

Parametrik Dinamik Motor Primitifleri

Hakan Girgin^{1,2} ve Emre Uğur¹

¹Bilgisayar Mühendisliği Bölümü, ²Sistem ve Kontrol Mühendisliği Bölümü

Boğaziçi Üniversitesi

İstanbul, Türkiye

Email: {hakan.girgin, emre.ugur}@boun.edu.tr

Özetçe —Gösterim yoluyla öğrenen robotlardaki en çok araştırılan ve ele alınan konulardan bir tanesi, öğrenilen beceriyi daha önce karşılaşılmamış durumlara genelleme problemi. Dinamik Motor Primitifleri (DMP), becerinin yörüngesinin ilk ve son konumuyla beraber şeklini de gürbüz bir şekilde kodlayarak hareketin farklı konumlarda da gerçekleştirilebilmesini sağlamaktadır. Ancak karmaşık yörüngeye sahip becerilerde, konum bilgisinin değişmesi, yörünge şeklini standart DMP ile öğrenilenden çok daha fazla etkilemekte ve becerinin başarılı bir şekilde tamamlanmasına engel olmaktadır. Bu nedenle, birden fazla gösterimle parametrik yörünge şekilleri öğrenerek genelleme probleminde daha başarılı olan bir yöntem gereklidir. Bu bildiride bu amaca yönelik olarak, DMP modellerinin şekillendirici terimlerinin, faz değişkeni uzayında Parametrik Saklı Markov Modelleri (PHMM) ile modellenmesiyle elde edilen Parametrik Dinamik Motor Primitifleri (PDMP) önerilmektedir. Önerilen yöntem 2 boyutlu engelden kaçınma problemiyle kavram ispatı olarak gösterilmekte ve Baxter robotla bir dolap açma senaryosunda kullanılmaktadır. Standart DMP ile kodlandığında açılma yörüngesi yaratılamayacak olan dolabın, PDMP kullanıldığında açılabilmesi ve beceriyi dolap kulp konumlarına genellebildiği gösterilmektedir.


Anahtar Kelimeler—dinamik motor primitifleri, parametrik hareket gösterimleri, gösterim yoluyla öğrenme

I. GİRİŞ

Gösterim yoluyla öğrenme, karmaşık motor programlarını robotlara doğrudan öğretmek için, insanlar tarafından gerçekleştirilen hareketlerin gözlemlene, öğrenme ve taklit edilmesi yoluyla robotlara aktarımını öneren metotlar kümesidir. Gösterim yoluyla öğrenme, nesne kavrama ve manipülasyonu dahil [1]–[5] çok farklı robot öğrenme problemlerine uygulanmıştır [6], [7]. Diğerleri arasında, dinamik sistemler ve istatistiksel modellemeye dayalı metotlar son yıllarda yaygın olarak araştırılmaktadır.

Dinamik Motor Primitifler (Dynamic Motor Primitives - DMP) [8], gösterilmiş hareket yörüngelerini diferansiyel denklemler olarak ifade etmekte ve doğrusal olmayan, bir kez gözlemlenmiş hareketleri gürbüz bir şekilde kodlamaktadırlar. DMP'ler ile ifade edilen robot programları, hareket gerçekleştirilirken dışarıdan gelen sarsıntılara rağmen son amaca ulaşma garantisi sunarak gerçek-zamanlı gürbüz bir şekilde çalışabilirler. Ayrıca başlangıç ve son amaç noktaları değiştirilse de ya da ortama engeller yerleştirilse de, hareketin şekli aynı kalacak şekilde, öğrenilen motor programlarını bu değişikliklerle başa çıkabilecek şekilde genelleyeabilmektedirler [9]. DMP sisteminin parametreleri farklı gelişmiş algoritmalarla öğrenilebilmektedir. Bunlar arasında Atkenson, Moore


Türkiye Robotbilim Konferansı, 2018



Şekil 1: Dolap kapağını açarken Baxter robot.

ve Schaal tarafından önerilen Yerel Ağırlıklı Bağlanım (Locally Weighted Regression, LWR [10]) ve türevleri [11] yaygın ve başarılı olarak kullanılmaktadır. Bu metotlar, bağlanım problemlerini öğrenmesi zor birleşik global problem uzayında çözmek yerine, global öğrenme uzayını bölerek, her yerele özgü nispeten daha basit modeller öğrenmekte ve bunları doğrusal olarak birleştirmektedir. DMP parametrelerinin bu veya benzer parametrelerle öğrenilmesiyle gözlemlenen hareketler robot tarafından tekrar edilebilir hale gelmektedir.

