

Bilişsel Robotlarda Deneyimsel Öğrenme

Experimental Learning in Cognitive Robots

Sertac Karapınar^a, Mustafa Ersen^a, Melis Kapotoglu^a, Petek Yıldız^a, Sanem Sariel-Talay^a, Hulya Yalcin^b

^aBilgisayar Mühendisliği Bölümü, İstanbul Teknik Üniversitesi, İstanbul. {karapınarse, ersenm, kapotoglu, petekyildiz, sariel}@itu.edu.tr


^bElektronik ve Haberleşme Mühendisliği Bölümü, İstanbul Teknik Üniversitesi, İstanbul. hulyayalcin@itu.edu.tr

Özetçe —Bilişsel bir robot, eylemlerini fiziksel dünyada yürütürken iç ve dış etkenlerden dolayı çeşitli hatalarla karşılaşabilir. Bu bildiride, robotların eylem yürütme deneyimleri göz önüne alınarak görev yürütmede gürbüzlüğü nasıl sağlanabileceği araştırılmış ve bu amaçla, yeni hipotezler oluşturmak üzere yaşam boyu deneyimsel öğrenme yöntemi önerilmiştir. Önerilen öğrenme süreci, robotun eylemler, eylemlerin parametreleri ve ortamda bu eylemlerden etkilenen varlıklar hakkında kazandığı tecrübelerinin gelecek görevlerini yönlendirmesini sağlar. Hem yürütme modelleri hem de hata durumları için hipotez üretmek amacıyla Tümevarımsal Mantıksal Programlama (Inductive Logic Programming) yöntemi kullanılmıştır. Bu yöntemde, öğrenme ile kazanılan deneyimler birinci-dereceden mantık gösterimi ile temsil edilerek çıkarsama ve planlama için uygun hale getirilir. Böylelikle robotun bu deneyimlerini gelecekteki kararlarını verirken kullanması sağlanmış olur. Deneylerde, Tümevarımsal Mantıksal Programlama yönteminin başarımlı nitelik tabanlı öğrenme yöntemleri ile karşılaştırmalı olarak Pioneer 3DX robotu üzerinde kullanılarak analiz edilmiştir. Sonuçlar, önerilen sistem ile hata durumları için üretilen hipotezlerin robotun gelecek görevlerinin güvenliği için fayda sağladığını göstermiştir.

Anahtar Kelimeler—Bilişsel robotlar, yaşamboyu deneyimsel öğrenme, gürbüz görev yürütme.

Abstract—A cognitive robot may face several types of failures during the execution of its actions in the physical world. In this paper, we investigate how robots can ensure robustness by gaining experience on action executions, and we propose a lifelong experimental learning method to derive new hypotheses. Our proposed learning process takes into account the actions, the objects in interest and their relations to guide the robot's future decisions. We use Inductive Logic Programming as the learning method to frame hypotheses for both efficient execution types and failure situations. ILP learning provides first-order logical representations of the derived hypotheses that are useful for reasoning and planning processes. Experience gained through incremental learning is used as a guide to the future decisions of the robot for robust execution. In the experiments, the performance of ILP learning is analysed on a Pioneer 3DX robot with comparison to attribute-based learners. The results reveal that the hypotheses framed for failure cases are sound and ensure safety in future tasks of the robot.

Keywords—Cognitive robots, lifelong experimental learning, robust task execution.



Şekil 1. Farklı durumlarda *tutma* eyleminin yürütülmesi (blok dünyası ve satranç ortamı).

I. GİRİŞ

Bilişsel bir robot, hedefe yönelik plan yapma, gerçek dünyanın dinamik durumlarına karşı kararlarını değiştirme ve deneyimlerinden öğrenme gibi yeteneklere sahip olmalıdır. Robot, planında yer alan eylemleri gerçek dünyada yürütürken çok sayıda hata ile karşılaşabilir. Bu hatalar yeniden planlama ile kotarılabilir. Ancak bir hata oluştuğunda, planlama probleminin gerçek dünya temsili ile sembolik temsili arasındaki farklardan dolayı planlayıcı geçerli bir plan üretemeyebilir. Bu tür durumlarla başa çıkabilmek için robotun dünya modelini güncellemesi ve yeni çıkarımlar yapabilmesi gerekmektedir. Ayrıca robotun gelecekte daha verimli kararlar verebilmesi için öğrenme yeteneğine de sahip olması gerekir.

