



Nesne-Yönelimli eylem tahmini gelişimi için hesaplamalı model

Computational modeling of object-directed action prediction development

Serkan BUĞUR^{1*} , Emre UĞUR² 

^{1,2}Bilgisayar Mühendisliği Bölümü, Fen Bilimleri Enstitüsü, Boğaziçi Üniversitesi, İstanbul, Türkiye.
serkanbugur@gmail.com, emre.ugur@boun.edu.tr

Geliş Tarihi/Received: 20.08.2019
Kabul Tarihi/Accepted: 16.01.2020

Düzeltilme Tarihi/Revision: 05.12.2019

doi: 10.5505/pajes.2020.09334
Araştırma Makalesi/Research Article

Öz

Deneysel psikoloji alanındaki son çalışmalar, başkalarının eylem sonuçlarını tahmin edebilme yeteneğinin gelişimi ile aynı eylemi gerçekleştirebilecek motor becerilerin gelişimi arasında doğrudan bir bağlantı olduğunu göstermiştir. Bebekler doğum sonrası ilk yıl içerisinde çevreleriyle etkileşime geçerler ve bu etkileşimleri sonucu bazı beceriler ve yetenekler kazanırlar. Aynı zamanda bu süreç içerisinde çevrelerindeki başka insanlarla da etkileşime geçip başkalarının eylem amaçları hakkında fikir sahibi olurlar. Bu çalışma, masa üstü nesnelere yönelik kavrama ve itme eylemlerinin sonuç tahminlerinin gelişimsel sürecini inceleyebilmek adına hesaplamalı bir model önermektedir. Bu bağlamda belirli nesnelere doğru yürüngeler oluşturulmuş ve bir veri kümesinden alınan el resimlerinin de yardımıyla kavrama ve itme eylemlerinin hedefindeki nesnelere yürünge tahminiyle saptanmaya çalışılmıştır. Kavrama ve itme eylemlerine yönelik gelişimsel süreç dört evrede analiz edilmiştir. Sonuçlar, ortaya koyulan hesaplamalı modelin eylem tanınırlığı ile eylem sonuç tahmin yeteneği arasında doğrudan bir ilişki kurabildiğini ve kavrama eylemine ait tahmin yeteneğinin daha erken geliştiğini göstermektedir.

Anahtar kelimeler: Deneysel psikoloji, Gelişimsel eylem tahmini, Ayna nöron sistemi, Evrişimli sinir ağı, Uzun kısa vadeli hafıza ağı.

Abstract

Recent studies in experimental psychology revealed that a developmental correspondence exists between prediction of others' action goals and motor ability to produce the same actions. Babies interact with their environment within the first year after birth and as a result of these interactions they acquire some skills and abilities. At the same time, babies interact with other people around them and gain insight into the action goals of others. This study proposes a computational model in order to examine the developmental progression of predicting the outcome of the grasping and pushing actions on a tabletop environment. In this context, some reaching trajectories were formed towards certain objects and by combining these trajectories with the images taken from a dataset, the targeted objects, with the intention of grasping or pushing, were tried to be determined. The developmental progression for grasping and pushing actions was analyzed in four stages. The results show that the computational model can establish a direct relationship between the action recognition and the ability to predict the outcome of the actions. And the prediction ability of the grasping action was developed earlier.

Keywords: Experimental psychology, Developmental action prediction, Mirror neuron system, Convolutional neural network, Long short-term memory.

1 Giriş

Başkalarının davranışlarının amaçlarını anlayabilmek ve sonuçlarını tahmin edebilmek, insan etkileşimi için çok önemli bir rol oynamaktadır. Doğumdan 4-6 ay sonrasında itibaren bebekler başkalarının eylem sonuçlarını, dolayısıyla eylemlerin gerçekleştirilme amaçlarını, tahmin edebilmeye başlamaktadır [1],[2]. Genellikle eylemi gerçekleştiren kişi eylem sırasında herhangi bir açıklama yapmaz ve eylemi hızlı bir şekilde gerçekleştirir. Bu durumda bile bebekler hızlı ve yüksek doğrulukla başkalarının eylemlerinin sonuçlarını tahmin edebilmektedir. Bebekler çevreyi nasıl algılar ve başkalarının gözlemlenen eylemleriyle hedefleri arasında nasıl bir ilişki kurarlar? Başkalarının eylemlerinin amacını anlayabilmek adına gerekli yetenekler nelerdir? Bu çalışmada, bu soruların ışığında, masa üstü nesnelere üzerinde başkalarının gerçekleştirdiği itme ve kavrama gibi manipülasyon eylemlerinin sonuçlarının ve amaçlarının gelişimsel tahmini için hesaplamalı bir model önerilmektedir.

Calligore ve Baldassarre tarafından yapılan ayrıntılı araştırmada [3], bir nesneye ulaşma ve kavrama gelişimi için gerekli olan altı önemli hesaplama bileşeni tanımlanmıştır: Ekolojik aktif görüş, motor becerilerinin keşfi ve birbiriyile ilişkilendirme süreci, deneme-yanılma yoluyla öğrenme,

hiyerarşik kontrol mimarileri, şekillenme (embodiment) ve nihayet içsel motivasyon. İçsel motivasyon, bebeklerin birikimli ve gelişimsel öğrenmelerini adaptif bir şekilde iyileştirerek, onlara geniş bir beceri koleksiyonu kazandırır. İçsel motivasyon Ryan ve Deci tarafından [4] "bir insanın yeteneklerini ve kabiliyetlerini geliştirebilmesi ve yenilerini öğrenebilmesi adına insan doğasından gelen eğilimlerle çevresindeki yeniliklere ve zorluklara yönelmesi" olarak tanımlanmaktadır. İçsel motivasyon insanlarda öğrenmeyi teşvik eden bir mekanizma olduğu için, yapay zeka alanındaki araştırmacılar öğrenme için harici sinyallerin yanında alternatif olarak içsel motivasyonu da kullanmaktadır.

Kraft ve diğ. [5] ise bebeklerin ulaşma ve kavrama yeteneklerinin gelişimini açıklayabilmek için çoklu-modsal bilginin nöro-hesaplama modeliyle işlenmesi gerektiğini vurgulamışlardır. Kortikal hafızanın, duyu-motor uzayının keşfi sırasında ortaya çıkan vücut sinyallerinden oluşturulabilecek, ulaşılabilir bir bölge haritası olarak düzenlenebileceğini ifade etmişlerdir. Bu vücut sinyalleri arasında omuz ve el bileği arasındaki eklem konfigürasyonları, elden alınan dokunsal ve gözden alınan görüş geri bildirimleri ve son olarak nesneye dokununca çıkan ses sayılabilir. Bahsedilen bu öğrenme mekanizmaları, "kavrama sevinci" (joy of grasping) gibi harici

*Yazışılan yazar/Corresponding author

ödüllerle yönlendirilen takviyeli öğrenme mekanizmaları kullanılarak hızlandırılabilir [6].

