

Logaritmik Moment ve Histogram Tabanlı Otomatik Sayısal Modülasyon Sınıflandırma

Ahmet GÜNER, Ömer Faruk ALÇİN, Mehmet ÜSTÜNDAĞ
Bingöl Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, BİNGÖL
aguner,ofalcin,mustundag@bingol.edu.tr

(Geliş/Received:22.06.2016 ; Kabul/Accepted:07.10.2016)

Özet

Otomatik Modülasyon Sınıflama (OMS), haberleşme sistemlerinde işaretin algılanması ile demodülasyon arasında yer alan bir süreçtir. OMS, alınan işarete ait hiç veya sınırlı bilgiye sahip olan bir alıcı için çok önemli bir süreçtir. OMS alınan örneklerden gönderilen işaretin modülasyon türünü belirlemek için kullanılmaktadır. Ayrıca yazılım tabanlı radyo, adaptif ve işbirliksiz haberleşme sistemleri gibi birçok uygulamada yer almaktadır. Fakat var olan tekniklerin birçoğu, modem standartlarında ve yüksek kapasiteli radyo sistemlerinde yaygın olarak kullanılan QAM işaretlerinin sınıflandırılmasında başarısız olduğu bildirilmektedir. Bu çalışmada, gönderilen toplanır beyaz Gauss gürültülü işaretlerin yüksek dereceden istatistik ve histogram kullanarak sınıflandırılması için EKK-DVM tabanlı bir QAM sınıflayıcı önerilmiştir. Burada önerilen yöntem, dört modülasyon türü (BPSK, QPSK, 16QAM ve 64QAM) için farklı işaret-gürültü oranı (SNR) ve örnek sayılarına göre analiz edilmiştir. Önerilen yöntem farklı SNR değerlerine karşı oldukça sağlamdır. Geliştirilen QAM sınıflayıcının bilinen logaritmik moment temelli OMS yöntemleriyle karşılaştırıldığı zaman yüksek başarıma sahip olduğu benzetim sonuçları ile görülmektedir. İşaret-gürültü oranı 4dB'den daha büyük olduğu zaman, önerilen sınıflayıcı %98 sınıflayıcı doğruluğundan daha fazlasına ulaşmaktadır.

Anahtar Kelimeler: Otomatik Modülasyon Sınıflama, Logaritmik Momentler, Enküçük Kareler-Destek Vektör Makinası, Öznitelik Çıkarma.

Cumulant and Histogram Based Automatic Digital Modulation Classification

Abstract

Automatic Modulation Classification (AMC) is an intermediate step between signal detection and demodulation. It is a very important process for a receiver that has no, or limited knowledge of received signals. It is employed to automatically identify the modulation types of transmitted signals by observing the received data samples. AMC has found many applications such as software defined radio, adaptive and non-cooperative communications systems. However, the majority of existing techniques fail to classify QAM signals that have been widely used in modem standards and high capacity radio systems. In this paper, a QAM classifier based on LS-SVM has been proposed classify the transmitted signals in the presence of additive white Gaussian noise (AWGN) by taking high order statistics and histogram into account. The approach suggested here, four types of modulation (BPSK, QPSK, 16QAM and 64QAM), was analyzed in accordance with different signal-to-noise ratio and the number of samples. The proposed classifier is more robust to different signal-noise ratios (SNR). Simulation results have demostared that the developed QAM classifier has high identification accuracy when compared to conventional cumulant based AMC methods. When the signal-to-noise ratio is greater than 4 dB, the proposed classifier accuracy reaches to more than 98%.

Keywords: Automatic Modulation Classification, Cumulants, Least Squares-Support Vector Machine, Features Extraction.

1. Giriş

Betonarme son yıllarda haberleşme standartlarından bağımsız, bulunduğu bölgede geçerli olan haberleşme standartlarına otomatik olarak uyum sağlayabilen akıllı alıcıların

kullanımı yaygınlaşmaktadır. Akıllı alıcılar sadece alınan işareten faydalanarak işarete ait simge hızı, taşıyıcı frekansı ve modülasyon türü gibi modülasyon parametrelerini kestirebilmekte ve kestirdiği parametreleri kullanarak haberleşme gerçekleştirmektedir. Otomatik

modülasyon sınıflama, alınan işaret içerisindeki bilgi sembollerinin elde edildiği son işlem olan demodülasyon işleminden önceki modülasyon türünün tespit edildiği aşamadır. Modülasyon türünün belirlenmesi işlemi, faz ve frekans kayması ile yayılım ortamının bozucu etkileri neticesinde oluşan senkronizasyon problemlerinin bulunduğu sivil ve askeri araştırmalarda, akıllı radyo ve yazılım tanımlı radyo gibi gerçek haberleşme senaryolarında çok daha önem kazanmaktadır. Bu gibi işbiriksiz haberleşme sistemlerinde hedef, alınan işaret üzerinden gönderici bilgilerin elde edilmesidir. Bu amaç çerçevesinde otomatik modülasyon tanımlama işlemi, tespit edilen işaretten modülasyon parametrelerinin kestirimi ile işaretin taşınmış olduğu bilginin elde edilebildiği demodülasyon işlemi arasında yer almaktadır.

