

# Şekil Bağlamı Kullanarak Eylem-Etki Tahmini

Muhammet Yunus ŞEKER, Erhan ÇAĞIRICI, Emre UĞUR  
Bilgisayar Mühendisliği Bölümü  
Boğaziçi Üniversitesi  
İSTANBUL, Türkiye  
Email: {yunus.seker1,erhan.cagirici,emre.ugur}@boun.edu.tr

**Özetçe** —Öğrenen robotların dış dünya ile etkileşiminde, yaptıkları eylemlerin etkilerini tahmin etmeleri, isabetli bir etkileşim ve karmaşık hareket planlamaları için önemli bir etmendir. Bu çalışmada, robotun rastgele bir şekil üzerinde uygulayacağı kaldırma hareketinin sonucunu tahmin ederken, *şekil bağlamı* öznitelikleri ve makine öğrenimi yöntemleri kullanarak tahmin isabetini artırdığı bir öğrenme modeli anlatılmaktadır. Çalışmamızda, önereceğimiz şekil bağlamı tanımlayıcısı kullanılarak fizik motoru tabanlı 3B simülâtörde cisimler üzerinde kaldırma eylemleri simüle edilmiş, ve bu veriler ile yapay sinir ağları üzerinden öğrenme gerçekleştirilmiştir. Bir cisim türünden öğrenilen kaldırma tahmin bilgisinin başka cisim türlerine de genellenebildiği, ve cisimlere ait ağırlık merkezi bilgisi kullanılmadan bile yöntemimiz ile eylem-etki tahminlerinde isabetli sonuçlar elde ettiği gösterilmiştir.


**Anahtar Kelimeler**—Eylem-etki tahmini, Şekil Bağlamı, Yapay Sinir Ağları.

## I. GİRİŞ

Gelişen robot teknolojileri ile robotlar artık dış dünya ile daha çok etkileşim halinde çalışmaktadırlar. Bu durumda robotların dış dünyadaki cisimler üzerinde yaptıkları veya gözlemledikleri eylemlerin etkilerini önceden tahmin edebilmesi, robotun eylemlerini planlayabilmesine ve yaptığı eylemlerin etkilerine bağlı olarak çalışmaya devam edebilmesine oldukça katkı sağlamaktadır. Bu çalışmadaki amacımız da robotun çevresi ile etkileşime geçerken öngörmesi zor fiziksel eylemlerin oluşturduğu etkilerin sonuçlarını tahmin edebilmesi ve bu tahminlere göre eylemlerini düzenleyebilmesidir.

Eylem-etki tahmininin çevresel etkileşimli öğrenen robot uygulamalarına sağladığı katkı çeşitli hareket ve görevlerin öğreniminde kullanılabilir. Üzerinde çalıştığımız projede kullanım durumlarından biri olan bilgisayar disklerinin demonte edilmesi, bu tip öğrenme görevlerine örnek olarak verilebilir. Burada amaç, karmaşık cisimlerin hareketlerinin tahmin edilerek, bu tahminlerin daha karmaşık bir görevi tamamlamak üzere planlamada kullanılması ve yapılan eylemin, planlandığı gibi sonuç verip vermediğinin kontrol edilmesidir. Bu durumda etki tahmini makine öğrenmesi yardımıyla nispeten basit regresyon işlemleri olabileceği gibi Uzun Kısa-Dönem Hafıza(LSTM) [1], Saklı Markov Modeli(HMM)[2] gibi daha karmaşık yörünge tahmin yöntemleri kullanılabilir.

Bu noktada etkileşime geçilen cisimlerin fiziksel özelliklerini temsil edebilecek ve karmaşık yörünge tahmin edici yöntemlere girdi olarak sağlanabilecek, genellenebilir, kapsamlı bir tanımlayıcıya ihtiyacımız vardır. Bu bildiride tanımlayıcı olarak şekil bağlamı kullanılması önerilmiştir [3]. Şekil bağlamı cisimlerin genel fiziksel bilgilerini temsil ederek Türkiye Robotbilim Konferansı, 2018



Şekil 1: Baxter robot sabit diskin üstündeki PCB ünitesine kaldırma eylemi gerçekleştiriyor

benzer şekillerin ve dolayısı ile benzer fiziksel özelliklere sahip cisimlerin ayırt edilmesini sağlayabilmektedir [4]. Dolayısıyla şekil bağlamı tanımlayıcısı, eylemlerin içerdiği kuvvet bilgileri ile birleştirildiğinde, cisim üzerinde oluşacak etki tahmin edilebilir bir duruma ulaşmaktadır.

