

# İlişkili Robotik Görevlerin Ortak Kodlamasının Öğrenilmesi

## Learning Shared Encoding of Related Robotic Tasks

Serdar Bahar, Yiğit Yıldırım, Emre Uğur

Bilgisayar Mühendisliği Bölümü

Boğaziçi Üniversitesi

İstanbul, Türkiye

serdar.bahar@std.bogazici.edu.tr, {yigit.yildirim, emre.ugur}@bogazici.edu.tr

**Özetçe**—Geleneksel yöntemler görev transfer problemini genellikle tabandan tepeye yöntemlerle veya Pekiştirmeli Öğrenme ve tersine oynatma gibi akıllıca tasarlanmış sistemlerle çözer. Ancak, benzer ve ilişkili görevlerin uygulandığı ortak anlamsal bağlamdan yararlanmak paylaşımlı temsillerin kullanılmasıyla öğrenme performansını arttırabilir. Bu çalışmada ilişkili robot görevi gösterimlerini bir arada öğrenen ve ortak temsilleri aktif bir şekilde keşfetmeye çalışan bir Göstererek Öğrenme modeli öneriyoruz. Bu sayede modelimiz, verilen bir gösterimden hareketle ilişkili bir diğer gösterimi üretmeyi öğrenir. Bu çalışmada, modelimizin performansını sentetik olarak üretilen gezinmelerde gösterdik ve ardından modelimizi ilişkili olan bir günlük görev çiftini kullanarak bir benzetim ortamında değerlendirdik.

**Anahtar Kelimeler**—Göstererek Öğrenme, Duyumotor Öğrenme

**Abstract**—Conventional techniques usually solve the task transfer problem through bottom-up approaches or cleverly designed tricks, such as Reinforcement Learning or reverse execution. However, leveraging the common semantic context between executions of similar or related tasks may promote learning performance by enabling the utilization of shared representations. In this study, we propose a Learning-from-Demonstration model that simultaneously learns from semantically related demonstrations while actively attempting to discover the common representations of both. By doing so, our model learns to generate trajectories from related demonstrations. We showcased the performance of our model in synthetically generated trajectories. Later, we assessed our model with a daily, related task couple in a simulation environment.

**Keywords**—Learning from Demonstration, Sensorimotor Learning

### I. GİRİŞ

Robot becerilerinin ölçeklenebilirliği ve genellenebilirliği gerçek dünya uygulamaları için gereken verimlilik ve esneklik açısından büyük önem taşır. Robot becerilerinin genellenmesi üzerine yapılan çalışmalar literatürde geniş yer kaplar [1]. Fakat her robot becerisini ayrı bir modelle öğrenen sistemler, öğrenilmesi gereken çok sayıda beceri olduğunda ölçeklenirlik açısından önemli sınırlar getirir.

Bazı beceriler doğası gereği birbirleriyle ilişkilidir. Birbirleriyle ilişkili becerilerin birlikte öğrenilmesi, becerilerin ortak bağlamının daha iyi öğrenilmesini sağlarken ölçeklenirliğe de

katkıda bulunur. Böylesine ilişkili becerilere, ileri ve karşıt görevler örnek olarak verilebilir. Bu çerçevede, karşıt görev, ileri görevin bitiş durumundan başlayıp, başlangıç durumunda biten görevi ifade etmektedir. Literatürde, montaj planlama görevlerinin, daha basit karşılıkları olan demontaj planlarından öğreniminin genel performansa katkısı gösterilmiştir [2]. Bu çalışmada, Pekiştirmeli Öğrenme (PÖ) yaklaşımı yalnızca basit ve kesikli becerilerde denenmiştir. Benzer amaçla yapılan bir başka çalışmada İleri-Geri PÖ yöntemi önerilmiş, fakat görevlerin ortak bağlamının sağlayacağı avantaj kullanılmadığı için, yöntemin ölçeklenirliği tartışmalıdır [3]. Ortak bağlamın önemini vurgulayan bir çalışmada ise [4], daha kolay olan demontaj görevlerinden elde edilen gösterimler, zaman ekseninde tersine çevrilerek montaj görevinin öğrenilmesi için özgeçitmen gösterimleri olarak kullanılmıştır. Bu çalışma, görevler arasındaki ortak bağlamın önemini vurgulasa da, zaman ekseninin terse çevrilmesi koşulu, hedef durumun sabit olmadığı stokastik görevler için uygun değildir.