Nörofizyolojik veriler, insanların kendi eylem sonuçlarını (yörünge tahmini ve hareket kontrolü) içsel ileri modeller (internal forward models) kullanarak monitör ettiklerini göstermiştir [7]. Bu sayede tahmin edilen ve gözlenen eylem sonuçları arasındaki hata hesaplanabilir ve öngörülü hata azaltma (predictive error minimization) yöntemiyle eylemi gerçekleştirebilecek motor becerileri geliştirilmiş olur [8],[9]. Buna ek olarak Sommerville ve diğ. [10], bir kişinin başkalarının eylemlerinin hedeflerini anlayabilmesi için, o eylemi gerçekleştirebilecek motor becerilerinin yeterince gelişmiş olması gerektiğini ifade etmişlerdir. Daum ve diğ. [11], düzenledikleri deneyde altı aydan büyük bebeklerin, başkalarının nesne hedefli eylemlerinin el yörüngelerini hareket tamamlanmadan tahmin edebildiklerini göstermişlerdir. Çünkü altı aydan büyük bebeklerin motor becerileri belirli nesnelere kavrayabilecek kadar gelişmiş durumdadır.

Rajmohan ve Mohandas [12], başkalarının eylemlerinin, ayna nöron sistemi (ANS) aracılığıyla doğrudan bir eşleştirme işlemi sonucu anlaşıldığını belirtmektedirler. Bir eylemi gerçekleştirirken ateşlenen nöronların, aynı eylemin başkaları tarafından gerçekleştirildiğini gözlemlerken de ateşlendiği ve bu nöronların ANS'nin temel yapıtaşları olduğu kanıtlanmıştır. Beyinde bulunan F5c bölgesindeki motor nöronların büyük bir yüzdesi ayna özelliğine sahiptir. Gallese ve diğ. [13], maymunlar üzerinde yaptıkları deneyde bu bölgedeki nöronların maymun belirli bir hedefe yönelik kavrama eylemi gerçekleştirdiğinde ve maymun aynı motor hareketini gördüğünde ateşlendiğini göstermişlerdir. Buna ek olarak, eylemi gerçekleştiren elin oryantasyonu, yörüngesi ve kinematığı, hedef nesnenin oryantasyonu, pozisyonu, şekli değişse bile ayna nöronlar ateşlenir ve böylelikle başkalarının eylem sonuçlarıyla ilgili ilişki kurulabilir [14].

Kanakogi ve diğ. [1], eylem üretimi ve aynı eylem başkaları tarafından gerçekleştirildiği durumda eylem hedefinin anlaşılabilmesi arasındaki bağlantıyı gösterebilmek adına bir deney yapmışlardır. Deneyde farklı yaş gruplarından bebeklere bir deneycinin masa üzerindeki belirli nesnelere uzanarak bu nesnelere etkileşime geçmesi izletilmiştir. Deney düzeneği 3 farklı eylem içerir: (i) Deneyci kavrayan el duruşu ile bir nesneye uzanır ve nesneyi kavrar. (GH - hedefe yönelik eylem), (ii) Deneyci iten el duruşu ile bir nesneye uzanır ve nesneyi hafifçe iter. (BH - hedefe yönelik olmayan eylem). (iii) Deneyci nesneye ulaşmak ve kavramak için mekanik bir pençe kullanır. (MC - alet kullanımı aracılığıyla hedefe yönelik eylem) Deney süresince bebeklerin nereye baktıkları kaydedilmiştir. Deney sonuçları incelendiğinde, BH ve MC eylemleri gerçekleştirildiği durumlarda, bebeklerin eylem hedefleri hakkında bir tahmin yapamadıkları görülmüştür. Fakat 6 aydan büyük bebeklerin GH eylemlerinin hedeflerini tahmin edebildiği saptanmış ve henüz eylem tamamlanmadan, bakışlarının hedef nesneye odaklandığı tespit edilmiştir. Çünkü bebeklerin tek elle kavrama motor becerileri doğumdan sonraki ilk 6 aydan itibaren gelişmeye başlar. Bunun yanında, bebeklerin itme veya cansız bir nesne yardımıyla kavrama eylemleri ile ilgili motor becerileri henüz gelişmeye başlamamıştır.

Sinirbilim çalışmaları, başkaları tarafından gerçekleştirilen bir eylemin sonuçlarını tahmin ederken ve aynı eylemi üretirken aynı sinirsel mimarinin kullanıldığını göstermiştir [12],[13]. Ama bu mimarinin nasıl geliştiği tam olarak bilinmemektedir.

Copete ve diğ. [15], bu mimarinin eşzamanlı bir şekilde nasıl geliştiğini gösterebilmek adına hesaplamalı bir model önermektedirler. Bu modelde farklı motor sinyallerinin kullanılması ile bir robotun, eylem üretimi ve eylem hedeflerinin tahmini arasındaki bağlantıyı daha iyi kurabildiğini göstermişlerdir.

Elin, hedef nesneye nasıl yaklaştığı, nesneye ulaşırken çizdiği yörünge, bebeklerin dikkatlerini eyleme çevirmesinde önemli bir rol oynar. Hogan ve diğ. [16], insanların ellerini hedef nesnelere götürürken ivme değişim oranını kullandıklarını fark etmişlerdir. Başlangıç ve bitiş noktaları arasında el genellikle düz bir yörünge izler, başlangıçtan hareketin ortasına kadar hızlanır, ortasından sonuna kadar ise yavaşlar.

Hareketin yörüngesinin yanı sıra doğumdan sonraki ilk yıl içerisinde bebekler başkalarının el duruşlarını da eylem sonuçlarıyla ilişkilendirmeye başlarlar. [17],[18] düzenledikleri deneylerle, bebeklerin kavrayan el duruşu ile başlayan eylemlerde hedef nesneye doğru tahmin edici bakışlar yaptıklarını, oysa iten el veya kutu el duruşları ile başlayan eylemlerde tahmin edici bakışlar gözlemlenmediğini göstermişlerdir. Burada dikkat edilmesi gereken nokta hareketin belirli bir amaç doğrultusunda yapıp yapılmadığıdır. Bebekler kavrama eylemi temelleriyle eylem sonuçları arasındaki bağlantıyı kurabildikleri için bu eylem sonuçlarını tahmin etmektedirler. Fakat itme eylemine dair bağlantı henüz kurulmadığı için eylem sonuçları hakkında bir fikirleri yoktur ve bu durumda eylem sonuçlarını tahmin etmeleri beklenemez.

İnsanlar ve hayvanlar üzerinde yapılan sinirbilim çalışmaları, eylem bağlamının gelecekteki eylem tahminini mümkün kılan beş geniş kategoriden oluştuğunu göstermiştir: eylemi gerçekleştiren deneyci, gözlemci, çevre, hedef nesne ve nesneye yaklaşırken elin çizdiği yörünge [2]. Bu çalışmada gözlemci, eylemi gerçekleştiren deneyciyi izleyen ve çevredeki değişimlere duyarlı bir etmene tekabül etmektedir.

Bu çalışma, başkalarının masa üstü nesnelere üzerinde yaptıkları kavrama veya itme eylemlerinin gelişimsel tahmin sürecini modelleyebilmeyi ve [1]'in deney sonuçları ile önerilen hesaplamalı model arasındaki paralellikleri gösterebilmeyi amaçlamaktadır. Önerilen hesaplamalı model, deneysel psikoloji açısından ele alınmış olup sinirbilim açısından değerlendirilmemiştir. [1]'in yürüttüğü deneyde gerçek bebek denekler kullanılmış ve araştırılan hipotezlere yönelik analizler yapılmış, sonuçlar alınmıştır. Bu çalışmada, [1]'in hipotezleri gözden geçirilmiş ve alınan sonuçlar önerilen hesaplamalı modelle tekrarlanmıştır. Dolayısıyla, önerilen hesaplamalı model, [1]'in mevcut hipotezlerinin yanı sıra, yeni hipotezlerin ortaya atılıp denenmesine olanak sağlayacaktır.

