

Laboratuvar Hayvanlarının Davranışlarının Görü Tabanlı Çözümlemesi: 3 Boyutlu Gradyan Tabanlı Bir Yaklaşım

Vision Based Behavior Analysis of Laboratory Animals: A 3D Gradient Based Approach

Selçuk Sandıkcı¹, Pınar Duygulu Şahin², A.Bülent Özgüler³

¹Aselsan A.Ş., Mikroelektronik Güdüm ve Elektro-Optik Grubu, ANKARA

²Bilkent Üniversitesi, Mühendislik Fakültesi, Bilgisayar Müh. Bölümü, ANKARA

³Bahçeşehir Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Müh. Bölümü, İSTANBUL

ssandik@mgeo.aselsan.com.tr¹, duygulu@cs.bilkent.edu.tr², bulent.ozguler@bahcesehir.edu.tr³

Özetçe

Farmakolojik deneylerde psikoterapik ilaçların etkisi altındaki laboratuvar farelerinin davranış örüntüsü ilacın etkileri açısından önemli ipuçlarına sahiptir. Laboratuvar farelerinin davranış analizini video işleme yoluyla gerçekleştirmek hem zaman hem de iş gücü tasarrufu sağlamaktadır. Bu çalışmada daha önce insan davranışlarını tanımak için kullanılmış bir yöntem laboratuvar faresi durumuna uyarlanmıştır. Yöntem 3 boyutlu uzay-zaman hacimlerinden çıkarılan uzaysal-zamansal gradyanların histogramlarını çok boyutlu istatistiksel dağılımlara oturtmak ve dağılımlar arasındaki uzaklığı dikkate alarak sınıflandırmak üzerine kuruludur. Bu çalışmada yöntem, ortak bir fare videosu veri kümesi üzerinde denenmiş, literatürdeki diğer yöntemlerle karşılaştırılmış ve başarılı olduğu görülmüştür.

Abstract

In pharmacological experiments behavior pattern of laboratory mice, which are under the influence of psychotherapeutic drugs, reveals important clues about effects of the drug. Behavior analysis of laboratory mice by video processing saves both time and labor. In this work a method which was previously used to recognize human behaviors is adapted to laboratory mice case. Method is based on fitting histograms of spatio-temporal gradients extracted from 3D space-time volumes to multidimensional statistical distributions and classifying according to distances between the distributions. In this work the method is tested on a common mice video dataset, compared to other methods in the literature and found to be successful.

1. Giriş

Farmakolojik deneylerde farelerin ilacın etkisi altında olduğu süre boyunca ortaya koyduğu davranış örüntüsü ilacın etkileri açısından oldukça zengin belirtilere sahiptir. Zerk edilen psikoterapik ilacın etkilerinin ortaya çıkarılması için fare, ilacın etkileri geçene kadar gözlenmeli ve davranışları nesnel ve ölçülebilir bir şekilde kaydedilmelidir. Günümüzde farmakolojik deneyler video kaydı altına alındıktan sonra insan tarafından gözlenmekte ve davranışları elle analiz

edilmektedir. İstatistiksel doğruluk ve tutarlılık için deneylerin binlerce fare üzerinde defalarca yapıldığı düşünülürse bilgisayarla görme tabanlı otomatik davranış analizi yapabilen bir sistem hem zaman hem de işgücünden oldukça tasarruf sağlayacaktır. Ayrıca böyle bir sistem insan gözlemleyicilere kıyasla daha nesnel sonuçlar üretecektir.