Bu çalışmada ele alınan problem, robotların görev yürütmesi esnasında gürbüzlüğü sağlamak için eylem yürütme hatalarından öğrenmesini gerektirmektedir. Problemin çözümü için kullanılan yaklaşım yaşam boyu deneyimsel öğrenmeye dayanmaktadır. Öğrenme ile elde edilen deneyimlerin robotu gelecek kararlarında da yönlendirmesi sağlanmıştır. Böylelikle robotlar uyarlamalı bir planlama stratejisi ile hataları kotarabilmektedir. Hem yürütme modelleri hem de hata durumları için hipotez üretmek amacıyla Tümevarımsal Mantıksal Programlama (Inductive Logic Programming) yöntemi kullanılmıştır. Mevcut durumun özelliklerinden (eylem, ilgilenilen nesne ve ilişkileri) yararlanılarak hipotez üretilmesi amaçlandığından nitelik tabanlı bir öğrenme yöntemi yerine bilgi tabanlı öğrenme yöntemi uygulanmıştır. Bu yöntemde hipotezler, önermeler mantığı gösterim dili ile ifade edilebilirler ve öğrenme sürecinde önsel bilgileri işleyebilirler. Robotun farklı bağlamlarda eylemlerini yürütürken hatalarından öğrenip bu deneyimlerinden yararlanabilmesi amaçlanmıştır. Örneğin, Şekil 1'de bir robot kolu ile üstüste blok yerleştirme ve satranç oynama problemlerinde tutma eyleminin yürütülmesi görülmektedir. Buna benzer farklı bağlamlarda robotun kazandığı deneyimleri yeni görevlerinde kullanabilmesi gerekmektedir.


Bu çalışma 111E286 no'lu proje kapsamında TÜBİTAK tarafından desteklenmektedir.

II. BİLİŞSEL ROBOTLARDA GÜRBÜZ GÖREV YÜRÜTME

Bilişsel robotlar, hedeflerine ulaşabilmek amacıyla yürütme gereken eylem dizilerini oluşturabilmek için bir eylem planlama sistemine ihtiyaç duyarlar. Planlama görevi $\Pi = (\Delta, s_0, s_G)$ şeklindeki bir çokuzlu tarafından temsil edilir. Bu çokuzluda Δ planlama tanım kümesini, s_0 başlangıç durumunu, s_G ise hedef durumunu temsil eder. Planlama tanım kümesi ise $\Delta = (T, C, S, O)$ şeklindeki bir çokuzlu ile temsil edilir. T tip kümesini, C tanım kümesi sabitlerinin kümesini, S durum kümesini ve O planlama operatörlerini belirtir. Bir planlama operatörü $o \subseteq O$, ön koşulları ve etkileri ile ($o = \{pre(o), add(o), del(o)\}$) temsil edilir. Başlangıç durumu s_0 'dan hedef durumu s_G 'ye ulaşmak için seçilen operatörlerin sırasıyla yürütülmesi ile planlama görevi tamamlanır. Herhangi bir $s \subseteq S$ durumunda operatör o 'nun seçilebilmesi için önkoşulların sağlanması ($pre(o) \subseteq s$) gerekir. o operatörünün s durumunda yürütülmesinden sonra $s' = add(o) \cup (s \setminus del(o))$ yeni durumuna geçilir. Geçerli bir plan P oluşturulduktan sonra, robot her a_t eylemini ($a_t \in A \rightarrow o_t$) fiziksel dünyada sırasıyla yürütebilir. Robot, yürütme sırasında herhangi bir problem ile karşılaşmazsa s_G durumuna ulaşmış olur. Ancak belirsizlikli olmayan eylemler ve fiziksel ortamlardaki belirsizlikler yüzünden, eylemler yürütülürken çeşitli hatalar ortaya çıkabilir [1]. Bu çalışmada eylem yürütme hataları ele alınmaktadır. Bu hatalardan bazıları robotun ortam hakkındaki yanlış ya da eksik bilgilerinden kaynaklanabilir. Örneğin robot bir nesnenin fiziksel/görsel özellikleri hakkında eksik bilgiye sahip ise, bu nesne üzerinde yürüteceği eylemlerde hata ile karşılaşabilir [2].