İlişkili beceriler arası ortak bağlamı, özniteliklerin kendiliğinden keşfedildiği Göstererek Öğrenme (GÖ) yaklaşımı ile bulmak öğrenme sürecini daha verimli hale getirir. Bu aynı zamanda, beceri öğreniminin ölçeklenirliğini arttırırken becerinin genellenmesine de katkı sağlar. Robot deneyiminin farklı modalitelerinin ortak bir temsille, özniteliklerin kendiliğinden keşfedilerek öğrenilmesi önerilmiş ve derin öğrenmenin eylem tanıma yeteneklerini kolaylaştırıldığı gösterilmiştir [5]. Özniteliklerin ortak temsillerle keşfedildiği başka bir çalışmada, bir becerinin farklı duyumotor gezinmeleri öğrenilmiştir [6]. Fakat bu çalışmanın ana odağı, aynı becerinin farklı robotlardaki duyumotor bağıntılarını öğrenmek olup çalışmada birbirleriyle anlamsal bağı olan becerilerin öğrenimi değerlendirilmemiştir.

Bildirimizde, derin ağlar kullanarak, anlamsal olarak ilişkili robot becerilerinin ortak kodlamalarını öğrenen ve bu ortak kodlamayla becerilerin gezinmelerini üretebilen bir GÖ modeli öneriyoruz. Önerdiğimiz model, ilişkili becerilerin gösterimlerini eş zamanlı olarak ve iki farklı kanaldan öğrenirken ortak kodların bulunmasını teşvik eder. Dolayısıyla, ortak bağlam bilgisi model tarafından otomatik olarak keşfedilir. Bu sayede özniteliklere aşırı uyumlanma davranışı gözlenmez. Modelimiz kısıtlı girdiyle eğitilebilmektedir ve eğitim sonrası, ortak bağlamı kullanarak koşullanan herhangi bir nokta için gezinmeler üretebilir. Aşağıdaki bölümlerde, önerilen modelin işleyişini detaylandırmakta, ardından benzetim ortamında alternatif, be-

ceriler arası ortak kodlama öğrenmeyen bir beceri öğrenme yöntemi ile karşılaştırmalı bir değerlendirme sunulmaktadır.

## II. YÖNTEM

Önerdiğimiz model, ilişkili robotik becerilerin (1) ortak kodlamalarını öğrenmeyi ve (2) bu ortak kodlamayı kullanarak beceri gezintileri üretmeyi amaçlar. Modelimiz, [6] modeline benzer bir şekilde belirli bir becerinin zaman-damgalı duyumotor gezinge çiftlerinin ortak kodlamalarını derin kodlayıcılar kullanarak öğrenir. Model, eğitim sonrası her ilişkili gezinge çiftinin ortak temsilini öğrenmiş olur. Gezinge üretmek için ise öğrenilen ortak kodlamayla istenilen zamanlar birleştirilerek derin sorgu ağlarından geçirilir. Modelimizin detayları aşağıda açıklanmış olup ilüstrasyonu Şekil 1’te gösterilmiştir.

### A. Temel

Duyumotor gezintilerini derin ağlarla öğrenmek ve genellemesi yapmak için Koşullu Sinirsel Hareket Primitifleri (KSHP) yöntemi önerilmiştir [7]. KSHP, robot gezintilerinden oluşan bir veri kümesi,  $I$ , üzerinde çalışır ve amacı girdi verilen, zaman damgalı bir duyumotor gözleminden geçen gezingenin dağılımını bulmaktır. Her eğitim yinelemesi, veri kümesinden rastgele bir gezingenin,  $I_j = \{(t, S_j)\}_{t=0}^T$ , seçilmesi ile başlar. Ardından, seçilen gezineden rastgele sayıda gözlem seçilerek gözlem kümesi,  $O \subseteq I_j$ , oluşturulur. Oluşturulan gözlem kümesi bir derin kodlayıcıdan geçirilerek gözlem kümesinin gizli temsilleri oluşturulur. Ardından gizli temsillerin ortalaması alınarak gözlem kümesinin genel bir gizli temsili oluşturulur:

$$L = \frac{1}{|O|} \sum_{i=1}^{|O|} E((t_i, S_i)|\theta) \quad (t_i, S_i) \in O \quad (1)$$


