

## Gauss Karışım Modeli ve Genlik Spektrumu Öznitelikleri ile Sesteki Gizli Bilginin Sezimlenmesi

Cemal HANILÇI

Bursa Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Bursa, Türkiye.  
cemal.hanilci@btu.edu.tr

(Geliş/Received: 13.02.2017; Kabul/Accepted:28.04.2017)

### Özet

Son yıllarda, dijital verilerin kullanımının önemli ölçüde artması ile dijital ortam verilerinin gizli haberleşme için kullanılması oldukça yaygınlaşmıştır. Bununla birlikte, dijital verilerdeki gizli mesajın tespiti (steganaliz) çalışmaları da aynı ölçüde önem kazanmaktadır. Bu çalışmanın amacı, literatürde konuşma işleme uygulamalarında yaygın olarak kullanılan Gauss karışım modeli (GKM) sınıflandırıcısı ve Mel-frekansı kepstrem katsayıları (MFKK) özniteliklerini kullanarak dijital ses (konuşma) dosyalarındaki gizli mesaj varlığını belirlemektir. 4380 adet konuşma sinyalinin kullanıldığı deneysel çalışmalardan MFKK öznitelikleri ve GKM sınıflandırıcısının gizli mesaj tespiti probleminde yaygın olarak kullanılan destek vektör makineleri (DVM) sınıflandırıcısından daha iyi sonuç verdiği görülmektedir.

**Anahtar Kelimeler:** Konuşma steganaliz, Steganografi, Gauss karışım modeli, Mel-Frekansı kepstrem katsayıları.

## Audio Steganalysis Using Gaussian Mixture Models and Magnitude Spectrum Features

### Abstract

Recently, increased popularity of using digital data has led to use digital medium for covert communication. On the other hand, steganalysis, detecting the presence of secret messages, has gained great interests. In this work, we aim to develop an audio steganalysis framework using Gaussian mixture model (GMM), widely used classification technique in speech processing applications and Mel-frequency cepstral coefficients (MFCC) features. Experiments conducted on a dataset consisting of 4380 audio signals suggest that GMM classifiers with MFCC features yield promising and encouraging results on audio steganalysis and GMM shows better performance than widely used support vector machines (SVM) classifier.

**Keywords:** Audio steganalysis, Steganography, Gaussian mixture model, Mel-frequency cepstral coefficients.

### 1. Giriş

Dijital verilerin (ses, resim, video) kullanımı internetin yaygınlaşması ile daha da popüler hale gelmiştir. Bununla birlikte bu verilerin gizli haberleşme amacı ile kullanımı da aynı ölçüde yaygınlaşmıştır [1]. Steganografi, bir dijital veri içerisine gizli mesaj veya bilgiler saklayarak, alıcıdan başka kimsenin farkedemeyeceği şekilde gönderme sanatıdır [2]. Steganaliz ise,

steganografi yöntemleri ile dijital veriler içerisine gizlenmiş olan gizli mesajın tespit edilmesidir. Steganalizin amacı mesajın içeriğinden çok mesajın varlığının tespit edilmesidir [3].

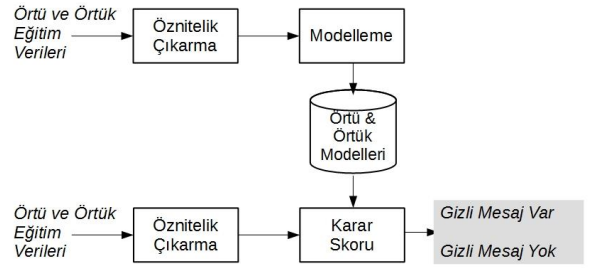
Steganaliz temel olarak hedefli ve hedefsiz olmak üzere iki gruba ayrılır [3]. Hedefli steganaliz yöntemleri, belirli bir veri gizleme yöntemi ile gizlenmiş mesajların varlığının tespit

edilmesini amaçlarken, hedefsiz steganaliz ise, veri gizleme yönteminden bağımsız olarak gizli mesajın tespit edilmesi işlemidir [4]. Dolayısı ile steganaliz, bir dijital verinin örtü (gizli mesaj/bilgi içermeyen) veya örtük (gizli mesaj/bilgi içeren) şeklinde ikiye ayrılması olarak tanımlanabilir. Bu bağlamda steganaliz, aslında test edilecek dijital veriden elde edilen öznitelikler ile eğitim aşamasında oluşturulan modeller karşılaştırma işlemine tabii tutularak bir karar skoru hesaplanır. Karar skoru belirli bir eşik değerden yüksek ise dijital veride gizli mesajın olduğu kararı verilir. Aksi durumda ise gizli mesajın olmadığı kararı verilir. Genel steganaliz sisteminin adımları Şekil 1’de gösterilmiştir.