Eylemleri yürütme sürecinde oluşabilecek hataları algılama en önemli sorunlardan birisidir. Robot, eylemlerini yürütürken aynı zamanda ortamın durumunu gözlemlemeli ve yürütme zamanı hatalarından çıkarım yapmalıdır [3]. Robot, donanımında oluşan hataları algılamak için gerekli olan sensörlere sahip olsa da ortamdaki aykırı durumları algılamak için dışalgı (exteroception) gereklidir. Bu durumda bir ya da daha fazla sensörden gelen verileri yorumlamak, hatalardan çıkarım yapabilmek için oldukça önemlidir. Bu nedenle, robotun bir hatayı tespit edebilmesi ve doğru kararlar verebilmesi için, gördüğü sahneyi yorumlaması ve çıkarım araçlarını bu doğrultuda kullanması gerekir. Robot ortamını modelleyebilmek için bir bilgi tabanına (knowledge base) sahip olmalıdır. Bilgi tabanı $KB = (F, H)$ şeklinde ifade edilir. F olgular kümesini ve H hipotezler kümesini içerir. Robot, ihtiyaç duyduğunda gözlemlerine dayanarak $KB \models H$ olacak şekilde yeni hipotezler (H) üretir ve KB bu hipotezlere göre güncellenir. Hipotezler, robotun gelecek görevlerindeki başarımını arttırmak için kullanılabilir. Güdümlü öğrenmede (supervised learning), bilinmeyen bir fonksiyonun ($x, f(x)$) giriş ve çıkış değerleri verilir ve bu fonksiyonu modelleyen bir hipotez (h) öğrenilir. Öğrenilen bu hipotez henüz karşılaşılmamış örnekleri doğru bir şekilde tahmin edebilirse, doğru bir hipotez olarak sınıflandırılabilir.

Bu çalışmada ele alınan problem, eylem yürütme durumları (eylemin parametreleri, sonucu vs.) ile başarısızlık durumları arasında ilişki kurmak için bir öğrenme yönteminin geliştirilmesini gerektirmektedir. Bu ilişkinin kurulması hataların koterılması veya önlenmesi için gereklidir. Robot yaşamı boyunca eylem yürütme sonuçlarını ve ortamı gözleyebildiği için artımlı ve devamlı bir öğrenme yöntemine



Şekil 2. Bilişsel robotlar için planlama, yürütme ve öğrenme sistemi.

ihtiyaç duyulmaktadır. Ayrıca robotun hedeflerine ulaşabilmesi amacıyla yapması gereken çıkarım ve planlama işleri için bilgi tabanı, sembolik olarak ifade edileceğinden, kullanılacak olan öğrenme algoritması hipotezleri mantıksal cümleler şeklinde ifade edebilmelidir. Tümevarımsal Mantıksal Programlama (Inductive Logic Programming) yaklaşımı bu ihtiyaçların tümünü karşılamaktadır. Bu yüzden önerilen sistemde bu yaklaşımdan faydalanılmıştır.

III. BİLİŞSEL ROBOTLARDA TÜMLEŞİK PLANLAMA, YÜRÜTME VE ÖĞRENME SİSTEMİ

Bu çalışmada önerilen sistem beş temel süreçten oluşmaktadır: *Planlama*, *Görüntü Yorumlama*, *Yürütme*, *Yürütme Gözlemleme* ve *Öğrenme*. Bütün bu süreçler robot belleğinde tutulan bir bilgi tabanını sorgulama ve güncelleme yetkisine sahiptir. Bu bilgi tabanı, planlama tanım kümesi bilgilerini, ortamın güncel durumunu, planlama problemi için tanımlanmış hedefleri, plan ve robotun yürütme esnasında elde ettiği deneyimleri içerir. Bu süreçleri içeren sistemin temel bileşenleri ve aralarındaki bilgi akışı Şekil 2'de gösterilmiştir. Bu süreçler robotun duyarga ve motor arabirimlerine bağlanarak robotun bilişsel bileşenlerini oluştururlar. Şeklin basitleştirilmesi açısından haritalama ve yol planlama birimleri sistem diyagramında gösterilmemiştir.