Literatürdeki davranış analizi yöntemlerinin birçoğu insan davranışlarına odaklanmıştır (genel bir sormaca için [1]'e bakınız), oysa bu yöntemler birçok sebepten dolayı fare davranış analizi için uygun değildir [2]. Öncelikle fare vücudu biçim açısından oldukça bozulabilir bir yapıya sahip olduğu için vücudu bir şablona ya da iskelete oturtmak her zaman mümkün olmayabilir. Ayırt edilebilir ve takip edilebilir vücut uzuvları sadece gözler, kulaklar ve kuyruktan ibarettir. Ayrıca farenin ön ve arka ayakları vücuduna oranla küçüktür ve vücudun diğer uzuvları tarafından örtülebilir. Bunun yanında bazı fare hareketleri oldukça yüksek hızda gerçekleşmektedir. Tüm bu sebeplerden dolayı örtüşmenin olmaması, vücut duruşunun hareket esnasında az değişmesi veya hiç değişmemesi gibi varsayımlar fare durumunda geçersizdir.

Literatürde davranış analizi için yukarıdan aşağıya ve tabandan tepeye yöntemler mevcuttur. Yukarıdan aşağıya yöntemlerde, davranış analizi yapılacak olan canlının vücut yapısı bir modele oturtularak imge serisi boyunca modelin parametrelerinin değişimi gözlenerek çözümleme yapılır [3]. Fare vücudu yüksek derecede bozulabilir 3 boyutlu bir nesne olduğu için model oturtma yaklaşımı fare davranışlarının analizinde işe yaramayacaktır [4]. Tabandan tepeye yöntemlerde ise ham veriden çıkartılan düşük seviye öznitelikler irdelenerek davranış analizi yapılmaya çalışılır. Dollar vd. [5] video verisinden çıkarttıkları seyrek uzamsal-zamansal ilgi (interest) noktalarının uzay-zaman komşuluğundaki pencerelemiş verinin (küçük) davranış analizi için yeterli olacağını varsaymışlardır. Eğitim veri kümesinden çıkarttıkları küçük ilkörneğini kullanarak oluşturdukları alfabenin yardımıyla her bir test videosunu küçük tiplerinin histogramı şeklinde ifade etmişlerdir. Jhuang vd. [6] beyindeki biyolojik hareket analizinin yapısından esinlenerek oluşturdukları hiyerarşik uzamsal-zamansal öznitelik sezicileri insan ve fare hareketinin tanınmasında kullanmışlardır. Xue ve Henderson [7] elipsoidlerle oluşturdukları yapay fare videolarında Temel Davranış Birimleri'ni bölütleme için, çıkardıkları uzamsal-zamansal

öznitelikleri kullanarak ilginlik çizgeleri çatmışlardır. İlginlik çizgelerinden Tekil Değer Ayrışımı kullanarak Temel Davranış Birimlerini bölütlemişlerdir. Bunların dışında literatürde laboratuvar hayvanlarını takip etmek için optik akış, aktif çevritler, çevrit ve öbek (blob) izleyiciler kullanılmıştır [4, 8, 9].

Bu bildiride, yukarıda bahsedilen otomatik davranış analiz sistemine bir ön çalışma olarak, ilaç ile uyarılmamış naif durumdaki farenin davranış analizi gerçekleştirilmiştir. Bunun için Zelnik-Manor ve Irani'nin [10] insan hareketlerinin sınıflandırılması için sundukları yöntem fare hareketlerinin analizi problemine uygulanmıştır. Yöntemde, davranışların 3 boyutlu uzamsal-zamansal rasgele süreçler olduğu ve bir olasılık yoğunluk fonksiyonu ile ifade edilebileceği varsayılmaktadır. Ham video verisi kullanılarak hesaplanan 3 boyutlu gradyan vektörleri videoya özgü olasılık yoğunluk fonksiyonunun örneklemeleri olarak kabul edilmekte ve söz konusu yoğunluk fonksiyonunun ampirik olarak çatılmasında kullanılmaktadır. Ayrıca davranışlar birden çok zamansal sıklık bileşenine sahiptir. Örneğin "tımar etme (temizlenme)" davranışında farenin ön ayakları yüksek zamansal sıklıkta hareket ederken vücudu daha yavaş hareket etmektedir. Değişik zamansal sıklık bileşenlerini yakalamak için, gradyan hesabı birden çok zamansal ölçekte yapılmaktadır. [10]'un yazarlarına göre iki davranışın benzerliğini ölçmek için ilgili olasılık yoğunluk fonksiyonlarını karşılık gelen zamansal ölçeklerde karşılaştırmak yeterlidir. Bildirinin 2. kısmında önerilen yöntem anlatılmakta, 3. kısımda deneysel sonuçlar verilmekte ve 4. bölümde de sonuçlar değerlendirilmektedir.