Çalışmamızda öznitelik vektörü olarak kuvvet bilgileri ve şekil bağlamı beraber kullanılmış ve bu öznitelikler makine öğrenmesi yöntemleri arayıcılığı ile eğitilerek daha önce robotun görmediği cisimler üzerinde de eyleminin etkilerini istikrarlı olarak tahmin edebilmesi gösterilmiştir. Örnek eylem olarak kaldırma eylemi seçilmiş ve şekil bağlamının kaldırma eylemi sırasında cisimlerin hangi kenarı üzerinden destek alarak kalktığını ve dolayısıyla cisimin nereye doğru yöneleceğini tahmin etmekteki başarısı öne çıkarılmıştır.

Bildirinin içeriği şu şekilde ilerlemektedir: II. Bölüm'de şekil bağlamını daha önce üç boyutlu nesne tanımada ve robot eylemlerinde kullanmış çalışmalardan bahsedilecek ve şekil bağlamının verimli bir tanımlayıcı olabileceği tartışılacaktır. III. Bölüm'de şekil bağlamı ve bizim çalışmamızda kullandığımız yöntemler açıklanacaktır. IV. Bölüm'de kaldırma eylemi ile yapılan deney düzeni anlatılacaktır. V. Bölümde deney sonuçları gösterilecek ve incelenecektir.

## II. BENZER ÇALIŞMALAR


Bu bölümde daha önce şekil bağlamını tanımlayıcı olarak kullanmış örnek çalışmalardan bahsedilmiştir. İlk çalışma üç boyutlu nesne tanımak ile alakalı olup robotik alanı ile de oldukça yakın olabilecek, robotun dış dünya ile etkileşimini destekleyecek bir konu üzerine yazılmıştır. İkinci çalışmada ise robotun etrafındaki cisimlerin kavrama noktalarını şekil bağlamı kullanarak başarılı bir şekilde öğrenebilmesi ve eylem-etki ilişkisini kurabilmesi anlatılmaktadır.

*Şekil Bağlamı Kullanılarak Şekil Eşleşmesi Tahmini ve Üç Boyutlu Nesne Tanıma:* Belongie ve Malik tarafından gerçekleştirilen bu çalışmanın konusu şekiller arasındaki benzerliği ölçebilen yeni bir yaklaşım sunmak ve bu ölçümün nesne tanınmasında kullanılabileceğini göstermektir [5]. Benzerlik ölçümleri 2 adım üzerine kuruludur: 1) İki şekil üzerindeki noktalar arasından karşılıklı gelebilecek noktaların çözülmesi, 2) Bu karşılıklı noktaları kullanarak şekiller arasında bir hizalama dönüşümü tahmini yapmak. Karşılıklı noktaları bulma problemini çözmek için her nokta üzerinde şekil bağlamı tanımlayıcısı kullanılmaktadır. Bir referans noktasındaki şekil bağlamı, kalan bütün diğer noktaların kendisine göre hizalarını ve dağılımlarını hesaplamakta, ve böylece şeklin genelini temsil edebilen bir tanımlayıcı olarak karşımıza çıkmaktadır. Birbirine benzeyen iki şekil üzerindeki karşılık gelen benzer noktalar, benzer şekil bağlamlarına sahip olmakta, ve iki şekil için en iyi karşılıklı gelen noktaların bulunmasını mümkün kılmaktadır. İki şekil arasındaki benzerlik, hizalama dönüşümünün büyüklüğünü ölçen bir terim ile birlikte, karşılık gelen noktalar arasındaki eşleşme hatalarının toplamı olarak hesaplanır. Nesnelere tanımda kullanılan sınıflandırma modeli, daha önceden gördüğü nesnelerin şekil bağlamı ile karşılaştırıldığında hata toplamını en düşüğe çekecek şekilde tasarlanmıştır ve deney sonuçları şekil bağlamının nesne tanımda istikrarlı bir tanımlayıcı olduğunu göstermektedir.

*Şekil Bağlamı Kullanılarak Kavrama Noktası Hesaplanması:* Bohg ve Kragic çalışmalarındaki ana konu görme temelli obje kavramadır [6]. Önerilen yöntem, iki boyutlu resimlerden görme yöntemleri aracılığıyla objelerin çevre noktalarının elde edilmesi ve bunların temsil edilmesi üzerine kurulmuştur. Robotun elindeki örnek cisimler ile bazı kavrama noktaları öğrenmesi ve öğrendiği modeli sonradan daha önce görmediği cisimlerde kullanarak elverişli kavrama noktaları üretebilmesi sağlanmıştır. Cisimlerin ve kavrama noktalarının temsili için şekil bağlamı tanımlayıcısı kullanılmış ve şekil bağlamı tanımlayıcısı, kavrama noktalarının önceden işaretlenmiş olduğu resimler ile gözetimli öğrenme yöntemlerine aktarılmıştır. Bu çalışmanın sonucu, şekil bağlamlarının doğrusal olmayan sınıflandırma yöntemleri ile birleştirildiğinde farklı özelliklerdeki cisimlerin kavrama noktalarını istikrarlı bir şekilde tespit edebildiğini göstermektedir.