Sistemde ilk olarak, ileri zincir çıkarsamalı zamansal bir planlayıcı olan TLPlan [4] kullanılarak bir plan üretilir. Bu plan, yürütme sürecinde her eylemin sırasıyla yürütülebilmesi için KB'de saklanır. Yürütme gözlemleme sürecinde güncellenen durumların kontrol edilmesi ve olası hataların sezişebilmesi için, plan bir yandan yürütülürken bir yandan da sürekli olarak gözlenir. *Görüntü Yorumlama* birimi sensörler ile ortamdaki elde edilen bilgilere dayanarak planlama bilgisini ve durumu günceller. Bütün sensör verileri toplandıktan sonra ortamdaki nesneler ve ilişkileri yorumlanıp önerme haline getirilerek KB'de kodlanır. Sistemde gerçek sensör girişleri ile beklenen değerler karşılaştırılarak hata tespiti yapılır. Hatanın sezişilmesiyle birlikte güncellenen ortam durumuna göre ya yeniden planlama yapılır ya da öğrenme süreci kullanılarak yeni hipotezler oluşturulur. Öğrenme sürecinde robotun gözlemlerinden eylemler, eylemlerin parametreleri ve ortamda bu eylemlerden etkilenen varlıklar hakkında deneyim kazanması sağlanır.

A. Planlama, Yürütme ve Gözlemlleme

Planlama ve yürütme işlemleri için kullanılan temel süreç (Algoritma 1) hedef durumuna ulaşıncaya ya da geçerli bir plan üretilmemeye durumuna dek çalışır. Geçerli bir plan bulunduğu, plandaki bütün eylemler yürütülürken bir yandan da hata durumlarına karşı gözlem yapılır.

Algorithm 1 Gürbüz Planlama, Yürütme ve Gözlemlleme (Δ, s_0, s_G)

Giriş: Planlama tanım kümesi Δ , başlangıç durumu s_0 , hedef durumu s_G
Çıktı: başarı ya da hata

```

 $s_t = s_0$ 
while  $s_t \not\subseteq s_G$  do
   $P = \text{Planlama}(\Delta, s_t, s_G)$ 
  if  $P = \emptyset$  then
    return hata
  end if
   $s_t = \text{Yürütme ve Gözlemlleme}(P, s_t)$ 
end while

return başarı

```

Yürütme ve gözlemlleme süreci (Algoritma 2) eylemlerin başarılı olarak yürütülüp yürütülmediğini sürekli olarak kontrol eder. Hem başarılı hem de başarısız yürütme durumlarında KB güncellenir (yeni hipotezler üretilir ya da var olanlar güncellenir). Eylem yürütülürken verilen bağlamda en başarılı eylem yürütme modeli saklanır ve saklanan model gelecekte tekrar kullanılır.

B. Yaşam Boyu Deneyimsel Öğrenme

Önerilen öğrenme yöntemi, *Tümevarımsal Mantıksal Öğrenme* (ILP) metoduna [5] dayanmaktadır. ILP’de asıl amaç gözlemler ile uyumlu bir hipotez üretmektir. Üretilen hipotez mantıksal cümleler kümesi ile ifade edilir. ILP, yeni gözlemler ortaya çıktıkça hipotez üretmeyi, hipotezi güncellemeyi ya da iptal etmeyi sağlar. Bu yöntemde hipotezler gözlemlerdeki niteliklerin bilgi kazançlarına göre oluşturulur. Yürütmenin gözlemlenmesi sonucu elde edilen iki tip hipotez vardır. Birinci tip hipotez farklı bağlamlarda güvenli eylem yürütme için uygun parametrelere ilişkin olarak üretilen hipotezlere karşılık düşer. İkinci tip hipotez ise yürütme hataları ile eylemlerin içerikleri arasındaki ilişkiyi ifade eder. İki durumda da bilinen ya da gözlenen nesnenin özellikleri, ilişkileri ve ortamın gözlenebilen özellikleri göz önünde bulundurularak ilgili olan özellikler hipoteze dahil edilir. Bu hipotezler gelecekteki planlamaları yönlendirmek amacıyla planlama tanım kümesini (Δ) güncellemek için kullanılır. Bu yüzden robot bir eylemi yürüttüğünde başarılı olsa da olmasa da tecrübe kazanmış olur.

