

Tutucu Entegre Edilmiş Robotlar için Artırılmış Gerçeklik Tabanlı Makine Öğrenmesi Teknikleri Augmented Reality-Driven Machine Learning Techniques for Gripper-Integrated Robotics

Ramazan Onur Acar, M. Talha Başbüyük, Serdar Bahar, Emre Uğur, Yiğit Yıldırım
Department of Computer Engineering
Boğaziçi University
Istanbul, Turkey
{ramazan.acar, muhammet.basibuyuk, serdar.bahar}@std.bogazici.edu.tr
{emre.ugur, yigit.yildirim}@bogazici.edu.tr

Mustafa Doğa Doğan
Massachusetts Institute of Technology (MIT)
Cambridge, MA, USA
doga@mit.edu

Özetçe —Gösterimden Öğrenme (GÖ), robotlarda kontrol politikaları öğrenmek için sıkça kullanılan bir yöntemdir. Ancak GÖ’de kullanılan duyumotor gezinmelerin üretimi, robot kontrolünün zorluğu ve fiziksel temasın doğurduğu güvenlik sorunları gibi zorluklar barındırır. Bu makalede, kinestetik öğretim sırasında manuel müdahaleye gerek bırakmayan bir artırılmış gerçeklik (AG) sistemi sunulmaktadır. Yöntemimiz, önceki AG tabanlı GÖ sistemlerinden farklı olarak, hem kullanıcının elle çizdiği uzamsal gezegeyi hem de tutucunun anlık açık/kapalı durumunu kullanır. Sistem, gezege verilerini tutucu eylemleriyle senkronize ederek robotun alma-bırakma gibi görevlerdeki başarısını artırır. Ayrıca, sisteme entegre edilen derin öğrenme modülüyle, AG gösterimlerinden üretilen verilerle eğitilen modelin sepete top atma görevindeki başarısı gösterilmiştir. Derin öğrenme yöntemi, mevcut istatistiksel yaklaşımla karşılaştırılarak sayısal performans artışıyla değerlendirilmiştir.

Anahtar Kelimeler—Gösterimden Öğrenme, Artırılmış Gerçeklik, Derin Öğrenme

Abstract—Learning from Demonstration (LfD) is a widely used method for teaching control policies to robots. However, generating the sensorimotor trajectories used in LfD involves challenges such as the difficulty of robot control and safety concerns due to physical contact. This paper presents an augmented reality (AR) system that eliminates the need for manual intervention during kinesthetic teaching. Unlike previous AR-based LfD systems, our method uses both the user’s hand-drawn spatial trajectory and the real-time open/closed state of the gripper. By synchronizing trajectory data with gripper actions, the system improves the success of tasks like object pick-and-place. Additionally, a deep learning module integrated into the system demonstrates the effectiveness of a model trained on AR-generated data in a ball-in-basket task. The performance of the deep learning method is quantitatively evaluated by comparing it to a standard statistical approach.

Keywords—Learning from Demonstration, Augmented Reality, Deep Learning

I. GİRİŞ


Makine öğrenimi tekniklerinde yaşanan büyük gelişmeler, robotların görevleri yerine getirirken kullandıkları kontrol

politikalarının elde edilme yöntemlerini derinden etkilemiştir. Yakın geçmişte başvurulan yöntemler yerlerini derin öğrenme temelli, genelleşebilir ve uyarlanabilir metotlara bırakmıştır. Robotun kontrol politikasının bir uzman tarafından üretildiği Gösterimden Öğrenme (GÖ) yöntemleri de derin yapıların entegrasyonu ile bu süreçte daha kabiliyetli hale gelmiştir [1].

GÖ, robotların doğrudan programlama gerektirmek yerine insan gösterimlerini gözlemleyerek beceri kazanmalarını sağlar. Gösterimler elde edilirken kinestetik öğretim, teleoperasyon veya görsellerden izleme gibi yöntemlere başvurulur. Ancak pratikte, veri toplamanın yoğun efor içermesi, büyük veya hassas robotları kullanmanın tehlikesi ve öğrenilen görevlerin yeni ortamlara aktarılmasındaki zorluklar gibi çeşitli güçlükler ortaya çıkarmaktadır [2]. Ayrıca, gösterimlerdeki sapmalar ve robotun etkili bir şekilde genelleme yapamaması, GÖ yönteminin uygulanmasını sınırlayabilmektedir.