Bölüm 2'de deney düzeneğinden ve önerilen hesaplamalı modelde kullanılan yöntemlerden bahsedilirken, Bölüm 3'te sonuçlar verilmekte ve son olarak Bölüm 4'te ise [1]'in deney düzeneğiyle kurulan bağlantı ve önerilen hesaplamalı modelin nasıl geliştirilebileceği tartışılmaktadır.

2 Yöntem

Bu çalışmada, başkalarının masa üstü nesnelere üzerindeki kavrama veya itme eylem sonuçlarının gelişimsel bir çerçevede incelenbilmesine olanak veren hesaplamalı bir model oluşturulmuştur. Hedef nesnelere ulaşırken elin çizdiği yörüngenin her iki eylem türü için de benzer olmasına rağmen [19],[20] bebekler, başkalarının kavrama ve itme eylemlerini henüz el nesneye ulaşmadan birbirinden ayırt etmeyi

başarılar [1],[17]. Bu ayrımı yapabilmelerini sağlayan faktörlerden biri el duruşudur. [1]'in deney sonuçları, başkalarının eylem sonuç tahmin başarılarıyla eylemi gerçekleştirebilecek motor becerilerin gelişimi arasında doğru orantı olduğunu ve bebeklerin kavrama eylemi sonuçlarını, gelişimsel süreçlerinin daha erken safhalarında tahmin etmeye başladıklarını göstermiştir. Buna ek olarak, bebeklerin herhangi bir eyleme yönelik motor becerileri o eylemi gerçekleştirmeyi ne kadar denedikleriyle doğrudan ilişkilidir [21].

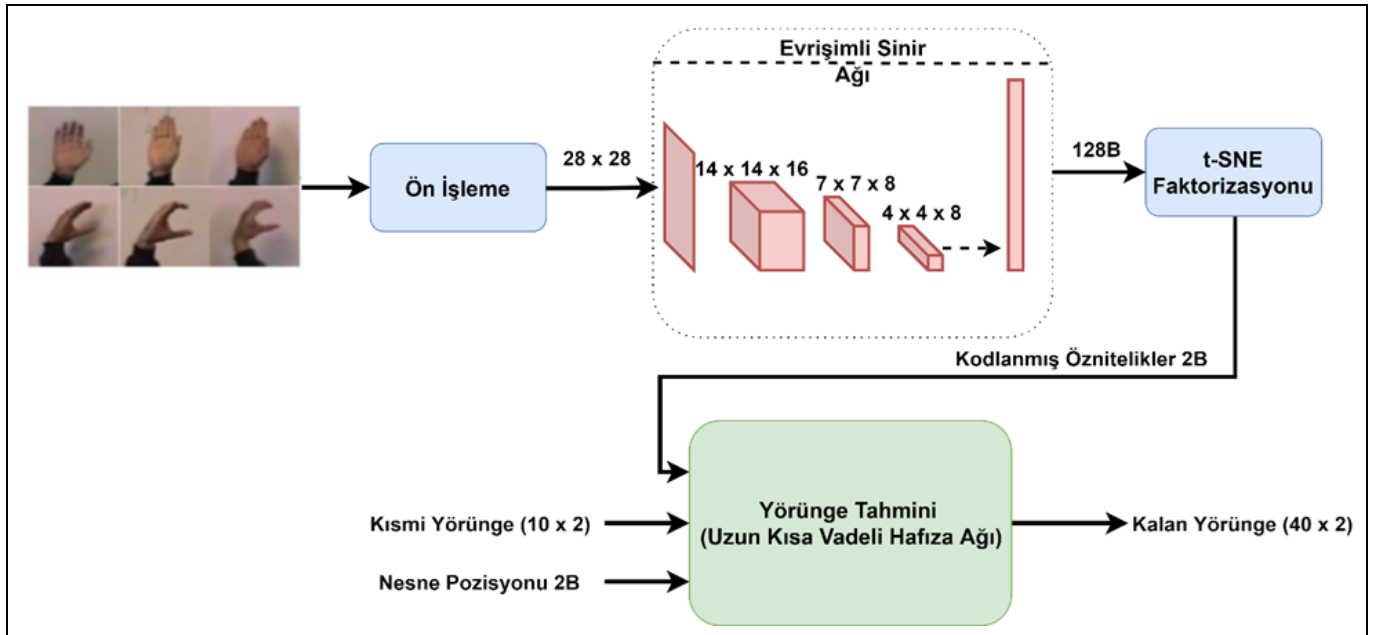
Başarılı bir kavrama evresi sonucunda elin ve hedef nesnenin son pozisyonları birbirine yakın olacakken, itme eylemi özelinde, kullanılan nesnelere fiziksel özelliklerinden ötürü, elin ve hedef nesnenin eylem sırasında izlediği yörünge, sonuç olarak da son pozisyonları birbirinden uzak olabilmektedir. Dolayısıyla kavrama eylemine yönelik sonuç tahmini itme eylemine kıyasla daha kolay yapılabilmektedir [22]. [1]'in gerçekleştirdiği deneyde bebek denekler yaşlarına göre dört farklı gruba ayrılmıştır ve eylem sonuç tahminleri bu dört farklı grup üzerinden verilmiştir. Bu deney ve deney sonuçlarıyla tutarlı olabilmek adına, bu çalışmada eylem tahmin sonuçlarını gerçekleştirecek etmenin gelişimsel süreci dört evreye ayrılmıştır. Her evrede etmen çevresiyle etkileşime geçer, kavrama ve itme eylemleri gerçekleştirir. Bu eylemler sonucu, etmenin sonraki evrede eylem tahmin sonuçlarındaki gelişim monitör edilmek istenmiştir.

Deney düzeneği, 3 boyutlu Bullet fizik motoru [23] kullanan VREP [24] benzetim ortamında oluşturulan bir masadan, masa üzerinde farklı pozisyonlara yerleştirilebilen bir nesnenin ve

bu nesnelere geçen yörüngelerden oluşmaktadır. Masa (50x100 cm) üzerinde ve farklı pozisyonlarda konumlanmış nesnelere yönelik birçok yörünge üretilmektedir. Üretilen yörüngeler elin eylem sırasında izlediği pozisyonların birleştirilmesi sonucu elde edilmektedir. Sebastian Marcel [25] tarafından oluşturulmuş veri kümesinden ise kavrama ve itme el duruşlarına ait fotoğraflar alınmaktadır. Bu fotoğraflar kullanılarak bir otokodlayıcı eğitilmektedir, otokodlayıcıdan çıkan gizli uzay (latent space) öznelikleri ise t-SNE (t-Distributed Stochastic Neighbor Embedding) faktörizasyonundan geçirilmekte ve herhangi bir fotoğraftan gelen öznelik boyutu 2'ye düşürülmektedir. Sonrasında kavrama ve itme eylemlerinin hedef yörüngelerinin tahmin edilebilmesi için eyleme özel Uzun Kısa Vadeli Hafıza Ağları (LSTM) eğitilmekte ve her evre için bu modellerin çevresinden edineceği düşünülen deneyimlerle güncellenmektedir. Yörünge tahmini doğruluğu, tahmin edilen yörüngenin son noktasının hedef nesneye olan uzaklığıyla ölçülmektedir. Şekil 1 genel model mimarisini gösterir. Aşağıdaki alt başlıklarda, modelin her modülünün detayları sunulmaktadır.