ILP, robotların çalışma süreleri boyunca elde ettiği yürütme sonuçlarını kullanarak hipotezler üretmelerine yardımcı olur. ILP’nin en güçlü yanlarından biri de, hipotezlerin önermeler mantığı gösterim dili ile temsil edilmeleri sonucu, kolayca doğal dile çevrilebilmeleridir.

IV. DENEYLER

Çalışmada önerilen sistemin ve öğrenme sürecinin başarı oranını ölçmek amacıyla iki farklı deney ortamı tasarlanmıştır. İlk deney ortamında rastgele oluşturulmuş veriler üzerinde

Algorithm 2 Yürütme ve Gözlemlleme (P, s_t)

Giriş: Mevcut durum s_t , plan P
Çıktı: $s_{t \pm k}$ ya da beklenmeyen bir durum

```

 $P = P_{t:G}$ 
while  $P \neq \emptyset$  do
   $eylem = \text{POP}(P)$ 
   $parametreler = KB.YurutmeTipiAlma(eylem, nesne)$ 
  while true do
     $yurutmeGozlem = \text{Yurutme}(eylem[parametreler], s_t)$ 
     $s' = \text{GörüntüYorumlama}(t)$ 
     $\text{TemsilGüncelleme}(eylem, nesne, parametreler, yurutmeGozlem)$ 
    if  $yurutmeGozlem = \text{başarılı}$  then
       $s_t \leftarrow s'$ 
      break
    else
      if  $s' = s_t$  then
         $parametreler = KB.YeniYurutmeTipi(eylem, nesne)$ 
      else
        return  $s'$ 
      end if
    end if
  end while
end while
return  $s'$ 

```

function $\text{TemsilGüncelleme}(eylem, nesne, parametreler, yurutmeGozlem)$

```

 $KB.Ekle([eylem, nesne, parametreler, \text{GörüntüYorumlama}(t), yurutmeGozlem])$ 
if  $yurutmeGozlem = \text{başarılı}$  then
   $h = \text{ILP-Öğrenme}(eylem, KB)$ 
   $KB.YurutmeTipiAtama([h, eylem])$ 
else
   $h = \text{ILP-Öğrenme}(eylem, KB)$ 
end if

```

```

 $KB.Güncelleme([h, eylem])$ 
 $KB.Güncelleme(\Delta)$ 

```

öğrenme algoritmasının başarıyı nitelik tabanlı öğrenme algoritmaları *ID3* ve *Bayes Ağları (BA)* ile karşılaştırmalı olarak incelenmiştir. İkinci deney ortamı ise gerçek robot ve nesneler kullanılarak oluşturulmuştur.

A. Genel Başarım Analizi

Birinci deney setinde, önceden belirlenmiş hipotezlere göre *tutma* eylemi için rastgele üretilmiş gözlem setleri kullanarak başarımlar ölçülmüştür. 6 farklı hipotez belirlenip, her hipotez için her biri 30 farklı gözlemden oluşan eğitim seti ve 10 farklı gözlemden oluşan test seti rastgele olarak oluşturulmuştur. Her bir eğitim seti için *ILP*, *ID3* ve *Bayes Ağları* algoritmalarının başarılı ve başarısız eylemler için hipotezler üretmeleri sağlanıp, test setleri üzerinde bu hipotezlerin başarımları ölçülmüştür. Bunun için üç farklı ölçüm kullanılmıştır: kesinlik (precision), anma (recall) ve F-ölçütü (F-score). Tüm algoritmaların sonuçları Tablo I’de yer almaktadır.