2. Önerilen Yöntem

Davranışların uzamsal-zamansal rasgele süreçler olduğu ve ilgili uzay-zaman hacminden çıkarılan gradyan vektörlerinin bu süreçlerin örneklemeleri olduğu kabul edilmektedir. Verilmiş bir test videosunu sınıflandırmak için öncelikle tüm videonun çoklu zaman ölçeklerinde uzamsal-zamansal gradyanları hesaplanmıştır. Daha sonra gradyan vektörlerinin mutlak değeri alınmış ve büyüklükleri 1 olacak şekilde düzelenmiştir. Mutlak değeri alınmış ve düzelenmiş gradyan vektörlerini bir uzamsal-zamansal rasgele süreç oturtmak için evrensel histogramları alınmıştır. İki videoyu karşılaştırmak için histogramlar arasındaki χ^2 (Chi-square) uzaklığına bakılmıştır. Sınıflandırma için en yakın komşu birini-dışla (leave-one-out) sınıflandırma yöntemi kullanılmıştır.

2.1. Zamansal Video Piramidi Çatımı

Verilen bir videonun değişik zamansal ölçeklerde gradyan hesabını yapmak için zamansal video piramidini oluşturmak gerekmektedir. Piramitteki her bir alt seviyeyi oluşturmak için bir üst seviyedeki video zamansal yumuşatma süzgecinden geçirildikten sonra 2 oranında altörneklenmiştir. Bu çalışmada yumuşatma süzgeci olarak değışintisi 2 olan Gauss süzgeci kullanılmıştır. Zamansal video piramidi çatımı Şekil-1'de gösterilmiştir. Bu çalışmada zamansal video piramidi asil video dahil toplam 3 seviyeden ($L = 3$) oluşmaktadır.

2.2. Gradyan Hesabı ve Düzgelemesi

3 boyutlu bir uzay-zaman hacmi (video) için gradyan hesabı, zamansal video piramidindeki tüm zamansal ölçeklerde yapılmıştır. Gradyan hesabı için aşağıdaki denklem kullanılmıştır.

$$\left(G_x^l, G_y^l, G_t^l \right) = \left(\frac{\partial V^l}{\partial x}, \frac{\partial V^l}{\partial y}, \frac{\partial V^l}{\partial t} \right) \quad (1)$$

burada V^l , l . zamansal ölçekteki 3 boyutlu uzay-zaman hacmidir. Gradyan hesabı sonunda verilmiş bir video için $3 \times L$ adet gradyan kanalı ortaya çıkar.

Sadece zamansal olarak aktif olan uzay-zaman noktalarına ait bilgiyi kullanabilmek ve arkaplana ait bilgiyi atmak için zamansal kanalının büyüklüğü belirli bir eşik değerinin altında olan gradyan vektörleri ihmal edilmiştir. Bu işlem kaba bir önplan-arkaplan bölütlemesine karşılık gelmektedir. Verilmiş 3 gradyan kanalı, (G_x^l, G_y^l, G_t^l) , için zamansal kanalı aşağıdaki eşitsizliği sağlayan gradyan vektörleri ihmal edilir.

$$\left| G_t^l(x, y, t) \right| - \mu_t < k * \sigma_t \quad (2)$$

burada $\left| G_t^l(x, y, t) \right|$, (x, y, t) uzay-zaman noktasındaki l . zamansal ölçekte hesaplanmış gradyan vektörünün zamansal kanalının büyüklüğüdür. μ_t ve σ_t ise zamansal kanalın büyüklüğünün ampirik ortalama ve standart sapma değerleridir. k ise eşik değerini ayarlamak için kullanılan bir sabittir. Burada G_t^l gradyan kanalının büyüklüğü Gauss dağılımına oturtulmuş ve ampirik ortalama $k * \sigma_t$ değerinden daha fazla sapan G_t^l elemanlarının yüksek zamansal değışime sahip olduğu varsayılmıştır.

