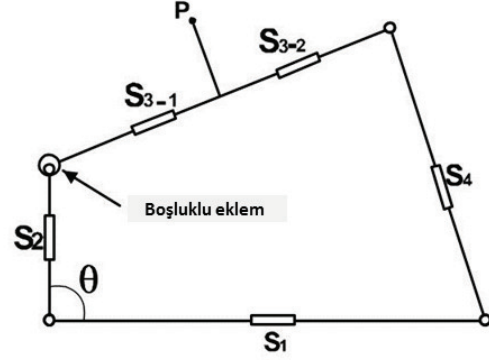
Etmen en yüksek değere sahip olan durumları gerçekleştiren eylemleri seçerek toplamda pozisyon hatasını minimize etmeye çalışır. Ancak gerekli bilgileri toplayabilmesi için belirli bir oranda “keşif” yapması gereklidir. Keşif işleminde değer fonksiyonu göz önüne alınmadan rastgele eylemler seçilerek oluşturduğu durumlar değerlendirilir ve böylece sistemin bilgi düzeyi artmış olur. Dinamik bir problemin çözümü için etmen hiçbir zaman “keşif” işleminden vazgeçip sürekli olarak “yararlanma” yapmamalıdır çünkü değişen koşullarda eski bilgiler geçerliliğini yitirecek ve yeni bilgilere ihtiyaç duyulacaktır. Başka bir deyişle bir “değerli durum” sürekli olarak “değerli” kalmayacak ve yeni değerli durumların keşfedilmesi gerekecektir.

“Keşif” ve “yararlanma” arasındaki bu denge etmenin eylem seçim politikası tarafından kontrol edilir. Hızlı değişen bir sistem için daha fazla “keşif” istenirken, durağan bir sistemde daha fazla “yararlanma” istenecektir. Bununla birlikte bu politika sabit kalmayıp ortam şartlarına bağlı olarak değiştirilebilir.


3. Eklem Boşluklu Bir Dört Kol Mekanizmasının Performansı

Eklemlerinden birinde boşluk bulunan bir dört kol mekanizması ele alınmıştır (Şekil 1). Mekanizmanın her uzvu, boy değişimini sağlayabilmek için, prizmatik bir eklemlerle birleştirilmiş iki uzuv şeklinde tasarlanmıştır. Üçüncü uzvun boyu, gözlem noktası olan P noktasını uzvun orta kısmında sabit tutabilmek için, bu nokranın iki tarafına yerleştirilen prizmatik eklemler ile ayarlanmaktadır. Şekil 1’de görülen S_1 , S_2 , S_3 , S_4 değerleri prizmatik eklemlerdeki uzama miktarlarını göstermektedir. S_3 değeri S_3-1 S_3-2 değerlerinin toplamına eşittir.

Mekanizmanın CAD modeli SolidWorks yazılımı kullanılarak oluşturulmuştur (Şekil 2). CAD modelde bulunan iki mekanizmadan soldakinde eklem boşluğu bulunurken diğerinde eklem boşluğu yoktur ve pozisyon hatası sıfırdır. Eklem boşluğu hariç birbirinin tamamen aynı olan bu mekanizmanın izlediği yörüngeler karşılaştırılarak eklem boşluklu mekanizmanın pozisyon hatası hesaplanmaktadır.




Şekil 1: Prizmatik eklemlerle oluşturulmuş dört kol mekanizması.



Şekil 2: Eklem boşluklu (solda) ve eklem boşluksuz (sağda) mekanizmaların CAD modelleri.

Mekanizmaların CAD modelleri benzetim için Simulink ortamına aktarıldı ve pozisyon hatası iki pozisyon vektörünün farkı olarak hesaplandı.



Şekil 3: İki mekanizmadaki P noktalarının bir t anındaki konumları.

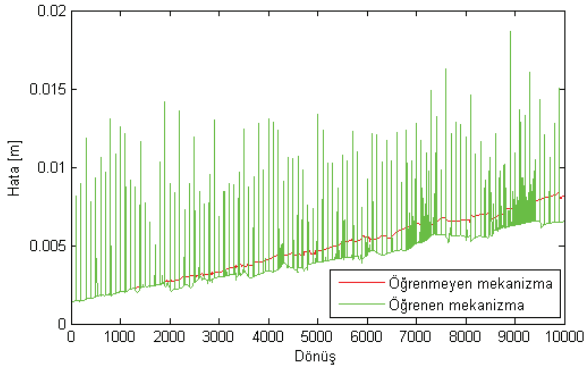
Şekil 3’te görüldüğü üzere iki mekanizmanın izlediği yörüngeler farklı olacaktır ve eklem boşluğu olan mekanizmanın pozisyon hatası bu iki nokta arasındaki uzaklığa eşit olacaktır. Buna göre, mekanizmanın bir dönüşü sırasında karşılaştığı toplam pozisyon hatası, denklem (2)’de görüldüğü gibi her veri noktasındaki hataların toplamı olarak ifade edilebilir.

$$e = \sum \sqrt{(x_D - x_R)^2 + (y_D - y_R)^2} \quad (2)$$

S1, S2, S3, S4 değerlerinin farklı kombinasyonları farklı durumlara karşılık gelecek ve her farklı durum için farklı hata değerleri alınacaktır. En düşük hata değeri veren durum en “değerli” durum olacağı için “ödül fonksiyonu” o durum için alınan hata değerinin negatifine eşit olacaktır.