Tablodan görülebileceği üzere *ID3* ve *Bayes Ağları* birbirlerine yakın ve *ILP*’den daha düşük F-Ölçütü değerlerine

Tablo I. ID3, BAYES AĞLARI VE ILP SONUÇLARI

Algoritma	Kesinlik	Anma	F-Ölçütü
ID3	0.643	0.648	0.645
BA	0.753	0.634	0.651
ILP	0.756	0.803	0.769

sahiptir. *Bayes Ağları* karşılaştığı test seti örneklerini genellikle *başarısız* olarak sınıflandırdığından *başarısız* sınıfı için çok yüksek doğru artı oranına ve *başarılı* sınıfı için de çok düşük doğru artı oranına sahiptir. *ILP*'de ise iki sınıf için doğru artı oranları ortalama olarak *ID3* ve *Bayes Ağları*'na göre daha iyi çıkmıştır. Hem kesinlik hem de anma ölçütüne göre hesaplanan F-ölçütü değerleri karşılaştırıldığında, *ILP* algoritmasının daha iyi sonuçlar verdiği görülmüştür.

B. Robot Üzerinde Başarım Analizi

Robot deneyleri, tutucu, sonar sensörler ve Kinect sensör taşıyan bir Pioneer 3DX robotu ile gerçekleştirilmiştir. Deneyde kullanılan robot ve nesneler Şekil 3'de gösterilmiştir. Seçilen nesneler dört farklı kategoriden oluşmaktadır: *dikdörtgen prizma*, *silindirik kutu*, *plastik lobut* ve *top*. Ortamdaki nesnelerin tanınması için çok-kipli şablon eşleştirmeye dayanan LINE-MOD [6] yaklaşımı kullanılmıştır. LINE-MOD yönteminde, nesnelerin şekillerinden ayırt edilebilmesi için yüzey normallerinden, farklı renklerin ayırt edilebilmesi içinse renk gradyanlarından yararlanılmaktadır.

Robot ile *tutma* eyleminin belirlenen nesneler üzerindeki başarısı test edilmiştir. Robotun nesneye olan uzaklığı, nesnenin ağırlık merkezine göre hesaplanmıştır. Kinect yaklaşık olarak 60 cm.'den daha kısa mesafelerde uzaklık ölçümü için çok güvenilir değildir. Bu yüzden hataların tespiti için, nesneye olan uzaklık belli bir değerin üstünde olduğunda Kinect, altında olduğunda ise sonar sensörler kullanılmıştır.

Tablo II birinci deneyin sonuçlarını göstermektedir. Her bir nesne için beş farklı *tutma* eyleminin başarım oranı tabloda verilmiştir. %50'den daha yüksek başarım oranı durumunda eylem başarılı kabul edilmiştir. Robot, kutu ve lobutlardan birer tanesi için eylemi yürütmede başarısız olmaktadır. Kutuyu almaya çalışırken oluşan hata, nesnenin fiziksel deformasyonundan kaynaklanmaktadır. Deformasyon yüzünden sonar sensörler nesnenin, robotun önünde olup olmadığına karar verirken hata oluşturmaktadır. Ancak bu sebep robot tarafından nesnenin bir niteliği olarak gözlenememektedir. Bunun yerine hipotez oluşturulurken gözlenebilen fiziksel nitelikler göz önüne alınmıştır. Lobutu almaya çalışırken oluşan hata ise robotun görüntü işlemesi ile ilgili bir problemten kaynaklanmaktadır. Robot bazen turuncu lobut ile yeşil lobutun



Şekil 3. Pioneer 3DX robotu turuncu plastik lobutu taşıırken görülmektedir.

Tablo II. BELİRLENEN NESNELERE GÖRE EYLEM BAŞARIM ORANI

Kategori	Şekil	Renk	Malzeme	Boyut	Başarı (%)
kutu	prizma	yeşil	kağıt	küçük	60
kutu	prizma	siyah	kağıt	büyük	60
kutu	silindir	yeşil	plastik	büyük	60
kutu	silindir	kırmızı	plastik	büyük	40
lobut		turuncu	plastik	küçük	20
lobut		yeşil	plastik	küçük	60
top	küre	mor	plastik	küçük	100
top	küre	beyaz	köpük	küçük	60

şablonlarını birbirine karıştırmaktadır, bu da uzaklık ölçülürken hataya yol açmaktadır. Bu yüzden nesneye yaklaşıırken çoğunlukla hata oluşur. Lobutun üst kısmı dar olduğu için sonar sensörlerle de konumu net algılamak mümkün olamamaktadır.