Bu zorlukları hafifletmek için, doğrudan insan-robot etkileşimini kolaylaştıran AG sistemleri tasarlanmıştır [3]–[5]. Meta Quest 3 gibi AG gözlüklerinde çalışan bu sistemler, kullanıcıların robotların hareketlerini gerçek zamanlı olarak görselleştirirken gösterimlerle onlara rehberlik etmelerini sağlamaktadır. Bu interaktif yaklaşım güvenliği ve uzamsal farkındalığı geliştirerek görev otomasyonunu kolaylaştırmaktadır. Aynı zamanda, kullanıcıların robotlarla daha sezgisel bir şekilde etkileşime girmesine olanak tanıyarak eğitim sürelerini kısaltmakta ve operatörlerin sistemleri daha verimli kullanmasını sağlamaktadır. Gerçek zamanlı geri bildirim mekanizmaları sayesinde, kullanıcılar hareketleri anında değerlendirebilmekte ve dikkat gerektiren noktaları anlık olarak tespit edebilmektedir.

Kullanıcı tecrübesi açısından değerlendirildiğinde, AG temelli robot kontrol yazılımlarının en büyük eksikliklerinden biri, kullanıcının sistem üzerinde yeterince kontrol hissetmemesidir [6]. Bunun sebebi, kullanıcının AG arayüzü aracılığıyla tutucu kontrolü sağlayamaması ve kullanıcıların nesneleri manipüle etmek için harici yöntemlere başvurmalarının gerekmesidir. Bu kısıtlar, sadece gösterimlerin akışını bozmakla kalmayıp ayrıca sistemin robot-nesne etkileşimlerini içeren görevler için kullanılabilirliğini de sınırlamaktadır. Çalışma-



Şekil 1: Sistem dört kısımdan oluşmaktadır. Kullanıcıdan genişletilmiş gerçeklik ortamında, Unity istemcisi kullanılarak alınan gezege ve koşul bilgileri sonrasında ROS sunucusunda işlenir ve gerçek robotta yürütülmeye hazır hale getirilir.

mızda bu sorunu çözmek için, tutucu kontrolünün doğrudan AG arayüzüne entegrasyonu sağlanmıştır. Kullanıcılar, kontrol birimi vasıtasıyla tutucuyu açıp kapatarak tutucunun kontrolünü sağlarken harici müdahaleye olan ihtiyaç ortadan kalkmıştır.

Robotik beceri öğretimi açısından değerlendirildiğinde, [5] çalışmasında sunulan AG sistemi, ProMP modelini kullanmaktadır [7]. ProMP, aynı beceriye ait birden fazla gezegeyi olasılık dağılımları kullanarak öğrenebilen bir istatistiksel modelleme yöntemidir. Öte yandan, bu model derin öğrenme temelli modellerle kıyaslandığında karmaşık görevlerdeki gezintileri uyarlamada yetersiz kalmaktadır.


Benzer bir çalışmada [8], Rauso ve arkadaşları hızlı başlangıç politikası oluşturmak için Davranış Kopyalama, politika güncellemelerini daha kararlı hale getirmek için Yakınsak Politika Optimizasyonu ve uzman davranışlarının taklit edilmesini teşvik etmek amacıyla Üretken Çekişmeli Taklit Öğrenimi yöntemlerini bir arada kullanmaktadır. Buna karşılık, bizim çalışmamız doğrudan artırılmış gerçeklik ortamında oluşturulan verilerle derin öğrenme tabanlı ve istatistiksel modellerin karşılaştırmalı değerlendirmesini sunmaktadır.

Çalışmamız sayesinde kaydedilebilen tutucu aparat kontrol sinyallerinin, daha önce geliştirilen yöntemdeki gezege bilgileriyle birleştirilmesi, robotik programlamada kullanılan makine öğrenmesi (MÖ) modellerinin değerlendirilmesinde yeni bir perspektif açmıştır. Makalemizin devamında, gezege bilgisinin yanı sıra tutucu aparat sinyallerinin de ara noktalarda kullanımının bahsedilen MÖ tekniklerindeki performansını irdelenmiş, CNMP [9] ve ProMP karşılaştırması yapılmış ve gelecekteki çalışmalarda insan-robot etkileşimi nezdinde yapılabilecek geliştirmelerden bahsedilmiştir.

Bahsedilen sorunları aşmak ve kullanıcıların robot kontrolündeki hakimiyetini artırmak üzere, önerdiğimiz yöntem aşağıda detaylandırılmıştır.