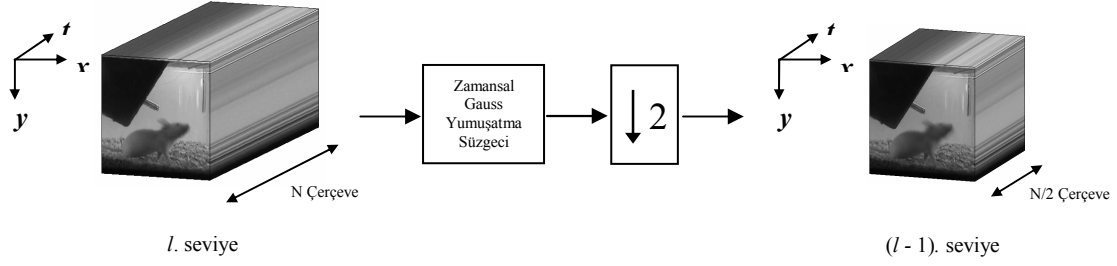
Gradyan vektörleri yerel olarak uzay-zaman hacminin yüzeyine diktir ve vektörlerin yönelimleri uzay-zaman hacminin şeklini karakterize etmektedir. Gradyan vektörlerinin büyüklükleri ise karşıtlık, ışıklandırma gibi ışıkölçümsel özellikleri temsil etmektedir. Büyüklüğün etkisini mümkün olduğunca azaltmak için gradyan vektörleri büyüklükleri 1 olacak şekilde düzelenmiştir. Ayrıca tersyüz edilmiş önplan-arkaplan karşıtlığından ve hareket yönünden bağımsız olmak için düzelenmiş gradyan vektörlerinin mutlak değeri alınmıştır. Düzgeleme işlemi aşağıdaki denklemle ifade edilir.

$$\left(N_x^l, N_y^l, N_t^l \right) = \frac{\left(\left| G_x^l \right|, \left| G_y^l \right|, \left| G_t^l \right| \right)}{\sqrt{\left(G_x^l \right)^2 + \left(G_y^l \right)^2 + \left(G_t^l \right)^2}} \quad (3)$$

burada (G_x^l, G_y^l, G_t^l) zamansal video piramidinin l . seviyesindeki 3 boyutlu uzay-zaman hacminden hesaplanan gradyan vektörleri iken, (N_x^l, N_y^l, N_t^l) ise düzelenmiş gradyan vektörleridir. Gradyan hesabı ve düzgelemesi sonunda her bir uzay-zaman noktası, (x, y, t) , 9 boyutlu bir vektör, $\left[N_x^1(x, y, t) \ N_y^1(x, y, t) \ N_t^1(x, y, t) \ N_x^2(x, y, t) \ \dots \ N_t^3(x, y, t) \right]$ ile ifade edilmiş olur.

2.3. Olasılık Yoğunluk Fonksiyonu Yaklaşıkması

Davranışların 3 boyutlu rasgele süreçler olduğu varsayıldığı için her bir video ile ilişkili bir olasılık yoğunluk fonksiyonu kestirilmelidir. Bu çalışmada olasılık yoğunluk fonksiyonun örneklemeleri 9 boyutlu düzelenmiş gradyan