### III. YÖNTEM

Çalışmamızda, şekil bağlamlarının öznitelik olarak kullanılmasının robotun kaldırma eylemi için eylem-etki tahminlerinde kayda değer gelişmeler ortaya çıkardığını göstermek için sıra ile şu yöntemler izlendi. Öncelikle bilgisayar ortamında üzerinde kaldırma eylemi yapılabilecek rastgele şekiller üretildi ve şekillerin kenarlarından kuvvet uygulama pozisyonları belirlendi. Ardından bu şekiller ve kuvvet uygulama pozisyonları simülatora aktarılarak kaldırma eylemi deneyleri gerçekleştirilip veri seti oluşturuldu. Ardından her şeklin her köşesine ait şekil bağlamı hesaplandı ve veri setine katıldı. Son olarak makine öğrenmesi yöntemleri ile elimizdeki veri setinden eğitimler yapıldı ve destek kenarını tahmin edebilmedeki başarımlar ölçüldü. Aşağıdaki alt bölümlerde yöntem adımlarımız sırası ile detaylandırılmıştır.



Şekil 2: Rastgele oluşturulmuş örnek şekiller




Şekil 3: Rastgele oluşturulmuş bir şekil ve simülasyon modeli.

#### A. Rastgele Şekil Üretme ve Kuvvet Uygulama Pozisyonu Oluşturma

Şekil bağlamının eylem-etki tahminindeki rolünü ve genellenabilirliğini araştırmak için rastgele değişik şekillerden oluşan bir veri seti oluşturuldu. Bu veri setinde bulunan rastgele şekilleri oluşturmak için boyutu rastgele seçilen bir çember üzerinden oluşturulmak istenen çokgenin köşe sayısı kadar nokta seçildi. Çember merkezi ile bu noktaların ayrı ayrı birleştirilmesi ile oluşan vektörlerin, çemberin bulunduğu dik koordinat düzlemiyle yaptığı açılara göre bu noktalar numaralandırılıp sırayla birleştirildi. Birleştirilen noktalar sonucu, istenen sayıda köşesi olan bir çokgen elde edildi (Şekil 2). Daha sonrasında oluşturulan çokgen kenarları üzerinde rastgele kuvvet uygulanacak noktalar belirlendi. Bu işlemler istenen sayıda şekil için rastgele seçilen köşe sayılarıyla tekrarlanarak, 100 tane şekil elde edildi. Bu şekillerin her kenarı için kuvvet uygulanacak 5 tane rastgele nokta belirlendi ve kaydedildi. Tüm şekillerin homojen yoğunluğa sahip olduğu varsayılmıştır.

#### B. Simülasyon ile Veri Seti Oluşturma

Oluşturulan rastgele şekillerin bilgileri kullanılarak model dosyaları oluşturulup simülasyon ortamına aktarıldı (Şekil 3). Simülasyon ortamı için VREP[7] ve Bullet 2.83 fizik motoru kullanıldı. Daha sonra oluşturulan şekil simülasyon ortamında oluşturulan bir masanın üst yüzeyinde sabit duracak şekilde yerleştirildi. Daha önce o şekil için oluşturulan rastgele kuvvet uygulama pozisyonlarından, şekil normaline paralel olacak biçimde yapay bir kaldırma kuvveti uygulandı (Şekil 4). Buradaki amaç, robotun sözkonusu şekli bir kenarından torka benzeri bir alet ile kaldırdığını varsayarak, bu hareketi simülasyonda taklit etmektir. Uygulanan kaldırma kuvveti sonrasında, cismin hangi köşelerinden destek alarak kalktığı,



Şekil 4: Üçgen bir cisim ile örnek bir kaldırma deneyi. Gösterilen kuvvet uygulama pozisyonundan kaldırma eylemi uygulanıyor ve cismin hangi kenardan destek olarak kalktığı gözlemleniyor.

daha önceki adımda uygulanan köşe numaralandırmasına sadık kalınarak kaydedildi. Bu aksiyon sistematik olarak tekrarlanarak, oluşturulan 100 şeklin, uygulanan her kuvvet için hangi noktadan destek olarak kalktığını gösteren bir veri seti oluşturuldu. Örnek vermek gerekirse, bir altıgen için (0.04, 0.08) noktasından kuvvet uygulandığında 2 ve 3. köşeler destek noktaları ise bu deney sonucunun formatı şu şekildedir:


Uygulanan kuvvetin koordinatları	Köşe Koordinatları	Köşe etiketleri
(0.04, 0.08) <sub>K<sub>1</sub></sub>	K <sub>1</sub>	0
(0.04, 0.08) <sub>K<sub>2</sub></sub>	K <sub>2</sub>	1
(0.04, 0.08) <sub>K<sub>3</sub></sub>	K <sub>3</sub>	1
(0.04, 0.08) <sub>K<sub>4</sub></sub>	K <sub>4</sub>	0
(0.04, 0.08) <sub>K<sub>5</sub></sub>	K <sub>5</sub>	0
(0.04, 0.08) <sub>K<sub>6</sub></sub>	K <sub>6</sub>	0

Tablo I: Bir kaldırma deneyinin sonuçları


Tablo I'de,  $K_i$ , şeklin  $i$ . köşesinin (x,y) koordinatlarını temsil etmektedir.  $(0.04, 0.08)_{K_i}$  ise uygulanan kuvvet pozisyonunun  $i$ . köşeye ait referans çerçevesine bağlı koordinatlarını ifade etmektedir. Kuvvet uygulama pozisyonu koordinatları her köşe noktası için bir önündeki kenar üzerine kurulmuş kendi referans çerçevesi üzerinden dönüştürüldüğünden, rotasyondan bağımsız olarak veri setimize eklenmiş durumdadır.

### C. Şekil Bağlamı Hesaplama

Şekil bağlamı tanımlayıcısı şeklin sınır noktalarını örnekleyerek şeklin genel hatlarını ve fiziksel özelliklerini temsil etmektedir. Öncelikle şeklin sınır noktaları hesaplanır ve hesaplanan sınırlardan düzgün dağılım oluşturacak şekilde örnek noktalar alınır. Şekil bağlamı özelliği sınır noktalardan bir noktayı referans kabul edilerek hesaplanır ve bizim çalışmamızda bu referans noktaları cisimlerin köşe noktalarıdır. İstenilen köşe belirlendikten sonra bu noktadan diğer bütün



Şekil 5: Şeklin sınırlarının bulunması, örnek noktalarının hesaplanması ve köşeden her noktaya vektörlerin çizilmesi



Şekil 6: Bir köşenin şekil bağlamı, yüzük ve yarıklar. Log-polar sistemin sıfıncı yarığı rotasyondan bağımsız olabilmek için referans köşenin bir sonraki köşe ile yaptığı kenar üzerinde.

örnek noktalara ulaşan vektörler hesaplanır (Şekil 5). Bu vektörler referans noktamızdan örnek noktalara olan uzaklıkları ve açıları temsil etmektedir ve örnek noktalar şeklin kenarlarına düzgün şekilde dağılmış olduğundan bu vektör kümesi o köşeyi referans olarak şeklin genel hatlarını ve fiziksel özelliklerini temsil ediyor durumdadır. Son olarak vektörler referans noktasına yerleştirilen bir log-polar koordinat sistemine göre sayılır ve hangi vektörün log-polar sistemdeki hangi yüzük (ring) ve yarık (edge) aralığına denk geldiği hesaplanır. Bu şekilde yüzük sayısı  $R$  ve yarık sayısı  $W$  olmak üzere o nokta için  $R \times W$ 'lik bir öznitelik çıkartılmış olunur (Şekil 6). Şekil bağlamı, Log-polar koordinat sistemini kullanır çünkü bu sistem, referans noktasına yakın olan örnek noktalardan daha fazla detay alınabilmesini sağlamaktadır.

Oluşturulacak şekil bağlamlarını, şekillerin büyüklüklerinden bağımsız hale getirmek için veri setindeki şekillerin köşe noktaları öncelikle bire birlik bir pencere içerisine ölçeklendirildi. Ardından şekillerin farklı rotasyonlarından bağımsızlık kazanabilmek için ise her köşenin referans çerçevesi, y eksenini kendisinden bir sonraki köşeye oluşturduğu vektör ile çakışacak şekilde yeniden düzenlendi. Her köşenin şekil bağlamındaki sıfıncı yarığının başlangıç yönü, o köşenin kendi y eksenini kabul edildi ve şekil bağlamı bu şekilde büyüklükten ve rotasyondan bağımsız olarak deneylere katıldı.