2.1 Yörünge üretimi

Her yörünge 50 tane 2 boyutlu (x, y) pozisyon çiftinden oluşturulmuştur. Oluşturulan yörüngelerin başlangıç ve bitiş pozisyonlarının x değerleri (0,0.5) arasında olacak şekilde, tekbüçümlü (uniform) dağılım izlenerek seçilmiştir. Sonrasında seçilen başlangıç ve bitiş noktaları arası eşit uzaklıkta olacak şekilde 50 tane x pozisyonu oluşturulmuştur.



Şekil 1. Genel model mimarisini. [3]'den alınan fotoğraflar ön işlemden geçerek boyutları 28 x 28'e indirgenir. Sonrasında evrişimsel bir sinir ağı ve t-SNE faktörizasyonu fotoğraftan gelen öznelikleri sırasıyla 128 ve 2 boyuta düşürür. Bu özneliklerle kısmi yörünge ve nesne pozisyonu birleştirilerek yörünge tahmin modülü eğitilir.

Figure 1. General model architecture. Images taken from [3] are pre-processed and their dimensions are reduced to 28 x 28. After that a convolutional neural network and t-SNE factorization extract features from the image to 128 and 2 dimensions, respectively. The trajectory prediction model is trained by combining partial trajectory points and object position features.

Yörüngedeki x pozisyonlarına tekbül eden y pozisyonları ise Denklem 1'deki formül izlenerek oluşturulmuştur. Denklemde yer alan a, b, c parametreleri belirlenirken normal Gaussian dağılımı kullanılmıştır ve bu şekilde 5000 tane yörünge oluşturulmuştur. Oluşturulan yörüngelerin bir kısmı yörünge tahmin modüllerinin eğitimi, bir kısmı ise test sırasında kullanılmıştır.

$$ax^2 + bx + c \quad (1)$$

2.2 Otokodlayıcı

[1],[17] düzenledikleri deneylerde, bebeklerin yalnızca deneyci kavrama eylemi gerçekleştirirken hedef nesneye tahmin edici bakışlar yaptıklarını göstermişlerdir. Bu durum bebeklerin, deneyci henüz eylemine başlamadan önceki el duruşuna dikkat ettiklerini gösterir. Kavrayan el ile gerçekleştirilen eylemlerde başarılı tahminler yapılırken iten el ile gerçekleştirilen eylemlerde başarılı tahminler gözlemlenmemiştir.

Bebeklerin bu yeteneklerini kopyalayabilmek adına bir otokodlayıcı (autoencoder) eğitilmiştir. Otokodlayıcı, çok boyutlu veriyi gizli uzay katmanında sıkıştırarak, sonra da bu sıkıştırılmış gizli uzay katmanından veriyi yeniden oluşturabilmek adına kullanılan bir gözetimsiz yapay sinir ağı çeşididir [26]. Otokodlayıcılar ilk olarak 1986'da Hinton ve diğ. [27] tarafından "öğretmen olmadan geri yayılım" (backpropagation without a teacher) sorununu ele almak için, girdi verilerini öğretmen olarak kullanma prensibiyle, ortaya atılmıştır. Otokodlayıcıların en önemli özellikleri çok boyutlu resimlerden az boyutlu öznitelikler çıkartabilmesi ve bunu yaparken resimlerdeki gürültüyü de temizleyebilmesidir. Birçok güncel çalışmada sistemin görsel algısı otokodlayıcılar tarafından kodlanmış ve gizli uzay katmanı görsel algı öznitelikleri olarak kullanılmıştır [28]-[30].

Bu çalışmada kullanılan otokodlayıcı yapısal olarak bir Evrişimli bir Sinir Ağı (Convolutional Neural Network) iken, [25] veri kümesinden alınan kavrayan el ve iten el fotoğrafları ile eğitilmiştir. Evrişimli Sinir Ağı, hayvan görsel korteksinin [31],[32] organizasyonundan ilham alan ve özniteliklerin birbirleri arasında kurulabilecek hiyerarşileri otomatik olarak ve uyarlamalı bir şekilde öğrenmek için tasarlanmış bir tür derin öğrenme modelidir [33]. CNN, tipik olarak üç tip katmandan (veya yapı taşlarından) oluşan matematiksel bir yapıdır: evrişim (convolution), havuzlama (pooling) ve tamamen birbirine bağlı (fully connected) katmanlar. İlk ikisi, öznitelik çıkarımını gerçekleştirirken, tamamen birbirine bağlı katmanlar çıkarılan özellikleri son çıktıya eşlemede kullanılır.

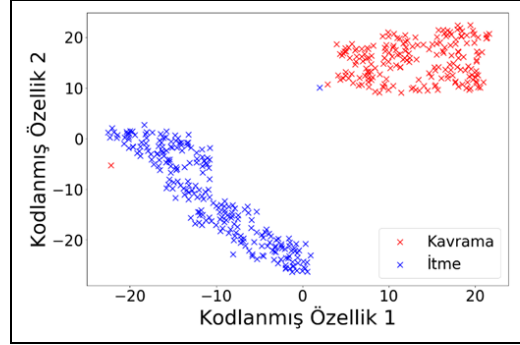
Kullanılan evrişimli sinir ağı Şekil 1'de gösterilmektedir. İlk olarak, fotoğraflar ön işlemden geçirilerek boyutları 28×28 e indirgenmiştir. Modelde üç evrişim katmanı kullanılırken, her katman sonrası maksimum örnekleme (Max Pool) kullanılmıştır. Her eylem tipi için 500 fotoğraf eğitim için kullanılırken 100 fotoğraf test için ayrılmıştır. Kavrama ve itme eylemlerine ait fotoğraf örnekleri Şekil 1'de gösterilmiştir.

2.3 t-SNE Faktörizasyonu

Otokodlayıcıdan çıkan gizli uzay öznitelikleri (128 boyutlu) t-SNE faktörizasyonundan geçirilerek fotoğrafları en iyi tanımlayabilecek 2 öznitelik bulundu. t-SNE faktörizasyonu, yüksek boyutlu verilerin daha iyi analiz edilebilmesini sağlayan bir boyut küçültme yöntemidir [34]. Avantajları arasında lineer olmayan veri özelinde de küçültme yapabilmemesi, her noktanın

etrafındaki komşularını olasılıksal bir dağılımla ifade edebilmesi verilebilir.

Şekil 2 her iki eylem için test fotoğraflarının indirgenmiş uzaydaki özniteliklerini göstermektedir. Kırmızı çarpılar kavrama eylemine ait el duruş fotoğraflarını temsil ederken mavi çarpılar itme eylemine ait el duruş fotoğraflarını temsil eder. Birkaç aykırı örnek dışında, iki kümenin çok iyi bir şekilde ayrıldığı gözlemlenmektedir. Dolayısıyla, bu iki öznitelik kullanılarak kavrama ve itme eylemleri birbirinden ayrılabilir.