Literatürde yer alan steganaliz çalışmaları daha çok dijital resim (imge) dosyalarındaki gizli mesajın tespitine yoğunlaşmış olup, ses dosyaları kullanılarak yapılan steganaliz çalışmaları oldukça sınırlı sayıdadır. Konuşma sinyallerindeki gizli mesajın tespiti konusunda bilinen en eski çalışmalardan biri Özer ve diğ. [5] tarafından gerçekleştirilmiştir. Özer ve diğ. [5], konuşmadaki gizli mesajın tespiti için ses kalite ölçütlerini öznitelik olarak kullanmış ve bu öznitelikleri destek vektör makineleri (DVM) sınıflandırıcısı [6] ve doğrusal regresyon sınıflandırıcısı yardımı ile sınıflandırmışlardır. Elde edilen bulgulardan DVM sınıflandırıcısının ses dosyalarındaki gizli mesajın tespitinde regresyon sınıflandırıcısına nazaran daha iyi sonuç verdiğini göstermiştir. Bir başka çalışmada Johnson ve diğ. [7] tarafından ses sinyalinin spektrogramındaki düzgünlükten faydalanılarak elde edilen öznitelikler DVM sınıflandırıcısı kullanılarak gizli mesaj tespiti çalışmaları yapılmıştır. Ru ve diğ. [8] ayrık Wavelet dönüşümü ve doğrusal öngörülü kodlama yöntemleri ile elde edilmiş öznitelikleri DVM sınıflandırıcısı ile kullanarak ses sinyallerinden gizli mesaj varlığının tespiti problemini incelemişlerdir. Fu ve diğ. [9] zaman frekans histogramlarının ilk üç momentini ve bunların wavelet dönüşümünden elde edilen öznitelikleri kullanarak ses sinyallerindeki gizli mesajın tespit edilmesini çalışmışlardır.

Bunun gibi daha birçok çalışmada genel olarak DVM sınıflandırıcısı [6] ve genellikle zaman tanım bölgesi analizinden elde edilen öznitelikler ses dosyalarındaki gizli mesaj

iki sınıflı bir örüntü tanıma problemidir ve genel olarak eğitim ve test olmak üzere iki aşamadan oluşmaktadır. Eğitim aşamasında gizli mesaj içeren (örtük) ve içermeyen (örtü) dijital verilerden öznitelikler çıkarılır ve her bir sınıfa ait (örtü ve örtük sınıfları) birer model eğitilir. Test aşamasında ise gizli mesajın var olup olmadığı varlığının tespit edilmesi problemi incelenmiştir. Bu çalışmada, konuşma işlemede yaygın bir şekilde kullanılan ve ses sinyalinin genlik spektrumundan elde edilen Mel-frekansı keppstrum katsayıları (MFKK) özniteliklerinin, yine konuşmacı tanıma, duygu durumu tanıma gibi birçok ses işleme tabanlı sınıflandırma problemlerinde yaygın olarak kullanılan Gauss karışım modeli (GKM) sınıflandırıcısı ile ses sinyallerindeki gizli mesaj varlığının tespit edilmesi problemini incelenmektedir.



Şekil 1. Genel steganaliz adımları

## 2. Gauss Karışım Modeli ile Steganaliz

Steganaliz, bir ses dosyasında gizli mesajın varlığının tespiti, daha önce de belirtildiği gibi aslında iki sınıflı bir örüntü tanıma problemidir. Bu problem aslında iki hipotezden oluşan bir hipotez testi olarak tanımlanabilir. Bir  $s$  ses sinyali için bu hipotezler:

- $H_0$  :  $s$  sinyalinde gizli mesaj yoktur
- $H_1$  :  $s$  sinyalinde gizli mesaj vardır.

şeklinde tanımlanabilir. Dolayısı ile bu iki hipotez arasında karar verme işlemi olabilirlik oran testi ile gerçekleştirilebilir ve logaritmik olabilirlik oran skoru

$$\Lambda(s) = \log p(s|H_0) - \log p(s|H_1) \quad (1)$$

şeklinde hesaplanır.  $\log p(s|H_0)$  ve  $\log p(s|H_1)$  olasılıklarını hesaplayabilmek için,  $H_0$  ve  $H_1$  hipotezlerini temsil edecek istatistiksel modellerin hesaplanması gerekir. Bu amaçla GKM yöntemi [10, 11] kullanılabilir.