Oluşturulan gizli temsil, seçilen gezineden rastgele seçilen bir noktanın,  $(t_{hedef}, S_{j,hedef})$ , zaman damgası ile birleştirilir ve sorgu ağı,  $Q$ ’dan geçirilir.

$$(\mu_{hedef}, \Sigma_{hedef}) = Q(L \oplus t_{hedef}|\phi) \quad (2)$$

Sorgu ağından çıkan ikili, aşağıdaki log olasılık kaybı neticesinde  $O$  gözlem kümesinden geçen gezingenin  $t_{hedef}$  anındaki duyumotor dağılımını verir:

$$Loss = -\log P(S_{j,hedef}|\mu_{hedef}, softplus(\Sigma_{hedef})) \quad (3)$$

Kodlayıcı ve sorgu ağının ağırlıkları,  $\theta$  ve  $\phi$ , tanımlanan kayba göre güncellenir. KSHP modelinin eğitimi tamamlandıktan sonra model bir gözlem kümesi girdi verilip tüm zaman adımları için sorgu yapıldığında, çıktı olarak gözlem kümesinden geçen gezingenin öğrenilen dağılımını verir.



Şekil 1: Önerilen modelin şeması. Eğitim ve gezinge üretme detayları için lütfen metne bakınız.

### B. Model

Önerdiğimiz model, ilişkili becerilerin zaman damgalı duyumotor bilgisini girdi alır. Daha biçimsel olarak,  $I^A$  ve  $I^B$  demonstrasyonu yapılan gezintilerin oluşturduğu veri kümelerini ifade eder.  $I_j^A = \{(t, S_j^A)\}_{t=0}^T$   $j$ 'inci gezinteye tekabül eder.  $I_j^B$  benzer olarak tanımlanır ve  $j$ 'inci gezintinin ilişkili görevdeki karşılık gelen gezintesidir. Her eğitim yinelemesinin başında,  $I^A$  ve  $I^B$  veri kümelerinden rastgele bir gezinge çifti  $I_d^A$  ve  $I_d^B$  örneklenir. Daha sonra,  $I_d^A$  ve  $I_d^B$ 'den veri noktaları seçilerek gözlem kümeleri tanımlanır:

$$O^A = \{(t_i, S_{d,i}^A)\}_i^{\text{azami_gözlem}}, \quad O^B = \{(t_i, S_{d,i}^B)\}_i^{\text{azami_gözlem}} \quad (4)$$

Gözlem kümelerine ek olarak,  $I_d^A$  ve  $I_d^B$ 'den rastgele seçilen hedef noktalar  $(t_{hedef}, S_{d,hedef}^A)$  ve  $(t_{hedef}, S_{d,hedef}^B)$  de belirlenir. Gözlem kümeleri, aşağıdaki denklem kullanılarak hesaplanan gizli temsillere dönüştürülür:

$$L^A = \frac{1}{|O^A|} \sum_i^{|O^A|} E^A((t_i, S_i^A)|\theta^A) \quad (t_i, S_i^A) \in O^A \quad (5)$$

Burada  $E^A$ , ağırlıkları  $\theta^A$  olan derin bir kodlayıcıyı temsil eder ve  $L^A$ , seçilen ileri yönlü gezingenin gizli temsilini ifade eder. İlişki beceri gezintesinin temsili  $L^B$ , benzer şekilde  $E^B$  adlı bir derin kodlayıcı kullanılarak elde edilir. İlişkili beceri çiftine ait ortak bir temsil elde etmek için,  $L^A$  ve  $L^B$ 'nin rastgele bir konveks kombinasyonu alınarak genel bir gizli temsil,  $L$ , oluşturulur:

$$L = pL^A + (1-p)L^B \quad 0 < p < 1 \quad (6)$$

İlişkili görev çiftine ait ortak kodlama elde edildikten sonra, seçilen  $t_{hedef}$  değeri  $L$  ile birleştirilerek bir sorgu oluşturulur ve ardından çözülür. Bu işlem, gezintilerdeki ilgili hedef zaman için duyumotor değerine ait dağılımı üretir:

$$(\mu_{hedef}^A, \Sigma_{hedef}^A) = Q^A(L \oplus t_{hedef}|\phi^A) \quad (7)$$

Burada  $Q^A$ , ağırlıkları  $\phi^A$  olan derin bir sorgu ağı olup,  $\mu_{hedef}^A$  ve  $\Sigma_{hedef}^A$ , A görevinin gezintesini  $t_{hedef}$  anındaki duyumotor dağılımının ortalaması ve standart sapmasını temsil eder. Benzer şekilde,  $\mu_{hedef}^B$  ve  $\Sigma_{hedef}^B$ ,  $Q^B$  derin sorgu ağı kullanılarak elde edilir.

Eğitim sürecinde,  $E^A$ ,  $E^B$ ,  $Q^A$  ve  $Q^B$ 'nin ağırlıkları aşağıdaki negatif log olasılık kaybına göre güncellenir:

$$Loss = -\log P(S_{d,hef}^A | \mu_{hef}^A, softplus(\Sigma_{hef}^A)) - \log P(S_{d,hef}^B | \mu_{hef}^B, softplus(\Sigma_{hef}^B)) \quad (8)$$

Bu kayıpla, tüm ağların ağırlıkları iki görevin gezin-gelerinde duymotor değerlerinin daha doğru dağılımlarını üretmek üzere güncellenir. Yeterli eğitimden sonra, model bir gözlem kümesi verildiğinde doğru duymotor tahminleri yapabilir hale gelir. Özellikle, örneğin, bir beceriye ait bir gözlem girdi verildiğinde, kombinasyon aşamasında  $p = 1$  veya 0 olarak seçilerek diğer ilişkili gezinenin tahmini tüm zaman adımlarının sorguları yapılarak bulunabilir.

### III. DENEYLER


Önerilen model, üç farklı özellikteki gezege çiftiyle test edilmiştir. İlk deney, sentetik, simetrik gezege çiftlerini içerir ve önerilen modelin kanıtı niteliğindedir. İkinci deney, sentetik, asimetrik gezege çiftlerini içerir ve ilk deney ile aynı amacı taşır. Son deney, sentetik gezin-gelerde gözlemlenen başarının ardından modelin daha gerçekçi senaryolarda genelleme kapasitesinin sınanmasını amaçlar ve benzetim ortamında belirlenen bir ilişkili beceri ikilisini öğrenmeyi amaçlar. Bu deneyde önerilen modelin ortak kodlama oluşturmaya çok katmanlı perseptronlarla karşılaştırmasına da yer verilmiştir.

#### A. Sentetik Gezege Çiftleri


Sentetik gezege çiftlerinden oluşan ilk veri kümesinde, bir gezege türü, diğerinin  $y = 0$  çizgisinde simetrisi olacak şekilde oluşturulmuştur. Eğitilen modeldeki kodlayıcılar 128 nöronlu 3 tam bağlantılı katmandan oluşur. Benzer şekilde sorgu ağları 128 nöronlu 3 tam bağlantılı katmandan oluşur. Eğitim sırasında Adam optimizasyon algoritması kullanılıp öğrenme çarpanı deneysel bir şekilde 0.001 olarak belirlenmiştir. Modelin yeterli eğitimi 60,000 epok sürmüştür.

Eğitim sonrası modele seçilen görevden eğitim aralığı içinde bulunan gözlemler girdi verildiğinde diğer görevin gezin-gelerini başarılı bir şekilde ürettiği gözlemlenmiştir. Şekil 2'de modelin ilk gezege türünden kodlayıcıya verilen gözlem kümesinden ürettiği ilişkili gezege tahmini görülür.


Modelin 100 farklı gözlem kümesindeki Ortalama Kare Hatası (OKH) performansı Şekil 3'de verilmiştir. Modele,



Şekil 2: Sentetik, simetrik gezege çiftlerinden oluşan veri kümesi ve modelin gözlem kümesinden ilişkili gezege tahmini.



Şekil 3: Sentetik, simetrik gezege çiftleriyle eğitilen modelin referans gezegeye OKH performansı. Gezege genliği, gözlem kümesinin seçildiği gezinenin belirlenen sinüs fonksiyonundaki genlik değerini belirtir.