Farklı nesneler için yürütülen *tutma* eylemlerinde başarısız durumlar için hipotez üretmek amacıyla bütün gözlemler *ILP* algoritmasına giriş olarak verildiğinde *ILP* algoritmasıyla aşağıdaki hipotezler üretilmiştir:

Renk(yeşil) ⇒ BaşarılıTutma

Kategori(top) ∧ Şekil(küre) ⇒ BaşarılıTutma

Kategori(kutu) ∧ Şekil(prizma) ∧ Renk(siyah) ∧

Malzeme(kağıt) ⇒ BaşarılıTutma

Kategori(kutu) ∧ Renk(kırmızı) ⇒ BaşarısızTutma

Kategori(lobut) ∧ Renk(turuncu) ⇒ BaşarısızTutma

Üretilen hipotezler, robot için bir öncelik modeli oluşturulmasını sağlar. Hipotezlere göre *tutma* eyleminin maliyeti değiştirilerek, robotun alternatif bir eylem (örneğin *itme*) ile nesneleri taşıması ya da tutabileceğine inandığı alternatif nesneleri seçmesi sağlanabilir.

V. SONUÇ

Bu çalışmada, bilişsel robotlarda görevlerin gürbüz bir şekilde yürütülebilmesi için deneyimsel öğrenmeye dayalı bir sistem sunulmuştur. Önerilen sistemde, eylem yürütme hatalarının deneyim tabanlı bir öğrenme yöntemi olan *ILP* metodu ile öğrenilmesi sağlanmıştır. Bu öğrenme yöntemi, planlama, yürütme, gözlemlleme ve öğrenme süreçleri ile tümleşik bir mimari içinde sunulmuştur. Öğrenme süreci hem daha verimli yürütme modelleri elde etmek hem de hata durumları ile eylem yürütme bağlamlarının ilişkilendirilmesini sağlamak için hipotezler üretmek amacıyla kullanılmıştır. Öğrenme sürecinin sonuçları yürütmeyi planlarken gelecekte alınacak kararları yönlendirmek için kullanılır. Deneylerde *ILP* algoritmasının başarımı *ID3* ve *Bayes Ağları* algoritmaları ile karşılaştırılmış ve daha yüksek başarıma sahip olduğu gözlemlenmiştir. Ayrıca, gerçek robot ve nesnelerden oluşan bir ortamda da deneyler yapılarak, robotun *tutma* eylemi için elde ettiği gözlemlere göre ürettiği hipotezler incelenmiş ve robotun üretilen hipotezleri gelecekteki eylemlerini çok daha verimli bir şekilde yürütmek için kullanabileceği görülmüştür.

KAYNAKÇA

- [1] S. Karapinar, D. Altan, and S. Sariel-Talay, "A robust planning framework for cognitive robots," in *Proceedings of the AAAI-12 Workshop on Cognitive Robotics (CogRob)*, 2012.
- [2] A. Bouguerra, L. Karlsson, and A. Saffiotti, "Monitoring the execution of robot plans using semantic knowledge," *Robotics and Autonomous Systems*, vol. 56, no. 11, pp. 942–954, Nov. 2008.
- [3] O. Pettersson, "Execution monitoring in robotics: A survey," *Robotics and Autonomous Systems*, vol. 53, pp. 73–88, 2005.
- [4] F. Bacchus and M. Ady, "Planning with resources and concurrency a forward chaining approach," in *Proceedings of the 17th International Joint Conference on Artificial Intelligence - Vol. 1*, 2001, pp. 417–424.
- [5] J. R. Quinlan, "Learning logical definitions from relations," *Machine Learning*, vol. 5, pp. 239–266, 1990.
- [6] S. Hinterstoisser, C. Cagniard, S. Ilic, P. Sturm, N. Navab, P. Fua, and V. Lepetit, "Gradient response maps for real-time detection of textureless objects," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 34, no. 5, pp. 876–888, 2012.