GKM ile her bir sınıf (örtü ve örtük sınıfları)  $M$  adet ağırlıklandırılmış Gauss yoğunluk fonksiyonunun toplamı olarak

$$p(\mathbf{x}|\lambda) = \sum_{i=1}^M w_i p_i(\mathbf{x}) \quad (2)$$

şeklinde temsil edilir [10,11]. Burada  $w_i$ ,  $i$ . Gauss bileşeninin ağırlığı,  $p_i(\mathbf{x})$  ortalaması  $\boldsymbol{\mu}_i$ , kovaryans matrisi  $\boldsymbol{\Sigma}_i$  olan çok değişkenli Gauss yoğunluk fonksiyonudur. Bütün bir GKM,  $\lambda = \{w_i, \boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i\}_{i=1}^M$  şeklinde temsil edilir.

Steganaliz için GKM kullanılırken, örtü ve örtük sınıflarına ait eğitim öznitelik vektörleri kullanılarak, her bir sınıf için  $\lambda_{\text{örtü}}$  ve  $\lambda_{\text{örtük}}$  ile belirtilen iki adet GKM, beklentinin maksimumlaştırılması algoritması ile en büyük olabilirlik kriterine göre eğitilir [10, 11]. Eğitim aşaması, her bir sınıfa ait GKM parametrelerinin (ağırlık, ortalama ve kovaryans) eğitim verilerinden tahmin edilmesi işlemidir.

Test aşamasında ise, bir ses sinyalinde elde edilen öznitelik vektörleri  $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_T\}$  ve örtü ve örtük sınıf GKM modelleri kullanılarak karar skoru şu şekilde hesaplanır:

$$L(\mathbf{Y}) = L(\mathbf{Y}|\lambda_{\text{örtü}}) - L(\mathbf{Y}|\lambda_{\text{örtük}}) \quad (3)$$

Burada  $L(\mathbf{Y}|\lambda)$  logaritmik olabilirlik skoru olup şu şekilde hesaplanır:

$$L(\mathbf{Y}|\lambda_{\text{örtü}}) = \frac{1}{T} \sum_{t=1}^T \log p(\mathbf{y}_t|\lambda) \quad (4)$$

### 3. Materyal ve Metot

Deneysel çalışmalarda, konuşma ve konuşmacı tanıma çalışmalarında yaygın olarak kullanılan TIMIT<sup>1</sup> veritabanında yer alan toplam 438 farklı erkek konuşmacıya ait toplam 4380 adet örtü ses sinyalleri kullanılmıştır. Her konuşmacı iki tanesi bütün konuşmacılar için ortak olan toplam 10 adet yaklaşık üç saniye uzunluğundaki cümleyi söylemiştir. Cinsiyet farklılıklarından kaynaklanabilecek yanılmaları ortadan kaldırmak amacı ile sadece erkek konuşmacılara ait sesler kullanılmıştır. Örtü ses sinyallerine *steghide* [12] veri gizleme yöntemi ile rasgele üretilmiş metin dosyaları gizlenerek 4380 adet örtük ses sinyali elde edilmiştir. Örtü ve Örtük sınıflarının her birine ait 1000 ses sinyali her bir sınıf için GKM eğitiminde kullanılmıştır.

Geri kalan 3380 sinyal ise test aşamasında kullanılmıştır. Dolayısı ile test aşamasında toplam 6760 adet sınıma (3380 örtü ve 3380 örtük sınıma) yapılmıştır. Destek vektör makineleri (DVM) ile yapılan deneylerde de benzer şekilde 1000'er adet örtü ve örtük ses sinyalleri eğitim geri kalan 6760 adet ses sinyali ise test aşamasında kullanılmıştır.

Steganaliz deneylerinde, ses işlemede sıklıkla kullanılan mel-frekans kepekstrum katsayıları (MFKK) öznitelikleri kullanılmıştır [13]. MFKK öznitelikleri bir ses sinyalinin 10 ms'lik kısımları örtüşen 20 ms uzunluğunda çerçevelere bölünmesi ile elde edilir. Hamming pencere ile pencerelenen ses sinyallerinin ayrık Fourier dönüşümü alınarak genlik spektrumu hesaplanır. Her bir çerçevenin genlik spektrumu, toplam 27 adet üçgen süzgeçten oluşan ve Mel-ölçeğinde yerleştirilmiş üçgen süzgeç takımından geçirilir. Logaritmik süzgeç çıkışlarının ayrık Cosinüs dönüşümü alınarak her bir çerçeveden toplam 12 adet MFKK öznitelikleri elde edilir.