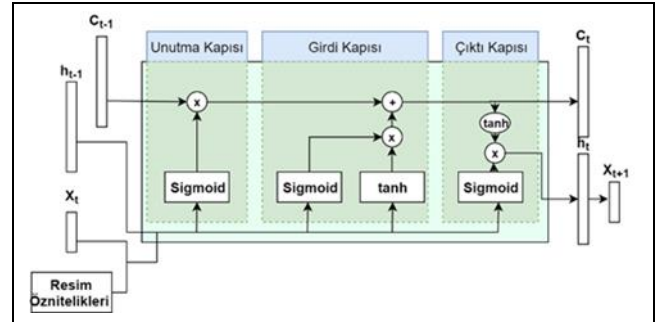


Şekil 2. Otokodlayıcı ve t-SNE faktörizasyonu sonucu oluşan kodlanmış öznitelik kümeleri.

Figure 2. Resulting feature space of autoencoder training and t-SNE factorization.

2.4 Uzun kısa vadeli hafıza ağları (Long Short-Term Memory) ile yörünge tahmini

LSTM verideki uzun vadeli bağımlılıkları öğrenebilen özel bir derin öğrenme modelidir [35]. Standart bir LSTM modelinde hücre adı verilen çeşitli hafıza blokları ve kapılar birbirlerine zincir şeklinde bağlanmıştır. Hücreler gerekli bilgiyi tutarken, kapılar ise hangi bilginin tutulması gerektiğine ve hücrelerin nasıl güncelleneceğine karar verirler [36]. Şekil 3 kullanılan LSTM ağının yapısını göstermektedir.



Şekil 3. Yörünge tahmin modeli. x_t : Mevcut pozisyon.
 h_t : Modelin kendine ve çıktı katmanına yolladığı mesaj.
 C_t : LSTM hafıza hücresi.

Figure 3. Trajectory prediction model. x_t : Current position.
 h_t : The message the model sends to itself and to the output layer. C_t : LSTM memory cell.

Öncelikle, mevcut pozisyon resim öznitelikleriyle birleştirilir. Sonrasında önceki çıktı değeri de hesaba katılarak sonraki yörünge pozisyonu tahmin edilir. LSTM ağı sürekli olarak bu yapıyı izleyerek ileriye dönük n adım için tahmin yapabilmeye özelliğine sahiptir. LSTM güncel çalışmalarda insan hareket yörüngelerini tahmin etmek için de kullanılmıştır [37].

Önerilen hesaplamalı modelde, yörünge tahmini modülü, herhangi bir yörünge başındaki 10 parçadan kalan parçaların tahmin edilebilmesine olanak vermektedir. Tahmin edilen son nokta hedef nesnenin tahmin edilen pozisyonuna tekabül ederken, kavrama ve itme eylemleri için 2 farklı LSTM modeli eğitilmektedir.

Otokodlayıcı ve t-SNE faktörizasyonundan gelen 2 öznitelik yörünge başındaki 10 parçanın x ve y değerlerinin arkasına eklenmektedir. Dolayısıyla modelin her girdisi 4 öznitelikten oluşmaktadır. Model eğitimi öncesinde her öznitelik standart normal dağılım kullanılarak normalize edilmiştir. Belirtilen öznitelikler modelin hem gerçekleştirilen eylemin hangisi olduğuna karar vermesine hem de yörünge tahmini yapabilesine olanak vermektedir.

Model bir sonraki zaman adımındaki yörünge başındaki x ve y değerlerini tahmin edecek şekilde eğitilmektedir. Eldeki yörüngelerin %80'i eğitim seti, geri kalan %20'si test seti olarak kullanılmıştır. Eğitim ve test setleri oranlarına karar verilirken çapraz doğrulama (cross-validation) kullanılmıştır. Model toplamda yirmi kere çalıştırılmış, her seferinde eğitim ve test setleri farklı verileri kapsayacak şekilde değiştirilmiştir.

Başkaları tarafından gerçekleştirilen kavrama ve itme eylemlerinin sonuçlarının tahmin edilebilmesinin süreç içerisindeki gelişimini gösterebilmek adına dört evre oluşturulmuştur. İlk evrede her iki eylem için de yörüngeler hedef nesneden aynı oranda sapmayla oluşturuldu. Bu sapma oranı, 2. ve 3. evrelerde kavrama eylemi için düşürülürken, itme eylemi için sabit tutuldu. 4. evrede her iki eylem için de sapma oranı önceki evrelerdeki orana kıyasla düşürüldü. Şekil 4'te 4 evre için de bu süreç anlatılmaya çalışılmıştır.


Mavi kesikli çizgiler itme eylemi için örnek bir yörüngeyi gösterirken kırmızı kesikli çizgiler kavrama eylemi için örnek yörüngeyi göstermektedir. Yeşil daireler ise her evrede eylemler için ne kadarlık bir sapma payının olduğunu gösterir. Nesne dairelerin tam ortasına yerleştirilmiştir. Fakat sapmadan dolayı oluşturduğumuz yörüngeler dairenin içinde herhangi bir yerde sonlanabilir. İlk evrede her eylem için 800 örneklem eğitim için, 200 örneklem test için kullanılmıştır. Diğer evreler sırasıyla eğitilmiş ve test sonuçları alınmıştır. Her evre için fazladan 800 örneklem eğitim için kullanılırken, 200 örneklem ise test için kullanılmıştır.

3 Sonuçlar

Şekil 5a, Kanakogi ve diğ. [1] deney sonuçlarından uyarlanmıştır. Şekilde siyah baklava şekiller kavrama eylemine (GH) ait tahmin sonuçlarını verirken, beyaz şekiller itme eylemine (BH) ait sonuçları vermektedir. Şekilde de görüldüğü gibi doğumdan sonraki 6 aydan itibaren bebekler, başkalarının kavrama eylemlerinin sonuçlarını tahmin etmeye başlamaktadır. Çünkü hedef nesneye eylem tamamlanmadan bakmaya başlamışlardır. Fakat itme eylemlerinin tahmini ancak 10 aydan itibaren gelişmeye başlar. Bu durumda bile, bebekler yalnızca eylemi takip edebilmişlerdir. Şekil 5b'de ise bu çalışmada önerilen hesaplamalı model sonuçları verilmektedir. Eylem tahminlerinin doğruluklarını ölçebilmek adına yörünge tahminlerinin ortalamada hedef nesneden ne kadar uzak kaldığına bakılmıştır.