4. Benzetimler

Şekil 4, %5 keşif oranı ile çalışan mekanizmanın 10000 tam dönüşü sonrasında elde edilen hata değerlerini göstermektedir. Eklem boşluğu başlangıçta 2 mm kabul edilmiş ve her devirde 0.001mm arttırılmıştır. Her bir prizmatik eklemin hareketi 2 mm ile sınırlı tutulmuştur.

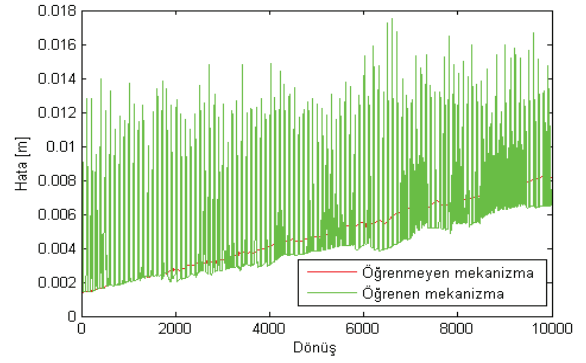


Şekil 4: %5 keşif oranı ile öğrenen ve öğrenmeyen mekanizmaların hata miktarları.

Takviyeli öğrenme mekanizma eğrisindeki ani çıkışlar keşif yapılan durumlara karşılık gelmektedir. Keşif işleminde uzuv boylarını değiştiren prizmatik eklemlerin pozisyonları rastlantısal olarak değiştirilmekte bu yüzden yüksek hata değerlerine ulaşılmaktadır. Keşif işleminden sonra “yararlanma” işlemi başlamakta ve algoritma bilinen en değerli durumu seçip hata oranını minimize etmektedir. Uygun bir keşif oranının seçilmesi ile uzun vadede toplam hata azaltılabilmektedir. 10000 devir sonrası algoritma 5,603m pozisyon hatası düzeltilmiştir. Bu değer şu şekilde hesaplanmıştır:

$$e_{düzeltilen} = \sum_{i=1}^n e_{öğrenmeyen_i} - e_{öğrenen_i} \quad (3)$$

Keşif oranını arttırarak durumlar hakkında daha kısa sürede bilgi toplamak mümkün olmakla beraber, daha fazla keşif daha fazla hata yapılmasına neden olacaktır. Hatta bu yüksek hatalar uzun vadede öğrenen mekanizmanın öğrenmeyen mekanizmaya göre daha kötü sonuçlar elde etmesine bile neden olabilir. Şekil 5'te diğer tüm parametreler sabit tutulup keşif oranı %5'ten %30'a çıkarılarak benzetim yapıldığında mekanizmanın karşılaştığı pozisyon hatası görülmektedir. Bu benzetimde denklem (3) kullanılarak $e_{düzeltilen}$ -5,335m olarak hesaplanmıştır.



Şekil 5: %30 keşif oranı ile öğrenen ve öğrenmeyen mekanizmaların hata miktarları.

5. Sonuçlar

Takviyeli öğrenme yönteminin benzetim ortamında eklem boşluklu bir dört kol mekanizmasının pozisyon hatasının azaltılmasında doğru keşif oranı seçildiği zaman başarılı olduğu görülmüştür. Alternatif bir seçenek olarak öğrenme oranı başlangıçta yüksek tutulup belirli bir bilgi düzeyine ulaşıldıktan sonra düşürülebilir. Böylece sistem hakkında daha hızlı bir şekilde bilgi toplanabilir.

Bu yöntem çok uzun süreler insan müdahalesinin mümkün olmadığı ortamlarda çalışması gereken mekanizmalar için uygundur ancak gerçek sistemlere uygulanmasında sonlandırıcı pozisyonunun ölçülmesi, çok hassas prizmatik eklemlere ihtiyaç duyulması ve uzun öğrenme süreci gibi zorluklar bulunmaktadır.

6. Kaynakça

- [1] N. Binaud, S. Caro, S. Bai ve P. Wenger, “Comparison of 3-PPR Parallel Planar Manipulators Based on their Sensitivity to Joint Clearances”, *The 2010 IEEE/RSJ International Conference on Intelligent Robots and Systems*, Taipei, Taiwan, 2010.
- [2] P. Flores ve J. Ambrosio, “Revolute joints with clearance in multibody systems”, *Computers and Structures*, s: 1359–1369, 2004
- [3] S. Erkaya ve İ. Uzman, “Determining link parameters using genetic algorithm”, *Mechanism and Machine Theory*, s: 222–234, 2009
- [4] R. S. Sutton ve A. G. Barto, *Reinforcement Learning: An Introduction*, MIT Press, 1998
- [5] E. Uchibe, M. Asada ve K. Hosoda, “Behavior Coordination for a Mobile Robot Using Modular Reinforcement Learning”, *IEEE/RSJ International Conference*, 1996

- [6] L. Zu, P. Yang, L. Chen, X. Zhang ve Y. Tian, "Obstacle Avoidance of Multi Mobile Robots Based on Behavior Decomposition Reinforcement Learning", International Conference on Robotics and Biomimetics, 2007
- [7] N. J. Van Eck ve M. van Wezel, "Application of reinforcement learning to the game of Othello", Computers & Operations Research, 2008
- [8] X. Jinlin, G. Qiang ve J. Weiping, "Reinforcement Learning for Engine Idle Speed Control", International Conference on Measuring Technology and Mechatronics Automation, 2010