Şekil 1: Zamansal video piramidinin çatımı

vektörleridir ($N_k^l, l=1,2,3$ ve $k \in \{x, y, t\}$ için). Olasılık yoğunluk fonksiyonunun kestirimi için 9 boyutlu düzgelmiş gradyan vektörlerinin histogramı alınmalıdır. Asıl olasılık yoğunluk fonksiyonunu kestirmek için 9 boyutlu bir histogram çatılmalıdır. Histogramın her boyutunun 128 seleye sahip olduğu varsayılırsa, ortaya çıkan histogramın büyüklüğü 128^9 olacaktır. Bu büyüklük günümüz bilgisayarları için oldukça fazladır. Bunun yerine [10]'un yazarları her bir uzay-zaman noktasıyla ilişkili 9 boyutlu vektörün bileşenlerinin istatistiksel olarak birbirinden bağımsız olduğunu varsaymışlardır. Böylece bir video 9 adet tek boyutlu histogram ile ifade edilebilir.

$$Q = \{h_x^1, h_y^1, h_t^1, h_x^2, h_y^2, h_t^2, h_x^3, h_y^3, h_t^3\} \quad (4)$$

burada Q öznitelik kümesi, h_k^l ise N_k^l düzgelmiş gradyan kanalının histogramıdır.

Yapılan varsayım oldukça güçlü olmasına karşın, uzamsal-zamansal olarak birbirinden çok farklı olan davranışları ayırt etmek için tek boyutlu histogramlar arasındaki farklılık yeterli olacaktır [10]. Fare davranışı analizinde bu varsayımın ne kadar doğru olduğunu ampirik olarak test etmek için veri kümesindeki tüm davranış sınıfları için ortalama öznitelik kümesi (Q) hesaplanmıştır. Şekil-2'de ortalama öznitelik kümesi içindeki ortalama histogramlardan bir kısmı verilmiştir. Bazı histogramlarda davranış sınıflarının ayırt edilebildiği, bazılarında ise birkaç davranış sınıfının çok benzer histogramlara sahip olduğu görülmektedir. (Şekil-2'de verilen histogramlar görselliğin artırılması için Gauss dağılımı kullanılarak yumuşatılmıştır.)


Verilmiş iki videonun benzerlik ölçütü öznitelik kümeleri arasındaki χ^2 uzaklığına bağlıdır. Bu uygulama için χ^2 uzaklığı aşağıdaki denklemle hesaplanmıştır.

$$\chi^2(h_1, h_2) = \frac{1}{3L} \sum_l \sum_k \sum_i \frac{(h_{lk}^1(i) - h_{lk}^2(i))^2}{h_{lk}^1(i) + h_{lk}^2(i)} \quad \begin{matrix} k = \{x, y, t\} \\ l = 1, 2, 3 \\ i = 1, \dots, \text{SELE SAYISI} \end{matrix} \quad (5)$$


3. Deneysel Sonuçlar

Bu çalışmada University of California San Diego Computer Vision grubu tarafından Smart Vivarium projesi için derlenen fare videosu veri kümesi kullanılmıştır [11]. Bu veri kümesinde 5 davranış sınıfı bulunmaktadır. Bunlar sırasıyla su içme, yemek yeme, keşif, kendini tımar etme ve uyumadır. Veri kümesinde 17 su içme, 144 yemek yeme, 183 keşif, 40 kendini tımar etme ve 46 uyuma videosu bulunmaktadır.


2. kısımda anlatılan yöntem uygun bir şekilde her bir videodan 9 adet tek boyutlu histogramlar çıkarılmıştır. Verilen iki video arasındaki uzaklık Denklem-5'te verilen χ^2 uzaklık ölçütüne göre hesaplanmıştır. Verilen bir video sınıflandırılırken veri kümesindeki diğer tüm videolarla karşılaştırılmış ve kendisine en yakın komşunun sınıfına atanmıştır (En yakın komşu birini-dışla sınıflandırma yöntemi).