Kırmızıçizgi kavrama eylemine ait tahmin sonuç hatalarını verirken mavi çizgi itme eylemine ait tahmin sonuç hatalarını verir. Model birbirinden bağımsız olacak şekilde toplamda yirmi kere çalıştırılmış, test verisi üzerinden alınan ortalama

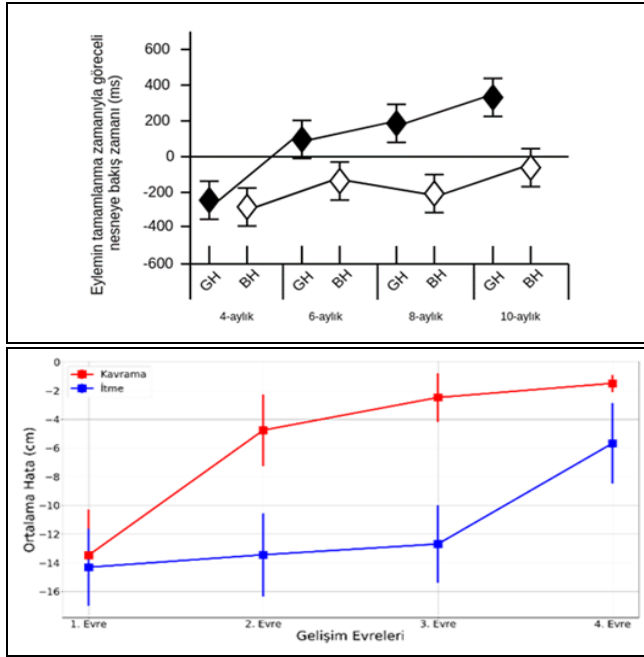
hatalar kare içerisinde gösterilmiş, standart sapma dikey çizgilerle belirtilmiştir.



Şekil 4. LSTM eğitim prosedürü. Soldan sağa her evre için kavrama ve itme eylemlerine ait örnek yörüngeler ve sapma oranları verilmektedir. Yörüngelerin etrafındaki yeşil daireler sapma oranlarını göstermektedir. Kırmızı daireler kavrama eylemlerine yönelik yörünge tahminini, mavi üçgenler ise itme eylemine yönelik yörünge tahminini vermektedir.

Figure 4. LSTM training procedure. From left to right, sample trajectories and deviation rates of grasp and push actions for each phase is given. The green circles around the trajectories show the deviation rates. Red circles correspond to the trajectory prediction for the grasp actions whereas blue triangles shows the same for the push actions.

Şekilde de görüldüğü gibi 1. evrede her iki eylem için yörünge tahmin hataları diğer evrelere göre yüksek ve birbirine yakındır. Kavrama eylemlerine ait tahmin sonuçlarının hataları 2. evreden itibaren gözle görülür bir şekilde azalmıştır. Fakat itme eylemlerine ait tahmin sonuçlarının hataları ancak 4. evreden itibaren azalmaya başlamıştır. Bu duruma sebep olarak yörünge tahmin modeli eğitimi sırasında, itme eylemlerindeki yörünge sapmasının daha büyük olması gösterilebilir. Şekil 5a ve 5b beraber incelendiğinde [1]'in deney sonuçlarının önerilen hesaplamalı model tarafından tekrarlandığı gözükmemektedir. Kavrama eylemi tahmin sonuçları itme eylemi tahmin sonuçlarına kıyasla her iki deneyde de daha erken düzelmeye başlamıştır.



Şekil 5. (a): [1]'den uyarlanan deney sonuçlarını göstermektedir. Siyah baklava şekiller kavrama eylemine (GH) ait tahmin sonuçlarını verirken, beyaz şekiller itme eylemine (BH) ait sonuçları vermektedir. Eylem tahmin doğruluğuna hedef nesneye bakış zamanlamasına göre karar verilir. (b): önerilen hesaplamalı modelin sonuçlarını göstermektedir. Kırmızı çizgi kavrama eylemine ait tahmin sonuç hatalarını verirken mavi çizgi itme eylemine ait tahmin sonuç hatalarını verir. Test verisi üzerinden alınan ortalama hatalar kare içerisinde gösterilmiş, standart sapma dikey çizgilerle belirtilmiştir.

Figure 5. (a): Shows the results adapted from [1]. Black diamonds correspond to the prediction results for the grasp action (GH) whereas white shapes correspond to the push action prediction results. Action prediction accuracy is correlated with the timing of the gaze towards the target object. (b): Shows the results of the proposed computational model. Red lines correspond to the prediction errors for the grasp action whereas blue lines correspond to the push action errors. The average errors from the test set are shown in squares, and the standard deviations are indicated by vertical lines.

Tablo 1'de yörünge tahmin modelinin doğruluk analizi yapılmıştır. Model yirmi kere çalıştırılmış ve her evre için ortalama hata ve standart sapma kaydedilmiştir. 4. evre sonunda model kavrama eylemine yönelik tahminleri 2 cm'den küçük bir hatayla yapabilmektedir. Gerçek dünyada kullanılan

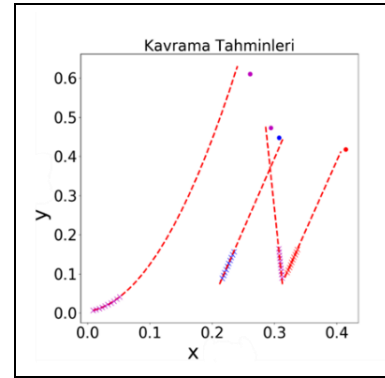
nesnelerin yarıçapları genellikle 2 cm'den büyüktür. Bu durumda, gerçek dünya nesnelere kullanıldığı durumda model kavrama eylemine yönelik tahminlerini yüksek başarı yüzdesiyle gerçekleştirebilecektir.

Tablo 1. Yörünge tahmini doğruluk analizi. Model yirmi kere çalıştırılmış, ortalama tahmin hatası ve standart sapma her evre için cm cinsinden gösterilmiştir.

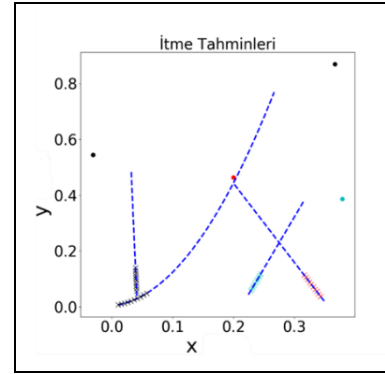
Table 1. Trajectory prediction accuracy analysis. For twenty independent runs, the average prediction error and the standard deviation for each phase is shown in cm.

	1. Evre		2. Evre		3. Evre		4. Evre	
	μ	σ	μ	σ	μ	σ	μ	σ
Kavrama	13.6	3.2	4.8	3.3	2.5	1.7	1.9	0.6
İtme	14.4	2.8	13.8	3.8	13.6	3.7	5.7	3.5

Kavrama ve itme eylemleri için örnek tahmin sonuçları Şekil 6a ve Şekil 6b'de sırasıyla verilmiştir.



(a): Kavrama tahmin sonuç örnekleri.



(b): İtme tahmin sonuç örnekleri.

Şekil 6: 4. evre sonrası eylem tahmin sonuçları. Kırmızı ve mavi kesikli çizgiler örnek yörüngelerdir. Yörüngelerin ilk 10 noktası farklı bir renkle işaretlenmiş, modelin tahminleri ise aynı renkte bir noktayla gösterilmiştir. (a): Kavrama eylemine ait yörüngelerin örnek tahmin sonuçlarını gösterirken, (b): İtme eylemine ait örnek tahminleri göstermektedir. x ve y eksenlerinde gösterilen değerler metre cinsindedir.

Figure 6: Action prediction results after the 4th phase. Red and blue dashed lines are sample trajectories. The initial 10 points of the sample trajectories marked with a color, and the model's estimates are shown by the same colored dot. (a): Shows the trajectory prediction results for the grasp action samples whereas (b): Shows the prediction results for the push action samples. The values shown on the axes are in meters.