### D. Makine Öğrenmesi ile Destek Noktası Tahmin Etme

Her köşe için şekil bağlamı öznitelik vektörleri oluşturulmasının ardından, bu öznitelik vektörlerini kullanarak bir noktanın destek noktası olup olmadığını tahmin eden gözetimli

makine öğrenmesi modeli oluşturuldu. Oluşturduğumuz modelde, girdi olarak, kuvvet uygulama pozisyonu ve o köşeye ait şekil bağlamının öznitelik vektörünün birleşimi verildi. Gözetimli öğrenme için, bu örneğin beklenen çıktısı iki sınıflı olmak üzere, eğer sözkonusu köşe destek noktası ise 1, değilse 0 olacak biçimde verildi.

$$[F_x \ F_y \ SC_1 \ \dots \ SC_n] \quad (1)$$

Buradaki değişkenler:

$F_x$  = Uygulanan kuvvetin x koordinatı

$F_y$  = Uygulanan kuvvetin y koordinatı

$SC_i$  = Sözkonusu şeklin, kontrol edilen köşesine ait şekil bağlamı öznitelik vektörü elemanı.

Bu model ile yapılan öğrenme sonucunda, bir kuvvet uygulama pozisyonu ve bir köşeye ait şekil bağlamı verildiğinde, sözkonusu köşenin destek noktası olup olmadığını sınıflandırıyoruz. Fakat ana amaç, herhangi bir şekle uygulanan kuvvet sonucunda destek alınan kenarı belirlemek olduğu için test prosedüründe tüm köşeler için bu tahmin yapılarak, eğer tüm köşelerin destek noktası olup olmadığı tamamen doğru tahmin edilirse, yapılan kenar tahmini de doğru kabul edildi. Örneğin, elimizdeki bir altıgenin simülasyon sonucunda elde edilmiş destek noktaları 2. ve 3. köşeler olsun. Yani bu şeklin köşelerinin sınıfları (0,1,1,0,0,0) biçiminde olmalıdır. Diğer kombinasyonlar, şeklin destek kenarının yanlış hesaplanması anlamına gelir. Öğrenme yöntemimiz,  $f$  öğrendiğimiz modeli temsil etmek üzere matematiksel olarak şu şekilde ifade edilir.

$$f(F_x, F_y, SC_1, SC_2, \dots, SC_n) = \begin{cases} 1 & , f > 0.5 \\ 0 & , f < 0.5 \end{cases} \quad (2)$$

Sınıflandırma için Yapay Sinir Ağları(ANN) kullanıldı. Tüm deney örneklerinden 0 ve 1 sınıf oranlarını koruyacak şekilde rastgele öğrenme seti seçilerek makine öğrenme metodlarına girdi olarak verildi. Kalan örnekler test seti olarak kullanıldı.

#### IV. DENEYLER

##### A. Deney Düzenliği

Deneyler yapılırken ilk önce yöntem kısmında anlatıldığı gibi toplamda 100 tane şekil üretimi yapıldı. Her biri üçgen veya ongen arasında oluşacak bu şekiller için üzerinden nokta alınan çemberin çapı 20cm olarak seçildi. Ardından şekil seçimini büyüklükten bağımsız hale getirmek için üretilen şekiller 1 ile 3 arasında rastgele noktalı değerler ile çarpıldı. Böylece büyüklükleri birbirinden farklı, kenar sayıları 3 ile 10 arasında olan 100 tane rastgele şekil üretilmiş oldu.

Üretilen şekiller VREP'te teker teker oluşturulup kuvvet uygulama pozisyonlarından kaldırma eylemi deneyleri gerçekleştirildi ve veri setine kaydedildi.  $N$ , bir şeklin kenar sayısı olmak üzere  $N$  kenarlı bir şekilden  $5 * N^2$  tane veri elde edilmektedir. Örneğin bir üçgen için üç kenarından beşer tane kaldırma noktası belirlenir ve bu on beş kaldırma deneyi için üç köşenin durumu 0 veya 1 olmasına göre kayıt edildiği için toplamda bir üçgenden kırk beş tane veri elde edilmiş olur. Bu durumda toplam veri sayımız,  $S$  toplam şekil sayısını,  $N_i$

ise  $i$ . şeklin kenar sayısını temsil edecek şekilde  $\sum_{i=1}^S (5 * N_i^2)$  olarak hesaplanabilir.