Motivasyon: DMP modellerinde öğrenilen (2). denklemdaki doğrusal olmayan fonksiyon $f(s)$, yörüngesinin şekliyle ilgili bilgiyi tutmakta, diğer terimler ise yörüngesinin belli bir ilk konumdan belli bir son konuma, istenilen sürede ulaşmasını sağlamaktadır. Dolayısıyla DMP, çok karmaşık olmayan kaldırıp yerleştirme, itme gibi hareketlerde, harekete geçirilmek istenilen objenin ilk veya son konumlarındaki statik veya dinamik değişikliklere, yörüngesinin şeklini koruyarak gürbüz bir şekilde cevap vermektedir. Ancak, dolap kapağı açma gibi daha karmaşık hareketlerde ilk ve/veya son pozisyonu değiştirerek yörüngesinin şeklini korumak, dolabın kapağını açmaya yetecek bir yörünge oluşturamaz. Böyle durumlarda, ortamdaki obje konumları, ağırlıkları vb. parametrelere bağlı yörünge modelleri oluşturup, değişen parametrelere göre yörünge şeklinin tahmin edilmesi gerekmektedir. Örneğin Şekil 2'de görülen engelden kaçınma probleminde 4 farklı son konumu olan, engelden kaçınmış yörüngeler gösterilmiş ve bu yörüngelerden bir DMP modeli çıkartılmıştır. Çıkarılan DMP modelinin son konumunu, engellerden kaçınan yörüngelerin şekillerinden öğrendiği doğrusal olmayan fonksiyonu koruyarak, çarpı ile gösterilen tekil noktaya yakın bir konumla



Şekil 2: 4 farklı son konuma giden gösterimlerden öğrenilen DMP modelinde son konumun çarpı ile gösterilen tekil noktaya yakın verilmesi ile üretilen yörüngenin şekli verilmiştir. Her ne kadar gösterimlerin hepsi engelden kaçınmış olsa da, bu yeni üretilen yörünge engelden kaçınmamıştır.

değiştirdiğimizde, yörüngenin engelden kaçınma görevini yerine getiremediği görülmektedir. Burada, son konum parametresine bağlı bir öğrenme ile engelden kaçınma görevinin tekil noktalara ne kadar yakın olursa olsun başarıyla gerçekleştirilebileceği gösterilmek istenmektedir.

DMP'nin şekillendirici terimini göreve belli parametrelerle bağlayarak modelleme yakın zamanda ele alınmaya başlanan konulardan olmuştur. Zhou et al. [12] bildirilerinde LWR'ı ortam kısıtlamalarına ve parametrelerine bağlı yeni bir objektif fonksiyonu tanımlayarak gerçekleştiren ve tüm parametrik uzayda çalışabilmesi için de bir model-değiştirici algoritmaya dayanan bir yöntem kullanmışlardır. Ancak burada öğrenilen ağırlıklar gösterimlerden gelen varyasyonu tanımlayabilecek özellikte değildirler. Pervez et al. ise [13] DMP'nin şekillendirici terimini Gauss Karışım Modelleri (GMM) ile öğrenip, Gauss Karışım Bağlanımı (GMR) ile tekrar oluşturmuşlardır. GMM ile öğrenirken veri kümelerine boyutluluğu artırma pahasına ortam parametrelerini de ekleyip, bu parametrelere ait varyansın değerini başlangıçtan itibaren hiç değişmeyen küçük bir epsilon değeriyle sabit tutmuşlardır.