Şekil 4: Sentetik, asimetrik gezege çiftlerinden oluşan veri kümesi ve modelin gözlem kümesinden ilişkili gezege tahmini.


eğitim aralığından bir gözlem kümesi verildiğinde neredeyse hatasız tahmin yaptığı gözlemlenmiştir. Fakat, modelin performansının gözlem kümesinin eğitim aralığından uzaklaştığı ölçüde üstel olarak kötüleştiği gözlemlenmiştir.

Benzer şekilde, ilişkili gezege türünün diğer gezinenin simetrisi olmadığı ikinci veri kümesinde de modelin verimli bir şekilde gezege tahmini yapabildiği görülür (Şekil 4). Modelin yeterli eğitimi tamamlaması 90,000 epok sürmüştür.

#### B. Robot Deney Ortamı

Önerilen modelin daha gerçekçi bir ortamda, karşılaştırmalı analizi için, seçilen bir benzetimcide Şekil 5'deki ortam hazırlanmıştır. Bu amaçla MuJoCo motoru [8] seçilmiş ve 7 serbestlik derecesine sahip xArm simüle robotu ve xArm tutucusu kullanılmıştır. İlişkili beceri çifti olarak yeşil objeyi tutup gri kutunun içine koyma ve gri kutuyu tutup ters çevirerek yeşil objeyi masaya düşürmek görevleri belirlenmiştir.

1) *Modeller ve Eğitim Detayları:* Karşılaştırma yapılmak üzere üç model eğitilmiştir: (1) Önerilen model, (2) objeyi kutuya koyma görevine ait gezineyi girdi alan ve diğer göreve ait gezineyi çıkıtlayan bir çok katmanlı perseptron ve (3) kutuyu ters çevirme görevine ait gezineyi girdi alan ve diğer göreve ait gezineyi çıkıtlayan bir çok katmanlı perseptron. (2) ve (3), görev çiftinin gezin-gelerinin ortak bir kodlamasını öğrenmemektedir. (1)'in katman sayısı sentetik gezege çiftlerinde eğitilen modelle aynı tutulmuş olup nöron sayısı 256'ya



Şekil 5: İlişkili iki görevin benzetim ortamları. (A) ortamı yeşil objeyi kutunun içine koyma görevinin, (B) ortamı kutuyu ters çevirip yeşil objeyi düşürme görevinin başlangıç durumlarıdır.

çıkarılmıştır. Ayrıca, (2) ve (3)'ün her birinin ağırlık sayısı (285B) (1)'in ağırlık sayısına yakın tutulmuştur (265B).


Veri kümesi Şekil 5'de gösterilen ortamda obje ve kutunun mavi alan içinde rastgele belirlenen pozisyonlarda verilen görevi tamamlayacak şekilde 48 gezinge çiftinden oluşur. Görev gezinmelerinin illüstrasyonu Şekil 6'te verilmiştir. Gezineler robotun uç işlevcisinin zaman damgalı, 3 boyutlu pozisyonlarından oluşur. Önerilen modelin eğitimi Yöntem'de anlatıldığından farklı olarak ortamda bulunan objelerin x ve y koordinatlarının genel gizli temsille birleştirilmesi suretiyle gerçekleştirilir. Benzer şekilde (2) ve (3)'te de ortam bilgisi eğitim sırasında bir gizli temsille birleştirilir.

2) *Model Performansları*: Modellerin yeterli eğitimi, (1) için 200.000 epok ve hızlı yakınsama sağladığı gözlemlenen (2) ve (3) için ise 1000 epok sürmüştür. Modelleri test etmek için obje ve kutu Şekil 5'de gösterilen mavi bölge içinde rastgele konumlarda oluşturulur ve referans gezinmeler üretilir. Gezinge üretmek için; önerilen modele ilişkili görevin referans gezinmesinin tüm zaman adımlarını içeren gözlem kümesi girdi verilir ve gezinge Yöntem'de anlatıldığı üzere üretilir, (2) ve (3)'e ise görevlerin referans gezinmelerinin tümü girdi verilir. Ardından iki görev için üretilen gezinmeler ile referans gezinmeleri arasında OKH bulunur ve ortalamaları alınır. (2) ve (3)'ün performanslarının ortak değerlendirilmesinin sebebi (2) ve (3)'ün gerçekleştirdiği öğrenmeyi yalnızca (1)'in gerçekleştirebiliyor olmasıdır. Bu, modellerin ağırlık sayıları göz önüne alındığında karşılaştırılan yöntemle daha yüksek bir kapasite verildiğine işaret eder.