a) Tüm davranış sınıfları için ortalama h_y^1




b) Tüm davranış sınıfları için ortalama h_t^1



c) Tüm davranış sınıfları için ortalama h_y^2

Şekil 2: Davranış sınıfları için ortalama histogram örnekleri

Yöntem, fare veri kümesine uygulanarak hata matrisleri oluşturulmuştur. Davranış sınıfı tanıma başarımlarının ağırlıklı ortalaması alınarak genel tanıma başarımları (GTB) hesaplanmıştır. Ayrıca histogramlardaki sele sayısının ve eşik değerini ayarlamak için kullanılan k sabitinin tanıma oranlarına etkisi irdelenmiştir. Şekil-3'de sele sayısı ve eşik sabitinin (k) değişik değerleri için GBT verilmiştir. İki parametrenin de GBT'ye etkisinin az olduğu görülmüş, en yüksek GBT'ye sele sayısı 128 ve eşik sabiti 1 iken ulaşılmıştır.



Şekil 3: Histogramlardaki sele sayısı ve k eşik sabitinin genel tanıma başarımına etkisi

Önerilen yöntem, aynı veri kümesi üzerinde sonuç almış literatürdeki diğer çalışmalar ile tanıma başarımları açısından karşılaştırılmıştır. Şekil-4'te, önerilen yöntem ile diğer çalışmalara ait hata matrislerinin karşılaştırılması verilmiştir. Yöntem, [5]'te önerilen yöntemle göre su içme ve uyuma davranışlarının tanınmasında bir miktar iyileşme sağlarken, kendini tımar etme davranışının tanınmasını yaklaşık 2 kat artırmıştır. Yemek yeme ve keşif davranışlarının tanınmasında ise yakın sonuçlara ulaşılmıştır. Genel tanıma başarımında önerilen yöntem, [5]'teki yöntemle göre bir miktar iyileşme sağlamıştır. [5]'te önerilen yöntem bu çalışmada uygulanan yöntem ([10]) ile oldukça kırılmış fare veri kümesi üzerinde karşılaştırılmıştır. Ancak hata matrisleri verilmemiştir, sadece genel tanıma başarımları verilmiştir. Yöntem, [6]'da önerilen yöntemle göre ise keşif, kendini tımar etme ve uyuma davranışlarını daha yüksek oranla tanırken, su içme ve yemek yeme davranışlarında daha düşük tanıma başarımlarına ulaşmıştır. Önerilen yöntem, genel tanıma başarımı açısından [6]'daki yöntemle çok yakın sonuç vermiştir.

4. Çıkarımlar ve Gelecek Çalışmalar

Bu çalışmada, daha önce insan davranışlarının sınıflandırılması için kullanılmış bir yöntem fare durumuna uyarlanmıştır. Yöntemde, 3 boyutlu uzay-zaman hacimlerinin birden çok zamansal ölçekte hesaplanmış olan gradyan vektörlerinin histogramları alınarak fare davranışları sınıflandırılmıştır. Yöntem, ortak bir veri kümesi üzerinde denenmiş ve literatürdeki diğer çalışmalar ile karşılaştırılmıştır. Önerilen yöntem, su içme ve uyuma davranışlarının tanınmasında [5]'te önerilen yöntemden daha yüksek başarı oranlarına ulaşmıştır. Kendini tımar etme davranışının tanınmasında ise çok ciddi iyileşme görülmüştür. Bunların yanında yemek yeme ve keşif davranışlarının sınıflandırılmasında yakın sonuçlar alınmıştır. Yöntem, [6]'daki yöntemle karşılaştırıldığında keşif, kendini tımar etme ve uyuma hareketlerinin tanınmasında iyileşme, su içme ve yemek yeme davranışlarında ise tanıma başarımı düşüklüğü görülmüştür. Genel tanıma başarımı açısından [5]'teki yöntemden daha başarılı sonuçlara ulaşırlarken, [6]'da önerilen yöntemle de çok yakın sonuçlar elde edilmiştir.