Bu bildiride, DMP modellerinin şekillendirici doğrusal olmayan fonksiyonlarını belirli bir parametreye bağlı olarak öğrenip, yörünge şeklini de bu parametrelere göre adapte etmesini sağlayan parametrik dinamik motor primitifleri (PDMP) sunulmuştur. PDMP'de doğrusal olmayan fonksiyon Parametrik Saklı Markov Modelleri (PHMM) [14] ile öğrenilmiştir. PHMM yazarların bilgisine göre robot programlarında daha önce bir kere sıvı dökme görevinde robotun eklem uzayıyla uygulaması gereken kuvvet uzayını, sıvı miktarına bağlayan model oluşturulmuştur [15]. Ancak burada, tüm yörünge PHMM ile modellendiğinden, sisteme robotun çalışması sırasında dinamik değişiklikler uygulamak kolay değildir. Bölüm II, doğrusal olmayan şekillendirici fonksiyonun öğreniminin en gelişkin DMP'de ve bu bildirinin katkısı olan PDMP'de kullanılan yöntemlerini verecektir. Bölüm

III'te kavramın işlevini gösteren kanıtlarla beraber robotla yapılan deney ve deney sonuçları verilip, Bölüm IV'te bildiri sonuçlandırılacaktır.

II. YÖNTEM

A. Gösterim Yoluyla Öğrenme

Robota gösterim yoluyla öğretilen görevin yörüngesi, eklem uzayında veya çalışma uzayında D serbestlik derecesinde, T süresi boyunca kaydedilip öğrenme veri kümesi aşağıda verildiği gibi oluşturulmaktadır.

$$S = \{x_d(t)\}_{t=0, d=1}^{t=T, d=D} \quad (1)$$

Bu bildiride okunmayı kolaylaştırması ve her serbestlik derecesinde genellenebilir olması nedeniyle, $x_d(t)$ yerine $x(t) \equiv x$ kullanılacak ve kullanılan yöntemler sadece bir serbestlik derecesiyle verilecektir.

B. Dinamik Motor Primitifleri

Bir serbestlik derecesi için DMP aşağıdaki diferansiyel denklem kümesinden oluşmaktadır.

$$\tau \dot{v} = K(g - x) - Dv - K(g - x_0)s + Kf(s) \quad (2)$$

$$\tau \dot{x} = v \quad (3)$$

Denklemlerde,

- x ve $\dot{x}$ konum ve hızı,
- x_0 ve g ilk ve son konumu,
- v ve $\dot{v}$ gösterimin süresi olan τ 'ya göre ölçeklendirilmiş hız ve ivmeyi,
- K ve D orantılama ve sönümlleme sabitlerini,
- $f(s)$ ise faz değişkeni olan s 'in doğrusal olmayan bir fonksiyonunu

temsil etmektedir.

K ve D 'nin seçimi kritik sönümlleme olacak şekilde yapılmakta ve sönümlleme sabiti $D = 2\sqrt{K}$ olarak alınmaktadır. Faz değişkeni s , zamanı (t),

$$\tau \dot{s} = -\alpha s \quad (4)$$

denklemini ile kodlayarak DMP yörüngesinin zamana bağlı pertürbasyonlara dayanıklı hale gelmesini sağlamaktadır. Faz denkleminde göre, α , faz değişkeninin 1'den başlayıp, $t = \tau$ 'da 0 ile bitmesini sağlayacak şekilde, $s = \exp(-\alpha \frac{t}{\tau})$ denkleminde göre hesaplanmaktadır. Ayrıca, DMP'nin her serbestlik derecesinin aynı faz değişkenisiyle başlatılıp, faz denkleminde göre entegre edilmesi, bu serbestlik derecelerinin simultane bir şekilde çalışmasını kesinleştirmektedir.

