



# Nesne Tanımda Kullanılan İki Popüler Özniteliğin Karşılaştırılması

Kaan Yasin Kocaman<sup>1</sup>, Celal Onur Gökçe<sup>2\*</sup>

<sup>1</sup> Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Anabilim Dalı, Afyonkarahisar, Türkiye, (ORCID: 0000-0001-5592-8680), [kocaman1881@gmail.com](mailto:kocaman1881@gmail.com)

<sup>2\*</sup> Afyon Kocatepe Üniversitesi, Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, Afyonkarahisar, Türkiye, (ORCID: 0000-0003-3120-7808), [cogokce@aku.edu.tr](mailto:cogokce@aku.edu.tr)

(1st International Conference on Engineering, Natural and Social Sciences ICENSOS 2022, December 20 - 23, 2022)

(DOI: 10.31590/ejosat.1222402)

**ATIF/REFERENCE:** Kocaman, K. Y. & Gökçe, C. O. (2022). Nesne Tanımda Kullanılan İki Popüler Özniteliğin Karşılaştırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (45), 85-87.

## Öz

Bu çalışmada nesne tespitinde ve nesne tanımda literatürde sıklıkla kullanılan iki popüler özniteliğin sınıflandırma performansı tahmini karşılaştırılması yapılmıştır. Birinci öznitelik, orijinal ismiyle Histogram of Oriented Gaussians (HOG), veya Türkçe'deki karşılığı ile Yönlendirilmiş Gradyanların Histogramları, nesne tespitinde ve nesne tanımda en sık kullanılan özniteliklerden birisidir. İkinci öznitelik, orijinal ismiyle Scale Invariant Feature Transform (SIFT), veya Türkçe'deki karşılığı ile Ölçek Değişmez Unsur Dönüşümü, yine nesne tespitinde ve nesne tanımda çok sık kullanılan bir başka özniteliktir. Bu iki öznitelikten birisinin çıktısını herhangi bir sınıflandırıcıya girerek oldukça başarılı sonuçlar almak mümkündür. Peki sınıflandırıcıdan bağımsız olarak hangi öznitelik daha iyi sınıflandırma performansı vermeye yatkındır? Bu çalışmada bu soru cevaplanmaya çalışılmıştır. Veri olarak VisDrone veri setinden araba ve yaya sınıflarından 10'ar tane görüntü kullanılmıştır. Bu iki sınıftan örnek görüntülerin sınıf içi ve sınıflar arası ortalama uzaklıkları hesaplanmış ve sonuçlar raporlanmıştır. Fisher'in Ayırtacına benzer bir mantık ile bir performans metriği hesaplanmıştır. Elde edilen sonuçlardan HOG özniteliğinin sınıflandırıcıdan bağımsız olarak bu örnek veri setinde sınıflandırma için daha uygun bir öznitelik olduğu tahminine varılmıştır.

**Anahtar Kelimeler:** Nesne tanıma, öznitelik, HOG, SIFT, sınıflandırma performansı.

## Comparison of Two Popular Features Used in Object Recognition

### Abstract

In this study performance comparison two popular features used in object recognition is done. First feature, namely Histogram of Oriented Gaussians (HOG) is one of the mostly used features in object detection and object recognition. Second feature, namely Scale Invariant Feature Transform (SIFT) is also widely used in object detection and object recognition. The output of one of these feature extractors is fed to various classifiers and quite successful results are achieved. The question is which one of these two features is more suitable for classification task independent from classifier type. This question is tried to be answered in this study. A subset of VisDrone dataset is used. 10 pictures of cars and 10 pictures of pedestrians are used for testing the feature extractors. Average within class distances and average between class distances are calculated and results are reported. A performance metric similar to Fisher's Discriminant is used to calculate and compare the performances. It is found that HOG feature extractor seems to have slightly better results for classification independent from classifier used.