II. YÖNTEM

Önerdiğimiz yöntem, AG arayüzü kullanıcısının robot hakimiyetini artırarak görevlerdeki hata oranını düşürmeyi ve sistem güvenilirliğini artırmayı hedefler. Sistem, gezege bilgilerini tutmanın yanı sıra robotun tutucu aparatına ait kontrol sinyalini gezege bilgisinin ara nokta değerleriyle eşleştirir.



Şekil 2: Sol kontrol birimi düğmesi (solda) ve Genişletilmiş gerçeklik ortamında kullanıcı menüsü ve tutucu aparat bilgisi (sağ yukarıda ve aşağıda) gösterildiği gibidir.

Kullanıcının çizdiği her gezege için eş zamanlı olarak kullanıcıdan tutucu aparatın açık/kapalı durum bilgisi alınır. Bu bilgiye, kullanıcının tek eliyle gezegeyi çizdiği sırada diğer eliyle tutucu aparat durumunu bildirmesi sağlanarak ulaşılmaktadır. Önerilen sistemin şeması Şekil 1'de resmedilmiştir.

A. Unity

Daha önce geliştirilen sistem, kullanıcıya gezege bilgilerini toplamak ve eğitim yapmak için kullanımı rahat bir arayüz sunmuştur. Yöntemimizde de Unity kullanılmış olup, var olan kullanıcı menüsü genişletilmiş gerçeklik ortamına uygun şekilde taşınabilir olduğu düşünülmüş ve aparat durumunun gezege boyunca anlık bilgisi eklenmiştir. Ayrıca, modeller için örnek gezege ve tutucu aparat bilgilerinin toplanması ve model eğitiminde kullanıcı arayüzünde bir değişim yapılmayıp CNMP seçeneği eklenmiş ve akıcı bir kullanıcı deneyimi hedeflenmiştir. Gezege çizme sürecinde tutucu aparat kullanım düğmesi ve tutucu aparat durum bildirimi Şekil 2'deki gibidir.

B. ROS

ROS (Robot Operating System), robotun kontrolünü sağlayan temel yazılım platformudur. Bu çalışmada, UR10 robotu ve ROBOTIQ 3F tutucu aparatı üzerinde yürütülen GÖ yönteminde, kullanıcının Unity ve uygulama arayüzünü kullanarak oluşturduğu gezintilerin robotun ulaşabildiği bölgelerde olup olmadığını kontrol eder. Ayrıca, Unity istemcisi tarafından kendisine gönderilen gezege ara noktalarını ve ara noktalarla eşleşen tutucu aparat durumlarını kullanarak gerçek robotun ve tutucu aparatın kullanıcı tarafından gösterilen ve istenen şekilde yapılmasına olanak sağlar. Deneylerimizdeki modellerin eğitim ve örneklenme işlemleri de bu platformda gerçekleşir.

C. Meta Quest 3 - AG Gözlüğü

Yöntemimizde, daha önce geliştirilen sistemdeki kullanıma ek olarak, kullanıcıdan gezege çizimi boyunca tutucu aparatın kapalı olduğu anlar için sol kontrol biriminde bulunan düğmeye basması, kapalı kaldığı müddetçe düğmeye basılı tutması, ve tutucu aparatı açmak ve açık bırakmak için parmağını düğmeden kaldırması istenmiştir [5].

Şekil 2'de gösterildiği üzere, buradan elde edilen tutucu aparatın durum bilgisi, 1 (kapalı) ve 0 (açık) olarak başlıkta kaydedilmiş ve ROS sunucusuna gönderilmiştir. Daha sonra var olan benzetim robot ile genişletilmiş gerçeklikte yürütme sonrasında, çizilen gezintinin gerçek robot tarafından yürütülebilmesine bakarak işleme devam edilmiş ve gerçek robot ile yaptığı gezintide tutucu aparatın kullanıldığı görülmüştür.

D. Gerçek Robot ve Tutucu Aparat

Planlama tamamlandıktan sonra kullanıcı, herhangi bir sorunlu durum olup olmadığını kontrol etmek için sanal robotun planı gerçekleştirmişini izleyebilir. Her şey hazır olduğunda, kullanıcı gerçek robotta uygulama seçeneğini seçer ve robot gerçek ortamda gezingeyi takip ederken tutucunun durumu da önceden tanımlanmış bilgilere göre gerçek zamanlı olarak güncellenir. Robot doğrudan kullanıcının önünde olduğundan, fiziksel hareketleri ve tutucu işlemleri anında gözlemlenebilir. Sanal gösterim ve gerçek robot uygulaması arasındaki bu entegrasyon, kullanıcının girdisini doğrular ve pratik uygulamalarda sistemin güvenilirlik hissini pekiştirir.