C. Şekillendirici Fonksiyonu Öğrenme

Doğrusal olmayan ve yörüngeye şeklini veren bu fonksiyonların öğrenilmesinde en gelişkin metot olması ve bu bildiride karşılaştırma amaçlı kullanılacak olmasından dolayı önce, Yerel Ağırlıklı Bağlanım (LWR) metodu verilip daha sonra bildirinin asıl katkısı olan Parametrik Saklı Markov Modeller (PHMM) anlatılacaktır. Öğrenme için gösterimlerden elde edilen data S kullanılarak, nümerik Euler türev alma yöntemiyle her x için $\dot{x}$ ve $\ddot{x}$ hesaplanmalı, zamana bağlı olarak faz değişkeni entegre edilmeli ve en sonunda (2) ve (3) kullanılarak aşağıdaki denklemde yerine konulup öğrenilmek istenen şekillendirici fonksiyon değerleri $f_{target}(s)$ bulunmalıdır.

$$f_{target}(s) = -(g - x) + (g - x_0)s + \frac{\tau\dot{v} + Dv}{K} \quad (5)$$

1) *Yerel Ağırlıklı Bağlanım* : Yörüngeyi şekli $f(s)$, denklemdaki (6) gibi radyal bazlı fonksiyonlar (ψ_i)'ın normalize edilmiş ağırlıklı toplamları ile kodlanmaktadır.

$$f(s) = \frac{\sum_i w_i \psi_i(s)s}{\sum_i \psi_i(s)} \quad (6)$$

Burada $\psi_i = \exp(-h_i(s - c_i)^2)$ radyal bazlı fonksiyonlar olup c_i ve h_i sırasıyla bu fonksiyonların merkezini ve varyansını ifade etmektedir. Ağırlıkları w_i ise lineer regresyonla öğrenilmekte ve bu ağırlıklar her motor primitifine özel parametreleri oluşturmaktadırlar. Bu ağırlıkları ve şekillendirici fonksiyonu bir gösterim için vektörel formda ifade ettiğimizde, (7) ve (8) elde edilmekte ve bu terimler arasındaki ilişki (9) ile verilmektedir.

$$\mathbf{f} = \begin{bmatrix} f_{target}(s_1) \\ \dots \\ f_{target}(s_T) \end{bmatrix}, \mathbf{w} = \begin{bmatrix} w_1 \\ \dots \\ w_N \end{bmatrix} \quad (7)$$

$$\mathbf{X} = \begin{bmatrix} \frac{\psi_1(s_1)}{\sum_i \psi_i(s_1)} s_1 & \dots & \frac{\psi_N(s_1)}{\sum_i \psi_i(s_1)} s_1 \\ \dots & \dots & \dots \\ \frac{\psi_1(s_T)}{\sum_i \psi_i(s_T)} s_T & \dots & \frac{\psi_N(s_T)}{\sum_i \psi_i(s_T)} s_T \end{bmatrix} \quad (8)$$

$$\mathbf{X}\mathbf{w} = \mathbf{f} \quad (9)$$

Denklem (9)'daki ağırlıklar vektörü $\mathbf{w}$ ise

$$\mathbf{w} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{f} \quad (10)$$

denklemini ile bulunabilir.

2) *Parametrik Saklı Markov Modeller*: Saklı Markov Model (HMM), θ , N adet saklı faktörün önsel dağılımları (π_i), geçiş olasılıkları (a_{ij}) ve gözlem olasılık dağılımı (b_i)'ndan oluşmaktadır.

$$\theta = \{\pi_i, a_{ij}, b_i\}_{i,j=1}^N$$

Buradaki gözlem olasılık dağılımı sürekli olduğu durumda genellikle her bir faktör birer çokdeğişkenli, merkezi μ_i , kovaryans matrisi Σ_i Gauss dağılımıyla ifade edilmektedir. Verilen bu model parametreleri, Beklenti Maksimizasyonu (EM)

Algoritması'nın bir türü olan Baum-Welch Algoritması ile öğrenilmekte olup, daha detaylı açıklama için Rabiner'in [16] makalesine danışılabilir. Ancak HMM'in bu hali, görevin gösterimlerine ait ortam parametreleri bilgisini yok saymaktadır. Bu nedenle, bu bildiride, HMM'in parametrik versiyonu olan Parametrik Saklı Markov Modelleri (PHMM)'nin kullanılması önerilmektedir. Bu modellerde, gözlem olasılık dağılımları artık, Gauss dağılım fonksiyonlarının merkezleri aracılığıyla gösterimlerin parametreleri $\theta = \{\theta_k\}_{k=1}^K$ 'nin bir fonksiyonu olup, burada K , gösterim sayısını ifade etmektedir. Buna göre, her saklı faktörün ürettiği Gauss dağılımının merkezi, θ_k 'in doğrusal bir fonksiyonu olup aşağıdaki gibi ifade edilmektedir.

