



ISSN:1306-3111
e-Journal of New World Sciences Academy
2008, Volume: 3, Number: 1
Article Number: A0056

NATURAL AND APPLIED SCIENCES
ELECTRONIC AND COMPUTER ENGINEERING

Received: July 2007
Accepted: December 2007
© 2008 www.newwsa.com

Ayhan Altınörs
Engin Avcı
Zeynep Biçer
University of Firat
aaors@hotmail.com
Elazig-Turkiye

SAYISAL MODÜLASYON TANIMA SİSTEMLERİ İÇİN
BAYES KARAR KURALLARI SINIFLANDIRICISININ KULLANIMI

ÖZET

Bu çalışmada, sayısal modüleli işaretleri sınıflamak üzere bir örüntü tanıma sistemi kullanılmıştır. Bu örüntü tanıma sisteminde, özellik çıkarma için dalgacık dönüşümü ve entropisi yöntemi, sınıflandırma için ise Bayes sınıflandırıcı kullanılmıştır. Bayes sınıflandırıcısının başarımı, kullanılan özellik çıkarım yönteminin sayısal modüleli işaretlerin sınıflandırılmasındaki etkinliğini göstermiştir.

Anahtar Kelimeler: Örüntü Tanıma, Özellik Çıkarma,
Sınıflandırma, Bayes Karar Kuralı

USING OF THE BAYES DECISION RULES CLASSIFIER FOR DIGITAL MODULATION
RECOGNITION SYSTEM

ABSTRACT

In this study, a pattern recognition system was used for the classification of digital modulated signals. In this pattern recognition system, the wavelet transform-entropy methods and Bayes classifier were used for feature extraction and classification. The Succession of Bayes classifier shows activity of used feature extraction method for the classification of digital modulated signals.

Keywords: Pattern Recognition, Feature Extraction,
Classification, Bayes Decision Rules

1. GİRİŞ (INTRODUCTION)

Modülasyon, haberin iletim ortamına verilmeden önce biçiminin değiştirilmesi anlamına gelir. Diğer bir tanıma göre ise, düşük frekanslı haber işaretinin yüksek frekanslı bir taşıyıcı işarete yüklenmesi işlemidir. Haberın modülasyondan önce işgal ettiği banda temel bant, modülasyondan sonra işgal ettiği banda ise geçiş bandı denir. Elektronik haberleşme sistemlerinde modülasyon işlemine başvurulmasının iki temel sebebi vardır [1 ve 2]:

- Haber işaretlerinin doğrudan iletimi, yaklaşık olarak aynı frekanslarda radyo dalgaları meydana getireceği için büyük girişim problemlerine yol açar.
- Çoğu haber işaretleri nispeten düşük frekanslara sahiptir. Öte yandan, antenlerin verimli çalışabilmesi için boyutlarının dalga boyu mertebelerinde olması gerekir. Bu sebeple modülasyon yapılmazsa aşırı derecede büyük antenlerin kullanılması gerekir.

Modülasyon işlemini gerçekleştirmek için iki işarete ihtiyaç vardır; Bunlar bilgi işareti ve taşıyıcı işarettir. Alçak frekanslı bilgi işaretine, modüle eden, modüle edici, modülasyon işareti, gönderilecek işaret, alçak frekanslı (AF) işaret adı da verilir. Yüksek frekanslı taşıyıcı işarete, modüle edilen, RF (Radyo Frekans) işareti, hamal işaret de denilebilir. Modülasyon işleminde modüle eden işaret bilgi işareti, modülasyona uğrayan veya modüle edilen işaret ise taşıyıcı işarettir [2 ve 3].