Sistemin tutucu aparat kontrolü ile entegrasyonu sağlandıktan sonra, bu bilginin makine öğrenmesi modelleri üzerindeki etkisini incelemek amacıyla ProMP ve CNMP modelleri karşılaştırılmıştır.

E. ProMP - CNMP

ProMP robot hareketlerini olasılık dağılımları üzerinden modelleyerek gösterimlerden elde edilen gezinmelerin ortalama ve varyans bilgilerini çıkaran bir modeldir. CNMP ise, derin öğrenme temelli yapısı ile duyumotor verilerinden koşullu bağımlılıkları öğrenip, karmaşık hareket gezinmelerini bağlama göre uyarlayabilir; bu, çevrimiçi adaptasyon ile anlık verilere dayalı güncellemelere olanak tanır. Ancak bu sebeple CNMP, daha fazla veri ve hesaplama gücü gerektiren bir modeldir. ProMP modeli arayüz içinde saniyeler içinde eğitilebilirken, CNMP modelinin eğitimi daha uzun sürmektedir.


Önerilen yöntemde, tutucu aparat bilgisi de eklenerek her iki modelle gezing e eğitimi gerçekleştirilip daha sonra bu modellerle gerçek robot üzerinde gezing e yürütmesi yapılır. Böylece, tutucu aparat sinyallerinin gezing e bilgisine eklenmesinin CNMP ve ProMP modelleri üzerindeki etkisi gözlemlenir.

III. DENEYLER

A. Tutucu Kullanılan Başarılı bir Gezing e

İlk deneyimizde robot, sabit duran bir topu tutmak ve kullanıcı tarafından çizilen bir gezingeyi takip ederek bir sepetin içine bırakmakla görevlendirilmiştir. Mevcut sistemde tutucunun kontrolü, sistemin ROS tarafını çalıştıran bilgisayarla sınırlıydı ve burada bir operatör tarafından yakalama ve bırakma eylemleri için gereken açma ve kapama sinyallerinin manuel olarak, gezing e yörüngesinden bağımsız olarak gönderildiği bir sistemdi. Bu manuel müdahale, görevin akışını bozarak daha kullanışsız ve verimsiz bir çalışmaya neden olmaktaydı.

Buna karşın, yeni sistem kullanıcıların gösterim sırasında tutucunun açık/kapalı olma durumunu doğrudan kontrol etmesini sağlamaktadır. Kullanıcının bir gezing e çizmesine izin verilir - başlangıçta elini topa doğru yaklaştırır, ardından topu sabitlemek için kapalı bir tutucu durumuna geçer ve son olarak robotu sepetin üzerine ulaşana kadar gezingeyi devam ettirir. Burada tutucu aparat topu serbest bırakmak için yeniden açılır. Doğrudan tutucu aparat kontrolünün gezing e çizimi ile entegre edilmesi, bilişsel yükü ve olası hataları azaltarak daha hassas bir şekilde görevlerin uygulanmasını sağlar. Bu deney, tutucu aparat ve gezing e gösteriminden öğrenmenin mümkün olduğunu göstermeyi amaçlamıştır. Deney, Şekil 3'te belirtilen gezing e ve tutucu aparat bilgisi ile gerçekleştirilmiştir.



Şekil 3: AG ortamında çizilen gezing e ve tutucu aparat bilgisinin gerçek (gri, hareket halinde) ve benzetim (lacivert, durağan) robotta yürütülmesi gösterilmiştir. Benzetim robot hareketini tamamlamış bir şekilde durmaktadır.

B. ProMP ve CNMP'de Tutucu Entegre Edilmiş Genellenabilirlik Karşılaştırması

Bu deneyde tutucu kullanımını entegre ettiğimiz sistemimiz içerisinde iki MÖ modeli kullanıldı ve bu modellerin ara değer bulma yetenekleri karşılaştırıldı. Deney, bir topun tutucu tarafından kaldırılıp hedef gösterilen başka bir lokasyona topun bırakılması üzerinden işledi.