Cisimlerin köşe noktalarının şekil bağlamı hesaplanırken log-polar koordinat sistemi kullanıldı. Parametreler olarak 10 yüzük (ring) ve 20 yarık (wedge) sayısı seçilerek her bir şeklin her bir köşesi için log-polar koordinat sisteminden 10x20 boyutunda 200'lük öznitelik vektörü elde edildi. Son olarak şekil bağlamı, değerlerinin toplamları bir olacak şekilde normleştirildi. Deneyler içerisindeki kuvvet uygulama pozisyonlarının koordinatları da her köşe için o köşenin referans çerçevesi üzerinden hesaplanarak kuvvet uygulama pozisyonları için rotasyon bağımsızlığı elde edildi.

##### B. Öğrenme Metodları

Deneyler ile ilgili veriler elde edilip düzenlendikten sonra sınıflandırma işlemi Yapay Sinir Ağları üzerinden gerçekleştirildi. Ardından öğrenme modeli, daha önce görülmemiş test noktaları ile denendi ve bulunan sonuçlardan köşe bazında ve şekil bazında doğruluk değerleri çıkartıldı. Yapay Sinir Ağı modeli için saklı katmanda 50 nöron kullanıldı. Saklı katmanda sigmoid aktivasyon fonksiyonu kullanıldı. Çıktı katmanında ise kayıp fonksiyonu olarak sınıflar arası çapraz entropi kullanıldı ve doğruluk sonuçları çıkartıldı. Uygulamalar, MATLAB Machine Learning Toolbox[8] üzerinden gerçekleştirildi.

#### V. DENEY SONUÇLARI


Deney sonuçlarımızda, önerdiğimiz şekil bağlamı tabanlı öznitelik tanımlayıcısı, bir taban çizgisi ile karşılaştırılmak istenmektedir. Taban çizgisi yöntemi olarak sadece kuvvet uygulama pozisyonu temelli bir öznitelik kullanılmış ve bu Kaldırma Pozisyonu (**KaldırPoz**) olarak isimlendirilmiştir. Bizim önerdiğimiz yöntem ise KaldırPoz yanında şekil bağlamı özniteliklerinin de kullanılmasıdır ve (**ŞekilBağ**) olarak isimlendirilmiştir.

**ŞekilBağ** yönteminin etkisini araştırmak için iki deney düzeninde de, önce **KaldırPoz** öznitelikleri girdi olarak kullanılarak model eğitimi yapıldı ve bu sonuçlar baz sonuçlar olarak kaydedildi. Daha sonrasında şekil bağlamı öznitelikleri de model eğitimine katıldıktan sonra, iki deney düzeni için de test veri seti başarımları hesaplandı. Bu sonuçlar, baz sonuçlar ile karşılaştırıldı. Bu deneylerde başarımlar, şekil bazındaki tüm noktaların doğru tahmin edimesine ve dolayısı ile şekil bazında doğru destek kenarının tahminine bağlı olarak hesaplandı.

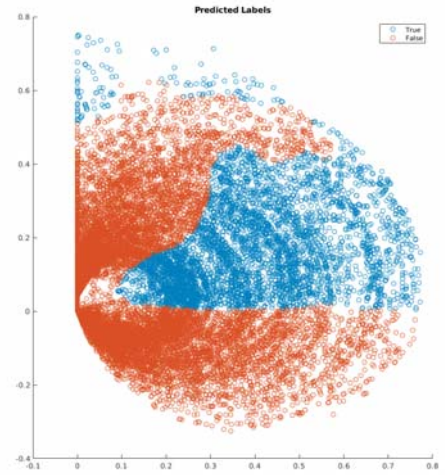
##### A. Kaldırma deneyi öğrenme verisi analizi

Öğrenme uzayının ayrılabilirliği ile kaldırma uygulama pozisyonlarının dağılımını görüntülemek ve cisimlerin hangi durumlarda hangi köşelerden kalktığını incelemek için öğrenme uzayı görselleştirildi. Şekil 7'de yapılan tüm kaldırma deneylerinin gerçek sonuçları (ground truth), uygulanan kuvvet uygulama pozisyonlarının uzayında görülmektedir. Kaldırma noktalarının koordinatları her köşe için o köşeye ait referans çerçevesi üzerinden dönüştürülerek deneye katıldığı için köşelerimiz uzayda (0,0) noktasındadır ve uygulanan kuvvetler bu noktaya göre gözükmektedir. Şekil 8 **KaldırPoz** öznitelikleri girdi olarak verildiğinde tahmin edilen sonuçları ve öğrenilen modelin uzayı nasıl ayırdığını göstermektedir. Bu modelin başarımları kaldırma deneyi bazında %76 olarak sonuçlanmıştır. Şekil 9'da ise **ŞekilBağ** öznitelikleri ile elde edilen





Şekil 7: Simülörde yapılan deney sonucu destek noktası olduğu veya olmadığı işaretlenen köşeler referans alınarak dönüştürülen kuvvet uygulama pozisyonlarının iki boyutlu uzaydaki kesin doğru dağılımı.