Modülasyonun çeşitli yararları vardır. Bunları şöyle sıralayabiliriz [1];

- Yayılımı kolaylaştırır. Elektromanyetik alanlar yaklaşık hızında yayıldığı ve uygun şartlarda dağ tepe çukur gibi doğal engelleri kolaylıkla aşarlar. Uzayda ise uygun bir antenle çok uzaklara gidebilir.
- Gürültü ve bozulmanın olumsuz etkilerini azaltır.
- Kanal ayrımı sağlar. Yani modülasyon sayesinde aynı iletim hattında birden çok bilgi yollama olanağı sağlar.
- Çevresel faktörlerin ortaya çıkardığı pek çok sınırlayıcı etkiyi ortadan kaldırır.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Son yıllarda sayısal modülasyon tanıma alanında önemli çalışmalar yapılmıştır [3 ve 4]. Bu makalede sayısal modülasyon tanıma alanında Dalgacık Dönüşümü Entropisi-Bayes Sınıflandırıcı (DDEBS) tabanlı bir yöntem kullanılarak bir sayısal modülasyon tanıma uygulaması gerçekleştirilmiştir. Bunun için sırasıyla 2. Bölüm'de örüntü tanıma kavramına değinilecek, 3. Bölümde geliştirilen yöntem üzerinde durulacaktır, 4. Bölümde ise Bayes karar kuralı kullanılarak gerçekleştirilen sınıflandırma çalışmasının basamakları tanıtılacak ve 5. Bölümde ise bu uygulama çalışmasından elde edilen sonuçlar irdelenecektir.


3. ÖRÜNTÜ TANIMA (PATTERN RECOGNITION)

Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Gerçek dünyadaki bu örüntüler, genellikle ilgilenilen verilerin nicel tanımlama şekilleridir [5 ve 6]. Örüntü tanıma, insanların çeşitli ses, görüntü ve benzeri tüm örüntülerin biçimsel şekillerinden çıkardıkları dilsel şekillendirmedi. Aslında, örüntü tanıma bilimin, mühendisliğin ve günlük hayatın geniş bir alanındaki etkinlikleri kapsamaktadır. Örüntü tanıma uygulamalarını insanların yaşantısında da görebiliriz: hava değişiminin algılanması, binlerce çiçek, bitki, hayvan türünü tanımlama, kitap okuma, yüz ve ses tanıma gibi bulanık sınırlara sahip bir çok

etkinlikte örüntü tanıma kullanılır. İnsan örüntü tanınması, geçmiş tecrübelerle dayalı öğrenme esaslıdır. Böylece, insanlar pratikte karşılaştığı örüntü tanıma olaylarını tecrübeleri ışığında değerlendirebilme yeteneğine sahiptirler. Belirli bir sesi tanımak için kullanılan kuralları tanımlamak mümkün değildir. İnsanlar bu işlemlerin bir çoğunu oldukça iyi yapmalarına rağmen, bu işlemleri daha ucuz, iyi, hızlı ve otomatik olarak makinelerin yapmasını arzulurlar. Örüntü tanıma, böyle akıllı ve öğrenebilen makineleri gerçekleştirmek için, çok boyutlu bir mühendislik disiplini [6 ve 7].

Örüntü tanıma, aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini veya nesnelere bazı tespit edilmiş özellikler veya karakterler vasıtasıyla tanımlama veya sınıflandırmadır [6, 7 ve 8]. Bu bağlamda, örüntü tanımanın en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir.

Örüntü tanıma tekniklerinin uygulamaları bir çok mühendislik, tıp, askeri ve bilim alanına açıktır. Bunlardan bazıları; ses tanıma [6 ve 9], radar hedef sınıflama [6 ve 10] ve biyomedikal kontrol [6 ve 11] verilebilir. Örüntü tanıma olarak bilinen bu uygulamalar, makina öğrenmesi, örüntü sınıflandırma, ayırım analizi ve nitelik tahmini gibi isimlerle de anılmaktadır [6 ve 8]. Örüntü tanıma sistemleri gözlenen veya ölçülen verileri tanımlanmasında bir çok uygulamanın merkezinde yer alır. Şekil 1'de yaygın olarak kullanılan genel anlamda örüntü tanıma sistemi verilmiştir [5 ve 6]. Algılayıcılar, herhangi bir anda mümkün olan birçok doğal durumlardan biri olabilen bazı fiziksel işlemleri ölçerler. Bu blok diyagramın en önemli görevlerinden biride, elde edilen ölçümlerin hepsinden oluşan giriş uzayından daha az boyutta özellik çıkartmaktır. Sonunda, sınıflandırıcının rolü örüntüyü özelliklerine göre kategorize ederek uygun sınıflara kaydetmektir