ProMP ve CNMP modelleri, aynı başlangıç noktasına sahip ancak dört farklı bitiş noktasına yönelen, her biri sekizer adet olmak üzere toplam 32 farklı gezing e gösterimiyle eğitildi. Bu dört farklı bitiş noktası, bir kenarı 23 cm olan bir karenin köşe noktalarından seçildi. Gezingeler, kullanıcı tarafından başlangıç ile bitiş noktası arasında Meta Quest 3 AG gözlüğü yardımıyla elle çizildi. ProMP modelinin eğitimi için 20 temel fonksiyon kullanıldı. CNMP modelinin eğitimi için ise sırasıyla 128, 256, 128 nöron içeren 3 saklı kodlayıcı ve çözücü katmanı ile 1.000.000 epok kullanılmıştır.

Test için modellerin eğitildiği dört bitiş noktasını merkez alan, 4 cm kenarlı karelerin çevresinde, 2 cm aralıklarla, her bir bitiş noktasının etrafında dört tane olmak üzere toplamda 32 nokta seçilip bu noktalar ve top pozisyonu, modellere koşul pozisyonları olarak verildi ve tutucu açıklık/kapalılık bilgisi içeren zamana bağlı gezinmeler üretilirdi. Üretilen gezinmeler, gerçek robot ve tutucu aparat tarafından uygulandıktan sonra, topun bırakıldığı nokta ile önceden hedef olarak belirlenen nokta arasındaki mesafe ölçüldü. Bu ölçüm, modelin başarısını değerlendirmek için belirlenen ana kriter olarak kullanıldı. Deney ortamı Şekil 4'te gösterildiği gibi oluşturulmuştur.

Deneyde ProMP modeli 32 testte ortalama 0.1753 metre



Şekil 4: Deneyde başlangıç noktasındaki top, topun atılması hedeflenen 32 nokta ve çarpı ile gösterilen, modellerin eğitildiği hedefler bu konumdadır.



Şekil 5: 32 farklı deney noktası ve sonuçların ortalama değerlerden farkı gösterilmektedir.

mesafe hatası ve 0.0650 standart sapma değeri sergiledi. Buna karşın, CNMP modeli testlerde daha başarılı sonuçlar elde etti: Ortalama mesafe hatası 0.1100 metreye düşerken, standart sapma değeri 0.0601 olarak belirlendi. Bu sonuçlar, CNMP'nin tutucu entegre edilmiş bir yaklaşımda aradeğerleme bakımından ProMP'den daha iyi performans sergilediğini göstermektedir. Şekil 5'te her bir test konumunda ölçülen ProMP ve CNMP hata değerleri ve bunların karşılaştırılması gösterilmektedir. Bu deneylerde, topun bırakıldığı nokta ile hedef nokta arasındaki mesafe (metre cinsinden) hata olarak alınmıştır. Ayrıca deneylerin genel değerlendirmesi sunan ortalama ve standart sapma değerleri gösterilmektedir. Bu değerler, 32 test noktasına ilişkin hataların ortalamasını ve dağılımını özetlemektedir.

IV. SONUÇ

Yöntemimiz büyük veya hassas robotlarda kullanım zorluğunu düşürmeyi hedefleyen önceki sisteme tutucu aparat ve CNMP modelini ekleyerek kullanıcının robot hakimiyetini artırmayı ve GÖ sürecini iyileştirmeyi hedeflemiştir. Ayrıca, MÖ yöntemlerinden CNMP ve ProMP'nin tutucu aparat bilgisi de dahil edilmiş durumdaki performanslarını incelemiştir.

Sonuçlar, CNMP'nin tutucu aparatın durum sinyallerini gezege verileriyle ProMP'den daha başarılı genellediğini gösterdi. 32 testte ProMP, topu ortalamada hedef noktalardan daha uzağa bırakırken ve daha yüksek standart sapma sergilerken, CNMP derin öğrenme temelli yapısıyla üstün performans sundu. Yapılan t-testinde $t = 7.056$ ve $p = 6.347e-08$ ile modeller arasındaki fark istatistiksel olarak anlamlı bulundu.