**Keywords:** Object recognition, feature, HOG, SIFT, classification performance.

## 1. Giriş

Nesne tespiti ve nesne tanıma, yapay görmenin en önemli uygulamalarından [1]. Verilen bir resimde belirli bir sınıfa ait bir nesnenin olup olmadığı sorusu nesne tespiti problemi, yine verilen bir resimdeki nesnenin hangi sınıfa ait olduğu sorusu ise nesne tanıma problemidir [2]. Bu konular yapay görme ile ilgilenen araştırmacıların ilgisini çekmiş ve çok sayıda çalışma yapılmıştır [3-5].

Nesne tespiti, nesne sınıflandırmanın özel bir alt problemi olarak düşünülebilir. Şöyle ki, verilen bir resimdeki nesne belirli bir sınıfa mı ait yoksa diğer herhangi bir sınıfa mı ait sorusu ile nesne tespiti aslında iki sınıflı bir nesne sınıflandırma problemi olarak görülebilir.

Nesne sınıflandırma probleminin çözümlerindeki en önemli safhalardan birisi verilen resimden özneliklerin çıkarılmasıdır. Burada amaç bir yandan verinin boyutunu küçülterek boyutluluk laneti (curse of dimensionality) probleminden kaçınmak, bir yandan da sınıflandırma için en uygun alt uzayı bularak sınıflandırma performansını artırmaktır.

Derin öğrenmede alınan başarılı sonuçlara kadar öznelik çıkarma işlemi araştırmacılar tarafından yıllar süren çalışmalar sonucunda manüel olarak yapılmakta idi. Son yıllarda pek çok alanda liderliği almış olan otomatik öznelik çıkartma işlemi ile manüel öznelik çıkartma işlemleri gitgide popülerliğini yitirmektedir. Yine de yılların birikimi olan başarılı manüel öznelikler de kullanarak hibrit bir yaklaşımla sınıflandırma performansını daha da artırmak mümkündür. Bu bağlamda manüel öznelikler otomatik özneliklere destekleyici alternatifler olmalarını sürdürmektedir.

Bu çalışmada kullanılan ilk manüel öznelik HOG [6] olarak bilinmektedir. HOG öznelik çıkarıcı algoritması şu aşamalardan oluşmaktadır:

- 1) Veri ön işleme: Resim boyutu 2'nin kuvveti olan, örneğin 128x64, büyüklüğe ayarlanır.
- 2) Gradyan hesaplama: x ve y yönlerinde gradyanlar hesaplanır.
- 3) Büyüklük ve oryantasyon hesaplama: Gradyanların büyüklükleri ve yönleri bulunur.
- 4) 8x8'lik hücrelerde gradyan histogramları hesaplama
- 5) Gradyanları 16x16'lık hücrelere normalize etme.

Bu çalışmada kullanılan ikinci manüel öznelik SIFT [7] olarak bilinmektedir. SIFT öznelik çıkarıcı algoritması şu aşamalardan oluşmaktadır:

- 1) Ölçek uzayında maksimum seçme
- 2) Anahtar nokta bulunması
- 3) Oryantasyon atama
- 4) Anahtar nokta tanımlayıcısı.

## 2. Materyal ve Metot

Bu çalışmada VisDrone [8] veri setinden elde edilen 10 araba ve 10 yaya olmak üzere toplam 20 resim kullanılmıştır. Bu resimler aşağıda Şekil 1.'de gösterilmiştir.



Şekil 1. Çalışmada kullanılan 20 resim

Her resim 64x128 piksel boyutundadır. Her bir resim hem HOG hem de SIFT öznelik çıkarıcılarına girilmiştir. Çıkışta alınan öznelik vektörleri birbirleriyle karşılaştırılmıştır. Karşılaştırılma yapılırken uzaklık olarak Öklid uzaklığı kullanılmıştır.

Fisher'in Ayırtıcıya benzer şekilde bir sınıflandırma performansı tahmin edicisi kullanılmıştır. Bu tahmin edicinin formülü aşağıda formül 1'deki gibidir.

$$\text{öznelik kalitesi} = \frac{\text{ortalama(Sınıflar arası uzaklık)}}{\text{ortalama(Sınıf içi uzaklık)}} \quad (1)$$

Dolayısıyla farklı sınıflar arasındaki uzaklık arttıkça veya aynı sınıflar arasındaki uzaklık azaldıkça öznelik kalitesi artmaktadır. Bu da tahmin edilebildiği gibi daha kolay sınıflandırılmayla sonuçlanmaktadır.