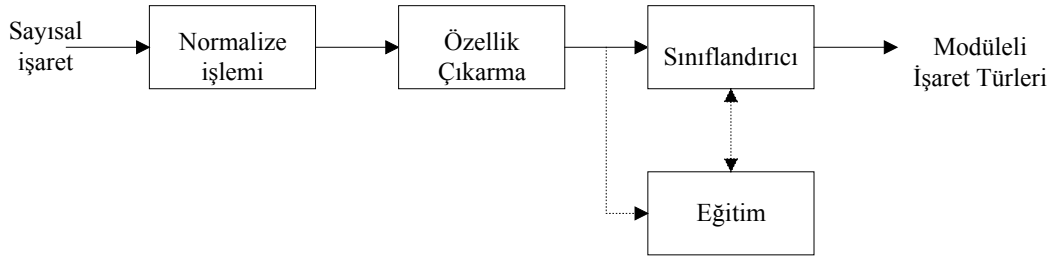


Şekil 1. Örüntü tanıma sistemi
(Figure 1. Pattern recognition system)

4. GELİŞTİRİLEN YÖNTEM (NEW METHOD)

Bu çalışmada sayısal modülasyon tanıma için frekans kaydırmalı anahtarlama (FSK), faz kaydırmalı anahtarlama (PSK), genlik kaydırmalı anahtarlama (ASK) ve kuadratör faz kaydırmalı anahtarlama (QASK) işaretleri şeklindeki 4 adet farklı modüleli işaretin birbirinden ayrımını sağlayacak etkili bir yöntem kullanılmıştır.

Kullanılan örüntü tanıma mekanizması ve hesaplama şemasından görüleceği üzere sistemin önem arz eden ve sınıflayıcının doğrudan başarımını etkileyen nokta özellik çıkarımıdır.



Şekil 2. Sayısal işaretlerin ayrımı için kullanılan örüntü tanıma sistemi

(Figure 2. Pattern recognition system for classification of digital digital signals)

Özellik Çıkarımı Aşaması: Özellik çıkarım örüntü tanıma için önemlidir. Eğer özellikler iyi seçilmezse, en iyi sınıflayıcı yetersiz olacaktır. Bir özellik çıkarıcı örüntü vektörünü (örn:orijinal dalga biçimi) orijinal vektörün faydalı bilgilerinin çoğunu kapsayan daha düşük bir boyuta indirgemelidir. İşaretten özellik çıkarmanın üç ana amacı vardır. Bunlar; sınıflama süresini azaltarak sınıflandırıcının başarımını artırmak, işlenecek bilgi miktarını en aza indirmek ve tanıma sisteminin güvenilirliğini sağlamaktır.

Burada özellik çıkarımı için dalgacık dönüşüm kullanılmıştır. Dalgacık dönüşümü ile işaretlerin diğer modülasyon tanıma yöntemlerinde ortaya çıkmayan en ince ayrıntılarına da ulaşılmıştır. Dalgacık dönüşümünün sonucunda elde edilen işaretler entropi işleminden geçirilmiştir. Entropi, işaretteki düzensizliğin ölçütüdür. Kaynağı bilinmeyen modüleli işaretlerin özelliklerinin çıkarılması için bu yöntem kullanılmaktadır. Entropi birçok alanda uygulanmaktadır fakat en fazla işaret işlemede kullanılmaktadır.

Entropi için birçok kriter bulunmaktadır. Bunlar Shannon entropisi, Norm entropi, Log energy entropisi ve Threshold entropisidir. Bu uygulama çalışmasında aşağıda Denklem 1'deki Norm entropi kullanılmıştır.

$$E(s) = \sum_i |s_i|^p = \|s\|^p \quad (1)$$

Burada s işaret, (s_i) işareti oluşturan örnek sayısı, i indis, E entropi değerleri (özellik vektörü), p isteğe bağlı bir parametredir. Denklem 1'deki Norm entropide p değeri 1'e eşit veya 1'den büyük ($1 \leq p$) olmalıdır.