Sonraki çalışmalarda, sistemin performansını ve kullanıcı deneyimini daha da geliştirmek ve farklı GÖ bilgisi toplanarak MÖ modelleri üzerindeki etkilerini ortaya çıkarmak adına aşağıdaki konular üzerinde çalışılması planlanmaktadır:

Sistemimizde kullanılan kontrol birimi yerine el açma,

kapama, kavrama gibi hareketlerin algılanmasını sağlayan çalışmalar [10] incelenerek, gezege çizmede kullanıcının gerçek hayattakine daha yakın bir GÖ sürecine dahil olması sağlanabilir ve elde edilen kullanıcının deneyimi metrikleri daha önce yapılan çalışmanın sonuçlarıyla ve model performanslarıyla karşılaştırılabilir [5]. Mevcut yöntem, el hareketlerini yalnızca görüş alanıyla sınırlı olarak algılayabilmekteyken; sunduğumuz yöntemle bu kısıtlama olmadan tutucu aparat kontrol edilebilir. Gelecekte, koldan geçen sinirsel sinyalleri algılayarak el ve parmak hareketlerini anlayabilen elektromiyografi bileklikleri [11] kullanılarak hem mevcut hem de sunduğumuz yöntemin kullanıcı deneyimini iyileştiren yönleri birleştirilebilir ve daha doğal bir GÖ süreci ortaya çıkar.

Son olarak, robot ve tutucu ile kullandığımız nesnelere karekod eklenerek Unity'de sanal bir nesne oluşturmak ve AG gözlüğünün nesnelerin derinliğini tespit etme yeteneğini kullanmak mümkündür. Bu görsel ve derinlik verileri, büyük dil modeli veya çoklu büyük dil modeli ile işlenerek robot ve tutucu aparatın görev bağlamını çözölmesi ve bu şekilde uygun robotik yürütmeleri otomatik olarak gerçekleştirmesi sağlanabilir. Böylece kullanıcı, gezege çizme veya tutucu aparatın durumunu manuel olarak kontrol etme gereksinimi duymadan, çeşitli görevleri robota uygulatabilir.

BİLGİLENDİRME

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

KAYNAKLAR

- [1] H. Ravichandar, A. S. Polydoros, S. Chernova, and A. Billard, "Recent advances in robot learning from demonstration," *Annual Review of Control, Robotics, and Autonomous Systems*, vol. 3, pp. 297–330, 2020.
- [2] R. Suzuki, A. Karim, T. Xia, H. Hedayati, and N. Marquardt, "Augmented reality and robotics: A survey and taxonomy for ar-enhanced human-robot interaction and robotic interfaces," in *CHI Conference on Human Factors in Computing Systems*. ACM, 2022.
- [3] Y. Cao, T. Wang, X. Qian, P. S. Rao, M. Wadhawan, K. Huo, and K. Ramani, "Ghostar: A time-space editor for embodied authoring of human-robot collaborative task with augmented reality," in *Proceedings of the 32nd Annual ACM Symposium on User Interface Software and Technology*, 2019, pp. 521–534.
- [4] C. P. Quintero, S. Li, M. K. Pan, W. P. Chan, H. M. Van der Loos, and E. Croft, "Robot programming through augmented trajectories in augmented reality," in *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE, 2018, pp. 1838–1844.
- [5] F. Dogangun, S. Bahar, Y. Yildirim, B. T. Temir, E. Ugur, and M. D. Dogan, "Rampa: Robotic augmented reality for machine programming by demonstration," *IEEE Robotics and Automation Letters*, 2025.
- [6] O. Escallada, N. Osa, G. Lasa, M. Mazmela, F. Doğangün, Y. Yildirim, S. Bahar, and E. Ugur, "Human attitudes in robotic path programming: A pilot study of user experience in manual and xr-controlled robotic arm manipulation," *Multimodal Technologies and Interaction*, vol. 9, no. 3, 2025.
- [7] A. Paraschos, C. Daniel, J. R. Peters, and G. Neumann, "Probabilistic movement primitives," *NIPS*, vol. 26, 2013.
- [8] G. Rauso, R. Caccavale, and A. Finzi, "Incremental learning of robotic manipulation tasks through virtual reality demonstrations," in *2024 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, 2024, pp. 5176–5181.
- [9] M. Y. Seker, M. Imre, J. H. Piater, and E. Ugur, "Conditional neural movement primitives," in *Robotics: Science and Systems*, vol. 10, 2019.
- [10] S. Chen, C. Wang, K. Nguyen, L. Fei-Fei, and C. K. Liu, "Arcap: Collecting high-quality human demonstrations for robot learning with augmented reality feedback," *arXiv preprint arXiv:2410.08464*, 2025.
- [11] J. Cao, Y. Liu, L. Han, and Z. Li, "Finger tracking using wrist-worn emg sensors," *IEEE Transactions on Mobile Computing*, vol. 23, no. 12, pp. 14 099–14 110, Dec. 2024.