Sonuçlar 4. evre eğitimi sonrasında sonuçları olup kırmızı ve mavi kesikli çizgiler örnek yörüngeleri temsil eder. Yörüngelerin ilk 10 noktası farklı bir renkle işaretlenmiş, modelin tahminleri ise aynı renk bir noktayla gösterilmiştir. Tahminler yörüngelerin ilk 10 noktaları kullanılarak yapılmış, bunların yanına otokodlayıcı ve t-SNE faktörizasyonundan gelen kodlanmış öznitelikler eklenmiştir. Kavrama eylemleri için kavrayan elden gelen öznitelikler kullanılırken itme eylemleri için iten elden gelen öznitelikler kullanılmıştır. Kavrama eylemine ait tahmin sonuçları yörüngelerin son pozisyonlarına, itme eylemine ait tahmin sonuçlarına kıyasla daha yakındır. Dolayısıyla, kavrama eylemine ait tahmin sonuçlarının itme eylemine göre daha başarılı olduğunu görülmektedir. Bu bağlamda Kanakogi ve diğ.ın [1] deney sonuçlarıyla bir paralellik göze çarpmaktadır. İki deney düzeneğinde de gelişimsel süreç dört parçaya ayrılmış ve kavrama eylemine ait tahmin sonuçlarının itme eylemine kıyasla daha erken gelişmeye başladığı gözlemlenmiştir.

4 Tartışmalar ve sonuç

Kanakogi ve diğ. [1] yaptıkları deneyde tahminlerin doğruluklarını ölçmek için bebeklerin hedef nesnelere bakış zamanlamasını kullanmışlardır. Bebeğin hedef nesneye ne kadar erken baktığı o eylemle ilgili tahmin yeteneğinin ne kadar gelişmiş olduğunu gösterir. Bu çalışmada bakış zamanlaması ile tahmin edilen yörüngenin son pozisyonunun bağlantılı olduğu varsayılmış, tahmin edilen yörüngenin son pozisyonunun hedef nesneye olan uzaklığı doğruluk metriği olarak kullanılmıştır. Uzaklık azaldıkça tahmin doğruluğunun arttığı düşünülebilir. Kavrama ve itme eylem sonuçları tahmin gelişimi dört evrede incelenmiştir. Bulunan sonuçların [1]'de yapılan deneyin sonuçlarıyla tutarlı olduğu gözlenmiştir. Kavrama eylemine yönelik tahmin gelişimi daha erken başlamıştır. Önerilen hesaplamalı modelde eylem sonuç tahminleri [1]'den farklı hesaplanmıştır. Buna karşın, sonuçlardaki paralellikler, eylem tahmininin her iki durumda da motor gelişimine bağlı olduğunu, motor gelişiminin ise deneyim miktarına bağlı olduğunu göstermektedir.

İleride eylem yörüngelerini elle oluşturmak yerine, etmenin zaman içerisinde çevresindeki nesnelere etkileşime geçtikten sonra yaptığı keşif sonrası elde edilen gerçek yörüngeler kullanılabilir. Keşif aşamasında ise etmen, farklı eylemleri öğrenebilmek adına içsel motivasyon prensibinden faydalanabilir. İçsel motivasyon dıştan gelen belirli bir ödül olmadan gerçekleştirilen davranıştır. Bebekler de keşif yaparken çoğu durumda dışardan belirli bir ödül almadan farklı faktörlerin etkisiyle hareket ederler. Bu faktörlere örnek olarak merak, ilgi, gurur, başarı verilebilir. Gerçek yörüngeler kullanıldığı takdirde evrelerde kullanılan örneklem sayısı da etmenin keşfi sırasında dendiği gerçek eylemlerden elde edilebilir. Sonuç olarak da gelişen motor becerilerle eylem sonuç tahmini arasında kurulan bağ daha kuvvetli olacaktır.

İçsel motivasyon kullanılan sistemlerde, etmenin çevresi ile etkileşimi sonucu gerçekleştirdiği eylemler ve eylem uzayı arasındaki bağlantıyı kurması beklenmektedir. Eylem uzayı bu açıdan büyük önem taşımaktadır çünkü yapılan eylemlerin hem keşif hem de keşif sonrası sınıflandırılmaları için eylem uzayı kullanılabilir. Oudeyer ve diğ. [38], ortaya koydukları aktif öğrenme modelini "Akıllı ve Adaptif Merak" (Intelligent Adaptive Curiosity-IAC) olarak isimlendirmişlerdir. IAC'de etmen eylem uzayını parçalara ayırır, bu parçalardaki öğrenme gelişimine bakar ve sonraki eylemin hangi parçadan örnekleneneğine karar verir. İçsel motivasyon sinyali olarak

eylem sonuçlarının ne kadar iyi tahmin edildiği kullanılırken, öğrenme gelişmesi ise parçalardaki eylem tahmin sonuçlarının ne hızda düzeldiğiyle ilgilidir. Buna benzer bir öğrenme mekanizması kurmak ve etmenin farklı şekilde sınıflandırılacak eylemler (kavrama, itme gibi) üzerinde keşif yapmasını, eylem uzayını parçalara bölerek öğrenme gelişimini hesaplamasını ve sonrasında aksiyon primitiflerinin öğrenilme sırasını incelemek ilerisi için uygulanabilir bir plan gibi gözükmektedir.

5 Discussions and results

Kanakogi et al. [1] used the timing of babies' gazes towards the target objects to measure the accuracy of the predictions in their experiment. How early the baby looks at the target object shows how advanced the prediction ability of the particular action. In this study, it is assumed that the end position of the predicted trajectory is related to gaze timing. Therefore, the distance of the end position of the predicted trajectory from the target object is used as the accuracy metric. It can be thought that the accuracy of the prediction increases as the distance decreases. The development of prediction of grasping and pushing actions was examined in four phases. It was observed that the results found were consistent with the results of the experiment in [1]. Prediction development for the action of grasping began earlier. In the proposed computational model, action result predictions were calculated differently than [1]. Nevertheless, the parallels in the results show that action prediction depends on motor development in both cases, and motor development depends on the amount of experience.

In the future, instead of manually creating action trajectories real trajectories obtained after the exploration of the agent by interacting with the surrounding objects can be used. In the exploration phase, the agent can benefit from the intrinsic motivation principle to learn different actions. Intrinsic motivation is the behavior performed without a specific reward from the outside world. Infants also act under the influence of different factors in most cases without receiving an explicit reward when exploring. Examples of these factors are curiosity, interest, pride, success. If real trajectories are going to be used, the number of samples used in the developmental phases can also be deducted from the real action executions obtained during the exploration of the agent. As a result, the link between motor skill development and action prediction development will be stronger.

In systems using intrinsic motivation, it is expected from an agent to establish the link between the actions performed by the interaction with the environment and the space of action. Action space is of great importance in this respect because action space can be used for both exploration and post-exploration classification of actions. Oudeyer et al. [38] named the active learning model they developed as "Intelligent and Adaptive Curiosity" (Intelligent Adaptive Curiosity-IAC). In IAC, the agent partitions the action space into regions, calculates the learning progress in these regions, and decides from which region the next action will be sampled. While the intrinsic motivation signal is used to estimate how well the action results are predicted, learning progress is concerned with how quickly the action prediction results in the regions improve. It seems to be a viable plan for the future to establish a learning mechanism like this, to explore on actions that can be classified differently (such as grasping, pushing), to calculate learning progress by partitioning the action space into regions, and then to analyze the developmental order of action primitives.