$$\hat{\mu}_i(\theta_k) = \mathbf{W}_i \theta_k + \mu_i \quad (11)$$

Bu durumda önsel dağılımlar ve geçiş olasılıklarının yanında gözlem olasılık dağılımını belirlemek için μ_i ve Σ_i 'nin yanında $\mathbf{W}_i$ de bulunmalıdır. Ancak Baum-Welch Algoritması'nda $\mathbf{W}_i$ ve μ_i 'nin değerini ayrı ayrı güncellenen dezanvantajı birini güncellerken diğerinin güncellenmemiş değerini kullanmaya itmesidir. Bu değerleri (12)'deki gibi yazarak, gözlem olasılık dağılımı için sadece $\mathbf{Z}_i$ ve Σ_i 'yi güncellememiz yetmektedir. Daha detaylı bilgi için [14]'ye başvurulabilir.

$$\mathbf{Z}_i \equiv [\mathbf{W}_i \ \mu_i], \ \Omega_k \equiv \begin{bmatrix} \theta_k \\ 1 \end{bmatrix} \quad (12)$$

DMP'deki şekillendirici doğrusal olmayan ve faz değişkenine bağlı fonksiyon, PHMM ile her biri bir veya birden fazla parametreye sahip K tane gösterimden elde edilen (13)'teki veri kümesinden öğrenildiğinde parametrik bir şekillendirici fonksiyon modeli elde edilmektedir. Bu modele yeni bir parametre verildiğinde bu model sayesinde (11) ve (12)'yi kullanarak Gauss dağılımlarının yeni merkezleri hesaplanacak ve yeni ortam yapılarına uyum sağlayan hareket primitifleri elde edilmiş olacaktır.

$$D = \{s_t, f_{target_k}(s_t)\}_{t=1, k=1}^{T, K} \quad (13)$$


D. Yörünge Oluşumu

1) *Yerel Ağırlıklarla Oluşturma*: (10) ile Öğrendiğimiz radyal bazlı fonksiyonların ağırlıklarını, radyal bazlı fonksiyonların değerlerini ve faz değişkenini, (6)'da yerine koyarak şekillendirici fonksiyonun değerleri hesaplanır. Bu değerler ile (2), (3) ve (4) kullanılarak istenilen konum ve hız hesaplanır.

2) *Gauss Karışım Bağlanımı*: PHMM ile elde edilen modelde, yeni bir parametrenin sisteme verilmesiyle her saklı faktör için bir çokdeğişkenli Gauss dağılımı oluşur. Bu dağılımların merkez vektörü μ_i ve kovaryans matrisi Σ_i , istenilen girdi (x) ve çıktılara (y) göre bölüntülenmiş matrisler olarak (14) ifade edilebilirler.

$$\mu_i = \begin{bmatrix} \mu_i^x \\ \mu_i^y \end{bmatrix}, \ \Sigma_i = \begin{bmatrix} \Sigma_i^{xx} & \Sigma_i^{xy} \\ \Sigma_i^{yx} & \Sigma_i^{yy} \end{bmatrix} \quad (14)$$

Bu durumda, GMR yöntemine göre, girdi vektörü ve PHMM ile elden edilen Gauss dağılımı verildiğinde, çıktı vektörü (15)'teki gibi bulunabilir [17].