Dalgacık dönüşümü 7 seviyede alındığından işaretlerin her birinin norm entropi değerleri hesaplanarak, her bir işaret için 7 özellik çıkarılmıştır. Bu herbir özellik için birer norm entropi değeri hesaplandığına göre bu özellik vektörü her bir modülasyon tipi için (15×7) boyutundadır.

Sınıflandırma Aşaması: Bu çalışmada sınıflandırıcı olarak, Bayes karar kuralı sınıflandırıcısı kullanılmıştır. Bu sınıflandırma aşamasında, özellik çıkarım aşamasında elde edilen özellikler kullanılmıştır. Bu şekilde sınıflandırıcı giriş uzayı elde edilmiştir.

Bayes teorisi sınıflandırma işlemine bir olasılık problemi gibi yaklaşmaktadır [12]. Temel Bayes sınıflandırıcısında kullanılan büyüklükler şu şekilde tanımlanır:

$\Omega = \{w_1, w_2 \dots w_s\}$ s adet sonlu doğal durum (tanınması istenen örüntü sınıflarının) kümesi.

$A = \{\alpha_1, \alpha_2 \dots \alpha_a\}$	a adet sonlu mümkün olabilen karar kümesi
$\underline{x} \in \mathfrak{R}^d$	d-bileşenli özellik/örüntü vektörü
$p(\underline{x} w_j)$	\underline{x} için şartlı olasılık yoğunluk fonksiyonu
$p(w_j)$	doğal w_j durumunda olan öncesel (<i>priori</i>) olasılık
$p(w_j \underline{x})$	sonrasal (<i>posteriori</i>) olasılık

Olasılıklar Bayes kuralıyla birlikte ilişkilendirildiğin de:

$$p(w_j|\underline{x}) = \frac{p(\underline{x}|w_j)p(w_j)}{p(\underline{x})} \quad (2)$$

Burada,

$$p(\underline{x}) = \sum_{j=1}^s p(\underline{x}|w_j)p(w_j) \quad (3)$$

Bayes karar kuralına göre

$$p(w_i|\underline{x}) > p(w_j|\underline{x}) \text{ ise Karar } w_i \quad \forall j \neq i. \quad (4)$$

Bayes sınıflandırıcısının bir çok varyasyonu ve genellemesi vardır, fakat temel yapı aynıdır ve örüntü tanıma için yeterlidir.

Bu çalışmada sayısal modüleli işaretler elde etmek için 0-60 dB S/G (Sinyal/Gürültü) aralığında Gaussian Beyaz Gürültü, modüleli işaretlere ilave edilmiştir. Gürültü ilave edilerek, her bir modülasyon tipinden 15 adet olmak üzere, toplam 60 adet sinyal elde edilmiştir. Gürültü ilave edilerek oluşturulan 15'er adet ASK8, FSK8, PSK8 ve QASK8 işaretlerinin taşıyıcı frekansı $F_c=10$, örnekleme oranı $F_s=25$, seviyesi $M=8$ şeklinde alınmıştır. Elde edilen her bir modüleli işaret dalgacık dönüşümünden geçirilerek özellikleri çıkarılmıştır. Dalgacık dönüşümünün sonucunda elde edilen işaretler entropi işleminden geçirilmiştir. Sayısal modülasyon tanıma çalışmasında entropi olarak norm entropi kullanılmıştır. Elde edilen entropi değerleri $N=200$ bölünele normalize edilmiştir. Böylece toplam normalize edilmiş 7 entropi değeri 60 işaretin her biri için bulunmuştur. Daha sonra bu 60 adet modüleli işaretin, her bir modülasyon çeşidi için 10'ar ve 5'er tanesi sırasıyla Bayes sınıflandırıcısının eğitimi ve testi için kullanılmıştır.

Bu çalışmada kullanılan Bayes karar kuralı sınıflandırıcısı için öncesel olasılıklar her bir hedef için 1/4 oranında eşit olarak alınmıştır. Olasılık yoğunluk fonksiyonu Denklem 5'de verilen normal dağılıma uygun olarak hesaplanmıştır.

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{1}{2\sigma^2}(x-\mu)^2} \quad (5)$$

Burada kullanılan normal dağılım formülünde yer alan σ varyansı (değişimi), x giriş parametresini ve μ ortalama parametresini ifade etmektedir.