Şekil 8: 50 saklı nöronlu yapay sinir ağına **KaldırPoz** öznelikleri verildiğinde eğitim sonuçlarının kuvvet uzayında dağılımı


test sonuçları ve öğrenme uzayını nasıl ayırdığı görülmektedir. Bu model kaldırma deneylerinin sonuçlarını tahmin etmedeki başarısı %97.2 olmuştur.

İki modelin ürettiği uzay ayrımlarını gerçek sonuçlar ile karşılaştıracak olursak, şekil bağlamı kullandığımız modelin gerçeğe çok daha yakın çıktığını görmekteyiz. **KaldırPoz** özneliklerinin oluşturduğu model, gerçek veriyi taklit etmeye çalışmakta fakat destek noktası ve destek noktası olmayan etiketli verilerin karmaşık ve düzensiz bir şekilde dağıldığı yerlerde basit ve başarımı çok daha az sonuçlar vermektedir. Noktaların karmaşık olarak çokca yoğunlaştığı bölgelerde, kuvvet uygulama pozisyonları şekil bağlamı ile beraber kullanıldığında çok daha başarılı tahminlerin yapılabilen olduğu Şekil 9'da gösterilmektedir.

#### B. Artan Eğitim veri seti miktarının öğrenime etkisi

**KaldırPoz** kullanılan model ile **ŞekilBağ** kullanılan modellerin doğruluk karşılaştırılmasının yapılabilmesi için iki farklı deney yöntemi oluşturuldu. İlk deneyde, eğitim setinin değişen miktarlarda örneklerle kullanılmasının model başarımına etkisi araştırıldı. Tüm veri setinin, %10'dan başlayarak, %10 aralıklarla %90'a kadarı kullanılarak model eğitildi.


Daha önce de bahsedildiği gibi, asıl test yöntemi şeklin tüm noktalarının doğru tahmin edilmesi biçimindedir. Birinci deney düzeneği için, Şekil 10'da **KaldırPoz** öznelikleri ile yapılan eğitimin, değişen eğitim seti miktarındaki test başarımı görülmektedir. Buna karşılık Şekil 12 aynı deneyin **ŞekilBağ** öznelikleri ile eğitilmesi sonucu oluşan durumu göstermektedir. Bu deneyde, **ŞekilBağ** özneliklerinin şekil bazlı test başarımını %35'e varan oranda artırdığı gözlemlenmektedir. Aynı zamanda artan eğitim veri seti miktarıyla test başarımında %72'den %90'a artış sağlanmıştır. Yaklaşık 2000 veri ile modelimizin gürbüz bir öğrenme gerçekleştirebildiği ve istikrarlı tahminler yapabildiği gözlemlenmiştir.



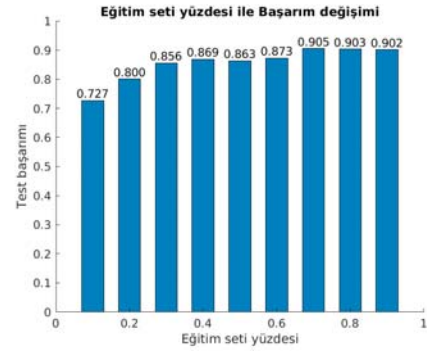
Şekil 9: **ŞekilBağ** özneliği kullanılan modelin eğitim sonuçlarının kuvvet uzayında dağılımı.

#### C. Eğitim setindeki çokgen türünün öğrenimine etkisi ve genellebilirlik

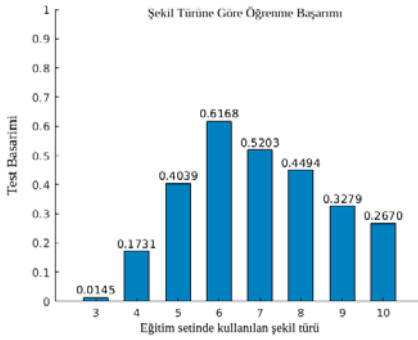
Bu deneyde bir tip şekil türüne ait cisim öğrenen bir sistemin daha önce hiç görmediği başka tip bir cisim ne kadar iyi tahmin edebildiği, yani öğrenilen modelin ne kadar genellebilir olduğu araştırıldı. Bu amaçla sadece bir tip çokgen model eğitiminde kullanılarak, diğer çokgen tiplerinin sınıflandırılmasındaki tahmin başarımı ölçüldü. Örneğin, model veri setindeki tüm altıgenler üzerindeki deney sonuçları ile eğitilerek, veri setindeki diğer tüm şekillere ait deneyleri doğru tahmin edebilme başarımı ölçülmüştür. Bu işlem köşe sayısı 3'ten 10'a kadar olan veri setindeki tüm köşe alt kümeleri için tekrarlandı. Şekil 11'de **KaldırPoz** öznelik