Yöntemde kullanılan eşik sabitinin ve histogramlardaki sele sayısının tanıma başarımı üzerindeki etkisi irdelendiğinde, söz konusu parametrelerin genel tanıma başarımını çok etkilemediği, davranışlar arası tanıma başarımını bir miktar etkilediği görülmüştür.

Gelecek çalışmalarda gradyan vektörlerinin yerel yönelim histogramlarının alınması düşünülmektedir. Ayrıca histogramların uzay-zaman hacminin tamamı yerine pencerelenmiş parçalarından çıkarılması ile davranışların altdavranışlar cinsinden ifade edilmesi planlanmaktadır.

su içme	.71	.18	.11	.00	.00
yemek yeme	.03	.80	.13	.03	.01
keşif	.02	.13	.78	.07	.00
tımar etme	.02	.15	.20	.63	.00
uyuma	.00	.00	.00	.00	1.00

a) Önerilen Yöntem
GTB = 0.79

su içme	.64	.00	.24	.06	.06
yemek yeme	.00	.89	.09	.02	.00
keşif	.02	.04	.85	.07	.02
tımar etme	.05	.00	.63	.32	.00
uyuma	.02	.00	.09	.02	.87

b) [5]'te önerilen yöntem
GTB = 0.72

su içme	.94	.04	.02	.00	.00
yemek yeme	.01	.92	.06	.01	.00
keşif	.04	.09	.69	.16	.02
tımar etme	.02	.00	.46	.51	.00
uyuma	.00	.00	.01	.01	.98

c) [6]'da önerilen yöntem GTB = 0.82

Şekil 4: Önerilen yöntemin [5] ve [6] ile karşılaştırılması

5. Kaynakça

- [1] Gavrilu, D. M., "The Visual Analysis of Human Movement: A Survey", *Computer Vision and Image Understanding*, Vol. 73, No. 1, pp. 82-98, January 1999.
- [2] Belongie, S., Branson, K., Dolar, P. and Rabaud, V., "Monitoring Animal Behavior in the Smart Vivarium", presented at Measuring Behavior, Wageningen, The Netherlands, 2005.
- [3] Ramanan, D. and Forsyth, D. A., "Using Coherence to Build Models of Animals", In *Proc. of IEEE ICCV2003*, 2003, Vol.2, pp. 338-345.
- [4] Branson, K., "Tracking Multiple Mice Through Severe Occlusions", Ph.D. dissertation, UCSD, San Diego, California, USA, 2007.
- [5] Dolar, P., Rabaud, V., Cottrell, G. and Belongie, S., "Behavior Recognition via Sparse Spatio-temporal Features", in *VS-PETS2005*, 2005, pp. 65-72.
- [6] Jhuang, H., Serre, T., Wolf, L. and Poggio, T., "A Biologically Inspired System for Action Recognition", in *Proc. of IEEE ICCV2007*, pp. 1-8, 2007.
- [7] Xue, X. and Henderson, T. C., "Video Based Animal Behavior Analysis from Multiple Cameras", in *IEEE Int. Conf. on Multisensor Fusion and Integration for Intelligent Systems*, 2006, pp.335-340.
- [8] Kalafatic, Z., Ribarić, S. and Stanisavljević, V., "A System for Tracking Laboratory Animals Based on Optical Flow and Active Contours", in *Proc. of IEEE ICIAP2001*, 2001, pp. 334-339.
- [9] Zurn, J. B., Hohmann, D., Dworkin, S. I. and Motai, Y., "A Real-Time Rodent Tracking System for Both Light and Dark Cycle Behavior Analysis", in *Proc. of IEEE WACV2005*, 2005, Vol.1, pp. 87-92.
- [10] Zelnik-Manor, L. and Irani, M., "Statistical Analysis of Dynamic Actions", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 28, No. 9, pp. 1530-1535, Sept. 2006.
- [11] <http://vision.ucsd.edu/~pdollar/research/research.html> [Erişim: Dec.24 , 2009]