GKM sınıflandırıcısı ile yapılan deneylerde, örtü ve örtük sınıfların her biri için toplam 256 adet Gauss bileşeninden oluşan modeller toplam 10 EM iterasyonu ile eğitilmiştir. DVM deneylerinde ise örtü ve örtük sınıflara ait eğitim MFKK öznitelikleri LibSVM [14] programı ile doğrusal çekirdek fonksiyonu ile eğitilmiştir.

Steganaliz deneylerinde başarımlık kriteri olarak duyarlılık (sensitivity-SE), özgüllük (specificity-SP) ve doğruluk (accuracy-ACC) kriterleri kullanılmıştır [4]. Bu kriterler hesaplanırken şu parametreler kullanılır:

- Gerçek Negatif (True Negative - DN) : Örtü olarak karar verilen toplam örtü sinyali sayısı
- Gerçek Pozitif (True Positive - GP) : Örtük olarak karar verilen toplam örtük sinyali sayısı
- Yanlış Negatif (False Negative - YN) : Örtü olarak karar verilen toplam örtük sinyali sayısı
- Yanlış Pozitif (False Positive - YP) : Örtük olarak karar verilen toplam örtü sinyali sayısı

Bu parametreler ile duyarlılık (SE)

<sup>1</sup> <https://catalog.ldc.upenn.edu/ldc93s1>

$$SE = \frac{GP}{GP + YN} \times 100 \quad (5)$$

$$Özgüllük (SP) \\ SP = \frac{GN}{GN + YP} \times 100 \quad (6)$$

$$Doğruluk (ACC) \text{ ise} \\ ACC = \frac{GN + GP}{GN + YP + GP + YN} \times 100 \quad (7)$$

şeklinde hesaplanır.

#### 4. Bulgular

GKM ve DVM ile elde edilen steganaliz sonuçları Tablo I de gösterilmiştir. Tabloda iki sınıflandırıcı ile elde edilen sonuçlardan en iyi olan değerler kalın font ile gösterilmiştir. Tablodan görüldüğü üzere, GKM sınıflandırıcısı ile her üç başarımlık kriteri açısından da DVM sınıflandırıcısından daha iyi steganaliz sonuçları elde edilmiştir. GKM sınıflandırma yöntemi DVM sınıflandırıcısından duyarlılık ve doğruluk kriterleri açısından sırası ile %21 ve %11 ve daha iyi steganaliz başarımlık elde edilmiştir. Fakat özgüllük kriteri açısından, DVM sınıflandırıcısı ile GKM sınıflandırıcıları oldukça yakın performans göstermektedir.

Tablo 1’de verilen sonuçlardan da görüldüğü gibi, örtük seslerin tanınma oranı, örtü seslerin tanınma oranına nazaran daha yüksektir. Bu sonuca duyarlılık kriteri baz alınarak ulaşılmaktadır. Çünkü duyarlılık kriteri, eşitlik (5) de görüldüğü gibi sadece örtük seslerin tanınması kriteridir.

**Tablo 1.** GKM ve DVM sınıflandırıcıları ile steganaliz sonuçları

Kriter	GKM	DVM
SE (%)	<b>52,72</b>	43,52
SP (%)	<b>38,87</b>	38,96
ACC (%)	<b>45,79</b>	41,24

Özgüllük kriteri ise, örtü seslerin tanınması kriterine karşılık gelmektedir. Bu gerçekten yola çıkarak örtük seslerin (gizli mesaj içeren), örtü seslere (gizli mesaj içermeyen) nazaran her iki sınıflandırma yöntemi için daha yüksek bir başarımlık tespit edildiği görülmektedir. Doğruluk kriteri ise hem örtük hem de örtü seslerin tanınma oranları ile hesaplanmaktadır ve her iki bilgiyi de içermektedir. GKM yöntemi, duyarlılık ve

doğruluk kriterleri için DVM yönteminden daha iyi performans göstermektedir.

Tablo 1 de elde edilen sonuçlar daha önce de belirtildiği gibi örtü ve örtük ses dosyalarından rasgele seçilen 1000'er adet eğitim verisi ile elde edilmiştir. GKM sınıflandırıcısının steganaliz performansının genelleştirilebilirliğini kontrol etmek amacı ile örtü ve örtük sınıflarına ait ses dosyalarından eğitim için kullanılan 1000'er adet ses dosyasının rasgele seçilmesi işlemi 25 kez tekrarlanmıştır. Steganaliz deneylerinin 25 kez tekrarlanması sonucunda elde edilen başarımların ortalaması ve bu başarımların standart sapmaları Tablo 2 de verilmiştir. Görüldüğü gibi GKM sınıflandırıcısı ile DVM sınıflandırıcısından çok daha yüksek steganaliz başarımları elde edilmektedir. Bu bulgular da steganaliz için ses işlemede özellikle konuşmacı tanımda yaygın olarak kullanılan GKM sınıflandırıcısının steganaliz için de uygun bir sınıflandırma yöntemi olduğunu göstermektedir. Tablo 1’de elde edilen sonuçlara benzer şekilde, örtük seslerin örtü seslere nazaran daha yüksek başarımlık ile tespit edilebildiği Tablo 2’de de görülmektedir.