Şekil 3: Bu sefer, gösterimlerin son konumlarına bağlı olarak öğrenilen PDMP modeli, çarpı ile gösterilen tekil noktaya ne kadar yakın olursa olsun, engelden kaçınabilmektedir.

$$y = \sum_{i=1}^N h_i [\mu_i^y + \Sigma_i^{yx} (\Sigma_i^{xx})^{-1} (x - \mu_i^x)] \quad (15)$$

Burada h_i girdiye bağlı bir ağırlık faktörü olup (16) ile hesaplanır. (16)'da $\mathcal{N}(x; \mu_i^x, \Sigma_i^{xx})$, girdinin çokdeğişkenli Gauss yoğunluk fonksiyonunu ifade etmektedir.

$$h_i = \frac{\mathcal{N}(x; \mu_i^x, \Sigma_i^{xx})}{\sum_{i=1}^N \mathcal{N}(x; \mu_i^x, \Sigma_i^{xx})} \quad (16)$$

PDMP modelinde, girdi ve çıktı sırasıyla (13)'teki s_t ve $f_{target_k}(s_t)$ alındığında, yeni ortam parametresi için şekillendirici fonksiyonun değeri hesaplanmış olur.


III. DENEYLER

A. Kavram İspatı

Bildirinin başında verilen engelden kaçınma probleminde PDMP'ye 4 farklı son konum parametresiyle yörüngenin şekillendirici fonksiyonunu öğrenmesi sağlanmıştır. DMP ile öğrenilen yörünge şekli engelden kaçınma görevinde başarısız olurken, PDMP'de kullanılan çok değişkenli Gauss yoğunluk fonksiyonlarının parametreye bağlı bağlanması sayesinde PDMP'nin tahmin ettiği yörünge tekil noktaya yakınlığına bakılmaksızın her son konum parametresinde engelden kaçınmayı başarabilmiştir (Şekil 3).

B. Robot Platformu

Deney düzeneğimiz 7 serbestlik derecesine sahip iki antropomorfik kollu Baxter robot ve her biri yanındakinden 5 cm uzaklıkta olan 5 kulplu bir dolaptan oluşmaktadır (Şekil 1). Deneylerde robotun sol koluna 3 boyutlu yazıcıdan çıkarılan ve dolap kulbuna kenetlenmesini sağlayan kancanın yerinde durmasını sağlayan yapay bir tutucu bağlanmıştır.



Şekil 4: Her kulptan alınan yörüngelerin şekillendirici fonksiyonları ve öğrenilen PHMM modeli. Ellipslerin yarıçapları ve merkezi, saklı faktörlerin ürettiği Gauss yoğunluk fonksiyonlarının sırasıyla merkezini ve varyansını ifade etmektedir.

C. Dolap Kapağı Açma Görevi


Robotun kinestetik yoluyla Şekil 5'teki gibi 1., 2., 4. ve 5. kulplardan tutarak dolabın kapağını açması sağlanıp, 7 serbestlik dereceli çalışma uzayı konumları (3 boyutlu konum ve 4 boyutlu dördey) ve konumlara karşılık gelen zaman bilgisi kaydedilmiştir. Sadelik adına, gösterimlerden elde edilen yörüngelerin sadece 2 boyutlu konumları Şekil 6'da gösterilmiştir. Amaç, bu kulpların gösterim yörüngelerinden elde edilen ve kulp pozisyonuna bağlı model sayesinde, robotun daha önce görmediği kulp konumlarına genelleme yaparak, bunların açılma yörüngesini hayal etmesini sağlamaktır. Kaydedilen veriler, kulpların, robotun bazal koordinat sistemine göre ifade edilmiş konumlarının parametre olarak alıp PDMP ile modellenmiştir. Modellemede, her biri dörder tane çokdeğişkenli Gauss yoğunluk fonksiyonları üreten 8 farklı saklı faktör ve $K = 5000$ kullanılmıştır.

Her bir saklı faktörün yoğunluk fonksiyonlarının merkezleri, gösterimlerin yörüngelerinin şekillendirici fonksiyonu üzerinde verilen parametreler aracılığıyla, (11)'e göre doğrusal bir şekilde bağlanmıştır (Şekil 4). Gauss fonksiyonlarının kovaryans matrisleri ise her bir saklı faktör için aynı olup, şekillendirici fonksiyonun kendi içindeki değişim bilgisini içermektedir.