## 3. Araştırma Sonuçları ve Tartışma

Yapılan çalışmada HOG özneliğinin SIFT özneliğine göre bir miktar daha başarılı olması tahmini çıkarılmıştır. Hesaplamalara göre HOG özneliğinin öznelik kalitesi 1.04, SIFT özneliğinin öznelik kalitesi 1.01 olarak bulunmuştur. Buna göre HOG öznelik kalitesi SIFT öznelik kalitesinden yaklaşık olarak %3 daha iyi olarak hesaplanmıştır.

HOG özneliğinin SIFT özneliğine göre %3 civarı bir üstünlük sergilemesi bütün sınıflandırıcılarda daha başarılı olacağı anlamına gelmez. Öznelik kalitesi hesaplanırken veriler arasındaki uzaklık esas alınmıştır. Özellikle yapay sinir ağları gibi doğrusal olmayan sınıflandırıcılarda sınıflandırma performansı, veriler arası uzaklıktan daha çok verilerin uzayda nasıl dizildiğine bağlıdır. Dolayısıyla bazı topolojilerde birbirlerine yakın olan sınıflar daha kolay ayırt edilebilir. Fakat yine de elde edilen bulgular genel olarak özneliklerin sınıflandırma performansı hakkında bir fikir vermektedir.

## 4. Sonuç

HOG öznelik çıkarma algoritması ile SIFT öznelik çıkarma algoritması karşılaştırılmış ve sınıflandırıcıdan bağımsız olarak sınıflandırma performansı tahmin edilmeye çalışılmıştır. HOG öznelik çıkarma algoritması önerilen performans metriği açısından %3 kadar daha üstün çıkmıştır. İlerideki çalışmalarda daha farklı öznelik çıkarıcıları, daha kapsamlı verilerle ve daha somut sınıflandırıcılarla denenmesi hedeflenmektedir.

## **Kaynakça**

- [1] Zaidi, S. S. A., Ansari, M. S., Aslam, A., Kanwal, N., Asghar, M., & Lee, B. (2022). A survey of modern deep learning based object detection models. *Digital Signal Processing*, 103514.
- [2] Hart, P. E., Stork, D. G., & Duda, R. O. (2000). *Pattern classification*. Hoboken: Wiley.
- [3] K. Gauen, R. Dailey, J. Laiman, Y. Zi, N. Asokan, Y.-H. Lu, G.K. Thiruvathukal, M.-L. Shyu, S.-C. Chen, Comparison of visual datasets for machine learning, in: 2017 IEEE International Conference on Information Reuse and Integration (IRI), 2017, pp.346–355.
- [4] W. Zhiqiang, L. Jun, A review of object detection based on convolutional neural network, in: 2017 36th Chinese Control Conference (CCC), 2017, pp.11104–11109.
- [5] J. Huang, V. Rathod, C. Sun, M. Zhu, A. Korattikara, A. Fathi, I. Fischer, Z. Wo-jna, Y. Song, S. Guadarrama, K. Murphy, Speed/accuracy trade-offs for modern convolutional object detectors, arXiv:1611.10012, 2017.
- [6] N. Dalal, B. Triggs, Histograms of oriented gradients for human detection, in: 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05), vol. 1, ISSN1063-6919, 2005-06, pp.886–893.
- [7] Lowe, D. G. (1999, September). Object recognition from local scale-invariant features. In *Proceedings of the seventh IEEE international conference on computer vision (Vol. 2, pp. 1150-1157)*. IEEE.
- [8] Zhu, P., Wen, L., Du, D., Bian, X., Ling, H., Hu, Q., ... & Song, Z. (2018). Visdrone-det2018: The vision meets drone object detection in image challenge results. In *Proceedings of the European Conference on Computer Vision (ECCV) Workshops (pp. 0-0)*.