Aşağıda birkaç adet test örneği ve elde edilen sonuçları verilmiştir:

Test-1:

giriş değerini giriniz:282

ans =

0.3938

0.2197

0.2976

0.0890

dahil olduğu sınıf

1

En büyük olasılık değeri

0.3938

Test-2:

giriş değerini giriniz:1000

ans =

0.0992

0.3540

0.3216

0.2252

dahil olduğu sınıf

2

En büyük olasılık değeri

0.3540

Yukarıdaki şekilde gerçekleştirilen Bayes sınıflandırıcı test aşaması sonucunda ortalama %80 oranında doğru sınıflandırma başarımı elde edilmiştir.

5. SONUÇ VE DEĞERLENDİRME (RESULT AND EVALUATION)

Geliştirilen özellik çıkarma yöntemi, sayısal modüleli işaretlere uygulanarak, %80'lik bir doğru sınıflandırma başarımı elde edilmiştir. Ayrım fonksiyonları arasında oldukça belirgin farklar olduğu tanıma yüzdelerinden anlaşılmaktadır. Bu göstergeler doğal girişlerden çıkarılan özelliklerin ne kadar etkili ve güçlü olduğunu betimlemektedir. Yine sistemin karar uzayındaki ayrım fonksiyonlarının çok belirgin oluşu, özellik vektörü için seçilen özelliklerin başka bir işleme gerek kalmadan sistemi en iyi bir biçimde özetlediğini ve seçilen özelliklerin güvenilirliğinin ispatı olmakla birlikte, sınıflandırıcı olarak Bayes eğitimcisi sınıflandırıcı kullanılmıştır. İleride bu alanda yapılabilecek çalışmalarda, özellik çıkarımına çevre ve gürültüden daha az etkilenen kararlı bir yapı kazandırılmasıyla, sayısal modülasyon tanıma sistemlerinde hedef kimliği hakkında bilgi edinme çalışmaları pratiğe dökülebilecektir.

KAYNAKLAR (REFERENCES)

1. Derin, H. ve Aşkar, M., (1987). İletişim Kuramı Modülasyon Yöntemleri. ODTÜ Mühendislik Fakültesi, Ankara.
2. Türkoğlu, İ., (2002). Haberleşme Tekniği-I Ders Notları. Fırat Üniversitesi, Elazığ.



3. Azzouz, E.E. and Nandi, A.K., (1997). Automatic Modulation Recognition-I, Journal of Franklin Inst., 334B, No.2, pp:241-273.
4. Azzouz, E.E. and Nandi, A.K., (1997). Automatic Modulation Recognition-II, Journal of Franklin Inst., 334B, No.2, 275-305.
5. Rajan, J.J., (1994) Time series classification, Doktora Tezi, Cambridge Üniversitesi, 191s.
6. Türkoğlu, İ., (2003). Örüntü Tanıma Ders Notları. Fırat Üniversitesi, Elazığ.
7. Rothe, H., (1998). Approaches to pattern recognition, advanced pattern recognition techniques, NATO-RTO Lecture Series 214, Lisbon Portugal, 1.1-1.29.
8. Duda, R.O. and Hart, P.E., (1989). Pattern Classification and Scene Analysis. Stanford Research Institute, pp:483.
9. Phan, F., Tzanakou, E.M., and Sideman, S., (2000). Speaker identification using neural networks and wavelets, IEEE Engineering in Medicine and Biology, Ocak/Şubat, pp:92-101.
10. Türkoğlu, İ. ve Hanbay, D., (2001). Yapay sinir ağı ve HFD kullanarak DTMF sinyal örüntülerini tanıma sistemi, Elektrik-Elektronik-Bilgisayar Mühendisliği 9.Ulusal Kongresi, 19-23 Eylül 2001, Kocaeli, ss:431-434.
11. Chau, T., (1994). Pattern recognition of processed EMG signals for two-site Myoelectric control, Uygulamalı Master Lisans Tezi, Toronto Üniversitesi, ss:96.
12. Duda, R.O. and Hart, P.E., (1989). Pattern Classification and Scene Analysis, Stanford Research Institute.