Öğrenilen modelle, öğrenme(training) kümesinde olmayan ve robot için yeni bir ortam oluşturan, 3. kulbun, yine robotun bazal koordinat sistemine göre ifade edilmiş konumu parametre olarak verilip, 8 saklı faktörün yeni merkezleri hesaplanmıştır. Gauss fonksiyonlarının yeni merkezleri ve kovaryans matrisleriyle beraber, referans olarak da kullanıldığımız, dolabın kapağının 3. kulbundan kinestetik yolla robota açtırılmasıyla kaydedilen yörüngenin ilk ve son konumu PDMP'ye verilmiştir. PDMP'nin tahmin ettiği yeni yörünge ve referans yörünge Şekil (6-a))'da verilmiştir. Performans kıyaslaması için de, 1. kulptan alınan gösterimden gelen



Şekil 5: Kinestetik yolla 1. kulpla dolap kapağı açma gösterimi. Aynı gösterimler ortadaki yörüngesi tahmin edilmek istenen 3.kulp dışında 2., 4. ve 5. kulplardan da alınmıştır.



(a) PDMP



(b) DMP

Şekil 6: Dolap kapağını, öğrenme sırasında gösterilmeyen 3. kulptan açmak için (a) PDMP ile üretilen, (b) DMP ile üretilen yörüngenin x-y düzlemindeki grafiği. PDMP ile üretilen yörünge referans yörüngeye çok benzer bir yol izlerken, DMP ile üretilen yörünge 1. kulptan öğrenilen yörünge şeklini korumaya çalışarak başarısız olmuştur.



Şekil 7: PDMP ile öğrenilen modele 3. kulbun ilk konumu parametre olarak verilerek üretilen yörüngenin Baxter robot tarafından uygulanması. Video linki : <https://youtu.be/GD1WFIIBCsa>

yörünge, LWR ile öğrenen DMP ile modellenmiştir. DMP'nin şeklini koruyarak, yörünge'nin ilk ve son pozisyonunu, 3. kulptan dolabı açtığımızda elde ettiğimiz ilk ve son konumla değiştirdiğimizde elde edilen yörünge ve referans yörünge ise Şekil (6-(b))'de gösterilmiştir. Görüldüğü üzere standart DMP 1. kulptan öğrenilen modelle 3. kulbu açmakta başarısız olacaktır.

Öğrenilen modelin referans yörüngeye çok benzeyen bir yörünge oluşturduğu görülmüş ve robotun bu yörüngeyi uygulaması sağlanmıştır. Robotun dolap kapağını öğrenilen model sayesinde 3. kulbundan açtığı Şekil 7'de gösterilmiştir.

IV. SONUÇ

Bu bildiride gösterim yoluyla öğrenme yönteminde ortam değişkenlerini parametre olarak alarak yörünge şeklini modelleyen PDMP önerilmiştir. Standart DMP'nin genellemede yetersiz kaldığı dolap kapağı açma gibi karmaşık becerilerde, PDMP'nin, karşılaşılan yeni ortam değişkenlerinde gerçekte olan yörüngeye çok yakın tahminler yaptığı gösterilmiştir. Ayrıca PDMP, standart DMP'nin, robot çalışması sırasında dinamik değişikliklere gürbüz bir şekilde cevap vermesi ve HMM'in gösterimlerin yörüngelerindeki varyansını da öğrenmesi gibi iki hareket primitifleri kodlama yöntemlerinin de güçlü yanlarını almaktadır.

İleride yapılabilecek çalışmalarda, daha karmaşık hareketlerin çoklu gösterimlerinden öğrenilen PHMM bazlı DMP yörüngelerinde bulunan yüksek varyanslı kısımları robotu daha işbirlikçi yapmak için insan-robot düzeneklerinde kullanmayı planlıyoruz. Ayrıca ileride PHMM'de merkezlerin bağlanması yanında, kovaryans matrislerinin de bağlanarak öğrenilmesi [18] varyanslarından robot çalışması sırasında işbirliği bakımından faydalanılması sayılabilir.

TEŞEKKÜR

Bu çalışma TÜBİTAK BİDEB 2232 Yurda Dönüş Araştırma Burs Programı'nın 117C016 numaralı projesi, Avrupa Komisyonu Ufuk 2020 Programı'nın 731761 numaralı IMAGINE projesi ve Bogazici Araştırma Fonu Startup projesi 12022 tarafından kısmi olarak desteklenmiştir.