Anlatılan test 20 kere tekrarlanmıştır. Önerilen modelin ortalama OKH'si 0.032 m olup karşılaştırılan modellerin ortalama OKH'si 0.056 m'dir. Yapılan t-sınaması aradaki farkın istatistiksel olarak anlamlı olduğunu ortaya çıkarmıştır ( $p=0.0022$ ).

#### IV. SONUÇ

Önerilen modelin sentetik gezinge çiftlerinde verimli bir şekilde gezinge ürettiği gözlemlenmiştir. Ayrıca, benzetim ortamında gerçekçi bir beceriyi örnek alınarak yapılan deneyde önerilen modelin karşılaştırılan çok katmanlı, fakat gezinge çiftlerinin ortak kodlamalarını öğrenmeyen perseptronlardan referans gezingeye uzaklık ölçüsünde daha iyi performans



Şekil 6: Benzetim ortamında seçilen bir görevin (A) ve belirlenen ilişkili görevin (B) robot tarafından gerçekleştirilişi. Sonuçlar, verilen videoda gösterilmektedir<sup>1</sup>.

verdiği gözlemlenmiştir. Bu farkın karşılaştırılan modellere verilen kapasite avantajına rağmen oluşması, önerilen modelin ilişkili gezinge çiftlerini verimli bir şekilde öğrendiğini göstermektedir. Bu sonuç, birbirleriyle anlamsal bağlantısı olan robot becerilerinin önerilen model ile öğrenilmesinin ölçeklenirliğe katkı sağladığı ve beceri genellemesi başarısını artırdığını ortaya koymaktadır. Bunun yanı sıra, modelin sentetik gezinge çiftlerinde eğitim aralığı dışındaki performansının düşük kaldığı gözlemlenmiştir. Bu durum, bilinmeyen senaryolara genelleme performansını kısıtlamasıyla önerilen modelin temel sınırlamalarından biri olarak saptanmıştır. Gelecek çalışmalarda önerilen modelin gerçek robot ortamında performansı test edilerek modelin pratik uygulamalarda sağladığı verimlilik daha kapsamlı bir şekilde değerlendirilecektir.

#### BİLGİLENDİRME

Bu çalışma, AB tarafından finanse edilen INVERSE projesi (no. 101136067) tarafından desteklenmiştir.

#### KAYNAKLAR

- [1] A. I. Károly, P. Galambos, J. Kuti, and I. J. Rudas, "Deep learning in robotics: Survey on model structures and training strategies," *IEEE Transactions on SMC*, vol. 51, no. 1, pp. 266–279, 2021.
- [2] N. Widulle and O. Niggemann, "Using reverse reinforcement learning for assembly tasks," in *PRL Workshop Series - Bridging the Gap Between AI Planning and Reinforcement Learning*, 2023.
- [3] A. D. Edwards, L. Downs, and J. C. Davidson, "Forward-backward reinforcement learning," *arXiv preprint arXiv:1803.10227*, 2018.
- [4] S. Nair, M. Babaeizadeh, C. Finn, S. Levine, and V. Kumar, "Trass: Time reversal as self-supervision," in *ICRA 2020*. IEEE, 2020, pp. 115–121.
- [5] M. Y. Seker, A. Ahmetoglu, Y. Nagai, M. Asada, E. Oztop, and E. Ugur, "Imitation and mirror systems in robots through deep modality blending networks," *Neural Networks*, vol. 146, pp. 22–35, 2022.
- [6] H. Aktas, Y. Nagai, M. Asada, E. Oztop, and E. Ugur, "Correspondence learning between morphologically different robots via task demonstrations," *RA-L*, 2024.
- [7] M. Y. Seker, M. Imre, J. Piater, and E. Ugur, "Conditional neural movement primitives," in *RSS*, June 2019.
- [8] E. Todorov, T. Erez, and Y. Tassa, "Mujoco: A physics engine for model-based control," in *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2012, pp. 5026–5033.

<sup>1</sup><https://youtu.be/XtDCTe34hXQ>