**Tablo 2.** Steganaliz deneylerinin 25 kez tekrarlanması ile elde edilen ortalama başarımlar ve standart sapmaları

Kriter	GKM	DVM
SE (%)	<b>46,71 ± 3,68</b>	41,33 ± 1,04
SP (%)	<b>43,85 ± 3,53</b>	40,90 ± 0,94
ACC (%)	<b>45,28 ± 0,46</b>	41,12 ± 0,28

#### 5. Sonuçlar

Bu çalışmada, veri gizleme yöntemi ile gizli mesaj içeren ses dosyalarının tespit edilmesi problemi olan konuşma steganalizi problemi ele alınmıştır. Görüntü steganaliz problemine nazaran daha az çalışmanın yapıldığı konuşma steganalizi için konuşmacı tanıma probleminde yaygın olarak kullanılan Gauss karışım modeli (GKM) sınıflandırıcısının steganaliz problemine kullanılması önerilmiştir. 4380 adet örtü ve steghide veri gizleme algoritması ile oluşturulmuş 4380 adet örtük ses sinyallerinin ve Mel-frekansı kepsstral katsayıların kullanıldığı deneysel çalışmalardan GKM sınıflandırıcısının popüler iki sınıflı sınıflandırma yöntemi olan destek vektör makineleri (DVM) sınıflandırıcısından

daha yüksek başarımlar verdiği görülmüştür. Elde edilen sonuçlardan (Tablo 1 ve Tablo 2), sınıflandırma yönteminden bağımsız olarak örtük seslerin daha kolay bir şekilde tespit edilebildiği görülmüştür.

## 6. Kaynaklar

1. Petitcolas, F. A. P., Anderson, R.J., and Kuhn, M.G. (1999). Information Hiding--A Survey. *Proceedings of the IEEE*, **87(7)**: 1062-1078.
2. Mavel, L.M. (2005). Information Hiding: Steganography and Watermarking. *Optical and Digital Techniques for Information Security*, New York, Springer New York, 113-133.
3. Böhme, R. (2010). Principles of Modern Steganography and Steganalysis. *Information Security and Cryptography*, 11-77.
4. Ghasemzade, H., Khass, T.M. and Arjmandi, M. K. (2016). Audio steganalysis based on reversed psychoacoustic model of human hearing. *Digital Signal Processing*, **51**: 133-141
5. Özer, H., Avcıbaş, İ., Sankur, B. and Memon, N.(2003). Steganalysis of audio based on audio quality metrics. *Electronic Imaging, International Society for Optics and Photonics*.
6. Burges, C. J. C. (1998). A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, **2**: 121-167.
7. Johnson, K.M., Lyu, S. and Farid, H.(2005). Steganalysis of Recorded Speech. *Electronic Imaging, International Society of Optics and Photonics*.
8. Ru, X.-M., Zhang, H.-J. and Huang, X. (2005). Steganalysis of audio: attacking the steghide. *International Conference on Machine Learning and Cybernetics*.
9. Fu, J.-W., Qi, Y.-C. and Yuan, J.-S. (2007). Wavelet domain audio steganalysis based on statistical moments and PCA. *International Conference on Wavelet Analysis and Pattern Recognition (ICWAPR)*.
10. Reynolds, D.A. and Rose, C. R. (1995). Robust Text-Independent Speaker Identification Using Gaussian Mixture Speaker Models. *IEEE Transactions on Speech and Audio Processing*, **3(1)**: 72-83.
11. Reynolds, D.A., Quatieri, T.F., Dunn, R.B. (2000). Speaker Verification Using Adapted Gaussian Mixture Models. *Digital Signal Processing* **10(1-3)**:19-41
12. "Steghide," [Çevrimiçi]. Available: <http://steghide.sourceforge.net/index.php>. [02 Şubat 2017 tarihinde erişilmiştir].
13. Davis, S. B. and Mermelstein, P.(1980). Comparison of parametric representations for monosyllabic word recognition in continuously spoken sentences. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, **28(4)**: 357-366.
14. Chang, C.-C. and Lin, C.J.(2011). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, **2(3)**: 1-27