6 Kaynaklar

- [1] Kanakogi Y, Itakura S. "Developmental correspondence between action prediction and motor ability in early infancy". *Nature Communications*, 2(1), 1-6, 2011.
- [2] Robson SJ, Kuhlmeier VA. "Infants' understanding of object-directed action: An interdisciplinary synthesis". *Frontiers in Psychology*, 7, 1-14, 2016
- [3] Caligiore D, Baldassarre G. "The development of reaching and grasping: towards an integrated framework based on a critical review of computational and robotic models". *Reach-to-Grasp Behavior*, 319-348, Routledge, 2018.
- [4] Ryan RM, Deci EL. "Self-determination theory and the facilitation of intrinsic motivation, social development, and well-being". *American psychologist*, 55(1), 68, 2000."
- [5] Kraft D, Detry R. "Development of Object and Grasping Knowledge by Robot Exploration". *IEEE Transactions on Autonomous Mental Development*, 2(4), 368-383, 2011.
- [6] Oztop E, Bradley NS, Arbib MA. "Infant grasp learning: a computational model". *Experimental Brain Research*, 158(4), 480-503, 2004.
- [7] Kawato M. "Internal models for motor control and trajectory planning". *Current Opinion in Neurobiology*, 9(6), 718-727, 1999.
- [8] Schmidhuber J. "Learning factorial codes by predictability minimization". *Neural Computation*, 4(6), 863-879, 1992.
- [9] de Bruin L, Michael J. "Prediction error minimization as a framework for social cognition research". *Erkenntnis*, <https://doi.org/10.1007/s10670-018-0090-9>, 2018.
- [10] Sommerville JA, Woodward AL, Needham A. "Action experience alters 3-month-old infants' perception of others' actions". *Cognition*, 96(1), 1-11, 2005.
- [11] Daum MM, Prinz W, Aschersleben G. "Encoding the goal of an object-directed but uncompleted reaching action in 6-and 9-month-old infants". *Developmental Science*, 11(4), 607-619, 2008.
- [12] Rajmohan V, Mohandas E. "Mirror neuron system". *Indian journal of psychiatry*, 49(1), 66, 2007.
- [13] Gallese V, Fadiga L, Fogassi L, Rizzolatti G. "Action recognition in the premotor cortex". *Brain*, 119(2), 593-609, 1996.
- [14] Rizzolatti G, Fogas si L, Gallese V. "Neurophysiological mechanisms underlying the understanding and imitation of action". *Nature reviews neuroscience*, 2(9), 661-670, 2001.
- [15] Copete JL, Nagai Y, Asada M. "Motor development facilitates the prediction of others' actions through sensorimotor predictive learning". *Joint IEEE International Conference on Development and Learning and Epigenetic Robotics (ICDL-EpiRob)*. IEEE, Cergy-Pontoise, France, 19-22 September 2016.
- [16] Flash T, Hogan N. "The coordination of arm movements: an experimentally confirmed mathematical model". *Journal of neuroscience*, 5(7), 1688-1703, 1985.
- [17] Woodward AL. "Infants' ability to distinguish between purposeful and non-purposeful behaviors". *Infant Behavior and Development*, 22(2), 145-160, 1999.
- [18] Gredebäck G, Stasiewicz D, Falck-Ytter T, Hofsten CV, Rosander K. "Action type and goal type modulate goal-directed gaze shifts in 14-month-old infants". *Developmental psychology*, 45(4), 1190, 2009.
- [19] Hamlin J, Hallinan EV, Woodward AL. "Do as i do: 7-month-old infants selectively reproduce others' goals". *Developmental Science*, 11(4), 487-94, 2008.
- [20] Dogar MR, Srinivasa SS. "Push-grasping with dexterous hands: Mechanics and a method". *IEEE/RSJ International Conference on Intelligent Robots and Systems*, Taipei, Taiwan, 18-22 October 2010.
- [21] Natale L, Metta G, Sandini G. "A developmental approach to grasping". *Developmental robotics AAAI spring symposium*, California, USA, 21-23 March 2005.
- [22] Juett J, Kuipers Benjamin. "Learning and Acting in Peripersonal Space: Moving, Reaching, and Grasping". *Frontiers in Neurobotics*, 13, 4, 2019.
- [23] Coumans E. "Bullet physics simulation". *In ACM SIGGRAPH Courses*, 2015.
- [24] Rohmer E, Singh SP, Freese M. "V-REP: A versatile and scalable robot simulation framework". *In 2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*, Tokyo, Japan, 03-07 November 2013.
- [25] Marcel S, Bernier O. "Hand Posture Recognition in a Body-Face Centered Space". *Proceedings of the International Gesture Workshop on Gesture-Based Communication in Human-Computer Interaction*, London, UK, 17-19 March 1999.
- [26] Baldi P. "Autoencoders, unsupervised learning, and deep architectures". *In Proceedings of ICML workshop on unsupervised and transfer learning*, Washington, USA, 02 July 2012.
- [27] Rumelhart DE, Hinton GE, Williams RJ. *Learning internal representations by error propagation*. Editors: McClelland JL, Rumelhart DE. Parallel Distributed Processing Explorations in the Microstructure of Cognition Foundations, 318-362, California, USA, MIT Press, 1985.
- [28] Ha D, Schmidhuber J. "Recurrent world models facilitate policy evolution". *In Advances in Neural Information Processing Systems*, Montreal, Canada 02-08 December 2018.
- [29] Finn C, Tan XY, Duan Y, Darrell T, Levine S, Abbeel P. "Deep spatial autoencoders for visuomotor learning". *IEEE International Conference on Robotics and Automation (ICRA)*, Stockholm, Sweden, 16-20 May 2016.
- [30] Watter M, Springenberg J, Boedecker J, Riedmiller M. "Embed to control: A locally linear latent dynamics model for control from raw images". *In Advances in neural information processing systems*, Montreal, Canada, 07-12 December 2015.
- [31] Hubel DH, Wiesel TN. "Receptive fields and functional architecture of monkey striate cortex". *The Journal of physiology*, 195(1), 215-243, 1968.
- [32] Fukushima K. "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position". *Biological Cybernetics*, 36(4), 193-202, 1980.
- [33] Yamashita R, Nishio M, Do RKG, Togashi K. "Convolutional neural networks: an overview and application in radiology". *Insights into imaging*, 9(4), 611-629, 2018.
- [34] Maaten LVD, Hinton G. "Visualizing data using t-SNE". *Journal of machine learning research*, 9, 2579-2605, 2008.
- [35] Hochreiter S, Schmidhuber J. "Long short-term memory". *Neural computation*, 9(8), 1735-1780, 1997.
- [36] Seker MY, Tekden AE, Ugur E. "Deep effect trajectory prediction in robot manipulation". *Robotics and Autonomous Systems*, 119, 173-184, 2019.

- [37] Zhang P, Ouyang W, Zhang P, Xue J, Zheng N. "SR-LSTM: State Refinement for LSTM towards Pedestrian Trajectory Prediction". In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, California, USA, 16-20 June, 2019.
- [38] Oudeyer P, Kaplan F, Hafner VF. "Intrinsic Motivation Systems for Autonomous Mental Development". *IEEE Transactions on Evolutionary Computation*, 11(2), 265-286, 2007.