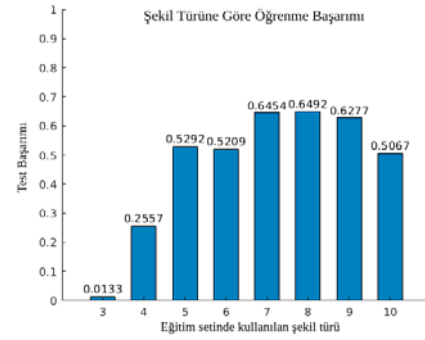
Şekil 10: **KaldırPoz** öznelikleri ile modelin isabet oranının eğitim veri setinin kullanılan yüzdesine göre değişimi.



Şekil 12: **ŞekilBağ** öznelikleri ile modelin isabet oranının eğitim veri setinin kullanılan yüzdesine göre değişimi



Şekil 11: **KaldırPoz** öznelikleri ile diğer çokgen türlerini tahmin edebilme isabet oranı



Şekil 13: **ŞekilBağ** öznelikleri ile diğer çokgen türlerini tahmin edebilme isabet oranı

vektörü olarak kullanıldığında tek tür çokgenlerin diğer çokgen türlerinin öğrenimine yaptığı başarımlar test edilmiştir. Şekil 13'te ise **ŞekilBağ** öznelikleri ile öğrenme gerçekleştirildiği zaman elde edilen şekil bazındaki başarımlar gözlemlenmektedir.

## VI. SONUÇ

Bu çalışmada, şekil bağlamı özneliklerinin, şekli tanımlamada ve eylem-etki tahminindeki başarımlarını artırıcı etkisi gösterilmiştir. Sadece kuvvet uygulama pozisyonu bilgisini kullanmanın eylem-etki tahmininde yeteri kadar isabetli sonuçlar vermediği, fakat çalışmamızda önerdiğimiz **ŞekilBağ** yöntemi ile eylem-etki tahmininde belirgin gelişmeler yaşandığı, ve öğrenme modelimizin destek kenarlarını tahmin etmede istikrarlı sonuçlar üretebildiği gözlemlenmiştir. Sistemimizin, cisimlerin ağırlık merkezlerine ait bilgiler kullanılmadan da cisimlerin fiziksel özellikleri ile ilgili istikrarlı tahminler yapabildiği görülmüştür. Ayrıca sekizgen kullanarak eğitilen sınıflandırıcıların üçgen yada diğer cisimleri kaldırmakta başarılı tahmin sonuçları ortaya çıkardığı da gözlemlenmiştir.

## TEŞEKKÜR

Bu çalışma TÜBİTAK BİDEB 2232 Yurda Dönüş Araştırma Burs Programı'nın 117C016 numaralı projesi, Avrupa Komisyonu Ufuk 2020 Programı'nın 731761 numaralı

IMAGINE projesi ve Bogazici Araştırma Fonu Startup projesi 12022 tarafından kısmi olarak desteklenmiştir.

## KAYNAKÇA

- [1] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997.
- [2] L. R. Rabiner, "Readings in speech recognition," A. Waibel and K.-F. Lee, Eds. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1990, ch. A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition, pp. 267–296.
- [3] S. Belongie, J. Malik, and J. Puzicha, "Shape context: A new descriptor for shape matching and object recognition," in *Advances in Neural Information Processing Systems 13*, T. K. Leen, T. G. Dietterich, and V. Tresp, Eds. MIT Press, 2001, pp. 831–837.
- [4] S. Belongie and J. Malik, "Matching with shape contexts," in *2000 Proceedings Workshop on Content-based Access of Image and Video Libraries*, 2000, pp. 20–26.
- [5] S. Belongie, J. Malik, and J. Puzicha, "Shape matching and object recognition using shape contexts," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 4, pp. 509–522, Apr 2002.
- [6] J. Bohg and D. Kragic, "Grasping familiar objects using shape context," in *2009 International Conference on Advanced Robotics*, June 2009, pp. 1–6.
- [7] M. F. E. Rohmer, S. P. N. Singh, "V-rep: a versatile and scalable robot simulation framework," in *Proc. of The International Conference on Intelligent Robots and Systems (IROS)*, 2013.
- [8] "Matlab machine learning toolbox," 2017, the MathWorks, Natick, MA, USA.