KAYNAKÇA

- [1] S. Calinon, P. Evrard, E. Gribovskaya, A. Billard, and A. Kheddar, "Learning collaborative manipulation tasks by demonstration using a haptic interface," in *2009 International Conference on Advanced Robotics*, June 2009, pp. 1–6.
- [2] T. Asfour, P. Azad, F. Gyarfas, and R. Dillmann, "Imitation learning of dual-arm manipulation tasks in humanoid robots," *International Journal of Humanoid Robotics*, vol. 5, no. 02, pp. 183–202, 2008.
- [3] P. Pastor, L. Righetti, M. Kalakrishnan, and S. Schaal, "Online movement adaptation based on previous sensor experiences," in *Intelligent Robots and Systems (IROS), 2011 IEEE/RSJ International Conference on*. IEEE, 2011, pp. 365–371.
- [4] H. Ben Amor, O. Kroemer, U. Hillenbrand, G. Neumann, and J. Peters, "Generalization of human grasping for multi-fingered robot hands," in *Intelligent Robots and Systems (IROS), 2012 IEEE/RSJ International Conference on*. IEEE, 2012, pp. 2043–2050.
- [5] M. Mühlig, M. Gienger, and J. J. Steil, "Interactive imitation learning of object movement skills," *Autonomous Robots*, vol. 32, no. 2, pp. 97–114, 2012.
- [6] A. Billard, S. Calinon, R. Dillmann, and S. Schaal, "Robot programming by demonstration," *Handbook of robotics*, vol. 1, 2008.
- [7] B. D. Argall, S. Chernova, M. Veloso, and B. Browning, "A survey of robot learning from demonstration," *Robotics and autonomous systems*, vol. 57, no. 5, pp. 469–483, 2009.
- [8] S. Schaal, "Dynamic movement primitives-a framework for motor control in humans and humanoid robotics," in *Adaptive Motion of Animals and Machines*. Springer, 2006, pp. 261–280.
- [9] P. Pastor, H. Hoffmann, T. Asfour, and S. Schaal, "Learning and generalization of motor skills by learning from demonstration," in *Robotics and Automation, 2009. ICRA'09. IEEE International Conference on*. IEEE, 2009, pp. 763–768.
- [10] C. G. Atkeson, A. W. Moore, and S. Schaal, "Locally weighted learning for control," in *Lazy learning*. Springer, 1997, pp. 75–113.
- [11] S. Vijayakumar and S. Schaal, "Locally weighted projection regression: Incremental real time learning in high dimensional space," in *Proceedings of the Seventeenth International Conference on Machine Learning*. Morgan Kaufmann Publishers Inc., 2000, pp. 1079–1086.
- [12] Y. Zhou and T. Asfour, "Task-oriented generalization of dynamic movement primitive," in *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Sept 2017, pp. 3202–3209.
- [13] A. Pervez and D. Lee, "Learning task parameterized dynamic movement primitives using mixture of gmms," *Intelligent Service Robotics*, 2017. [Online]. Available: <http://elib.dlr.de/113356/>
- [14] A. D. Wilson and A. F. Bobick, "Parametric hidden markov models for gesture recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 21, no. 9, pp. 884–900, Sep 1999.
- [15] L. Roza, P. Jiménez, and C. Torras, "Force-based robot learning of pouring skills using parametric hidden markov models," in *Robot Motion and Control (RoMoCo), 2013 9th Workshop on*. IEEE, 2013, pp. 227–232.
- [16] L. R. Rabiner, "A tutorial on hidden markov models and selected applications in speech recognition," *Proceedings of the IEEE*, vol. 77, no. 2, pp. 257–286, Feb 1989.
- [17] Z. Ghahramani and M. I. Jordan, "Supervised learning from incomplete data via an em approach," in *Advances in Neural Information Processing Systems 6*. Morgan Kaufmann, 1994, pp. 120–127.
- [18] A. K. Tanwani and S. Calinon, "Learning robot manipulation tasks with task-parameterized semitied hidden semi-markov model," *IEEE Robotics and Automation Letters*, vol. 1, no. 1, pp. 235–242, Jan 2016.