Otomatik modülasyon sınıflama, iki önemli işlem adımından oluşmaktadır. İlk adımda sınıflayıcının girişini özneliğin işaretten çıkarılması ve ikincisi adım modülasyon türünün belirlendiği sınıflandırma işlemidir. Literatürde yapılan çalışmalara bakıldığında, kullanılan öznelilikler ve sınıflandırıcılar farklı şekillerde bir araya getirilerek modülasyon sınıflandırıcı yapıları ortaya konulmaktadır. A. K. Nandi ve E. E. Azzouz tarafından, analog ve sayısal modülasyonların sınıflandırılması için iki yöntem sunulmuştur [1]. Birinci yöntemde, farklı modülasyon türlerini sınıflamak için geliştirdikleri karar ölçüt kümesi içeren karar ağacı yaklaşımı kullanılmıştır. İkinci yöntemde, modülasyon sınıflama işleminde yapay sinir ağları kullanılmıştır. Her iki yöntemde de anahtar öznelilikler olarak alınan işarete ait anlık genlik, anlık faz ve anlık frekans bilgileri kullanılmaktadır. Sınıflandırılmaya çalışılan modülasyon türleri kümesi, 2ASK, 4ASK, 2FSK, 4FSK, BPSK ve QPSK modülasyon türlerini içermektedir. SNR değeri 15dB için birinci yöntemin doğru sınıflama başarımı %94 olduğunda ikinci yöntemin doğru sınıflama başarımı %96 olmaktadır.

A. Swami ve B. M. Sadler tarafından, MQAM, MPSK ve MASK modülasyon türlerini sınıflandırmak için dördüncü dereceden logaritmik momentlerin öznelilik olarak seçildiği ve sınıflandırıcı olarak hiyerarşik karar ağacı yapısının kullanıldığı bir yöntem sunulmuştur [2]. Bu çalışma özellikle yüksek dereceden

logaritmik momentlerin öznelilik olarak kullanılan çalışmalar için bir referans çalışma olmaktadır. Yapılan çalışmada, SNR değeri 8dB ve 10dB olduğunda istenilen düzeyde bir başarımla elde edilmektedir.

Wang Yu-e ve arkadaşları tarafından, 2ASK, 4ASK, 2PSK, 4PSK, 8PSK, 2FSK, 4FSK, 8FSK, 16QAM ve MSK modülasyon türleri için işarete ait anlık genlik, frekans ve faz bilgisinin, normalize edilmiş dördüncü dereceden momentin, dalgalı detay dizisinin ve anlık fazının öznelilik olarak seçildiği ve sınıflandırıcı olarak PSO-destek vektör makinesinin kullanıldığı bir yöntem sunulmuştur [3]. Yapılan çalışmada, SNR değeri 5dB olduğunda doğru sınıflama başarımı %93 üzerinde olmaktadır.

Son yıllarda, karesel genlik modülasyonu (QAM), yayılım ortamının durumuna göre modülasyon seviyesinin uyarlanabilmesi ve yüksek veri hızına imkan sağlayabilmesinden modem ve yüksek kapasiteli radyo sistemleri standartlarında yaygın olarak kullanılmaktadır. Örneğin, 16-QAM modemlerde, 4-QAM ve 64-QAM kablosuz LAN, sayısal video yayınları ve 802.16 WiMAX sistemlerinde kullanılmaktadır. Gelecekteki haberleşme sistemlerinde de bu çok seviyeli modülasyonlar yaygın olarak kullanılması beklenmektedir[4].

Bu çalışmada, toplanır beyaz Gauss gürültülü (AWGN) kanallarda QAM işaretlerinin sınıflandırılması için düşük karmaşıklığa sahip öznelilik tabanlı bir modülasyon sınıflandırıcı önerilmektedir. Alınan işaretin gücünü normalize ederek yıldız kümesi diyagramının genlik değişiminin sabit bir aralık içerisinde olması sağlanır. Böylelikle tüm modülasyon türleri için aynı değişim aralığında yıldız kümesi diyagramından ayırt edici özelliğe sahip yeni bir öznelilik çıkartılmaktadır. Böylelikle öznelilik olarak, yüksek dereceden logaritmik momentler ve yıldız kümesi diyagramı üzerindeki noktaların değişimlerine ait histogram üzerindeki tepe noktalarının sayısı ile sınıflandırma yapılmaktadır.

Bu çalışmada; Bölüm 2’de işaret modeli ve kullanılan öznelilik çıkarım yöntemlerine ait detaylar sunulmuştur. Bölüm 3’te özneliliklere göre sınıflama yapmak için kullandığımız En Küçük Kareler-Destek Vektör Makinesi hakkında bilgi verilmiştir. Bölüm 4’de benzetim

çalışmaları ve elde edilen sonuçlardan bahsedilmiştir. Ayrıca verilen özniteliklerle tasarlanmış olan sınıflandırıcı yapılarının başarımları detaylı tablolar ile sunulmuştur. Bölüm 4 ise önerilen çalışmanın sonuçlarına yer verilmiştir.

2. İşaret Modeli ve Öznitelik Çıkarımı

2.1. İşaret Modeli

Kablosuz haberleşme sistemlerinde, sayısal modüle edilmiş bir işaretin (y) genel olarak gösterimi,

$$y(n) = \sqrt{p} e^{j(2\pi\epsilon n + \theta)} x(n) + w(n) \quad (1)$$

burada $x(n)$ gönderilen işareti, ϵ normalize edilmiş taşıyıcı frekans kayması ($\Delta f T_s = \epsilon$), θ faz kayması, p alınan işarettaki gücünü ve $w(n)$, σ_w^2 varyanslı AWGN göstermektedir. Ayrıca T_s ve Δf simge hızını ve taşıyıcı frekans kaymasını göstermektedir.

2.2. Öznitelik çıkarımı

Önerilen modülasyon sınıflayıcı, öznitelik tabanlı bir sınıflayıcıdır. Alınan işarettan çıkarılan öznitelikler altıncı dereceden logaritmik moment ve yıldız kümesi diyagramı üzerindeki noktaların değişimlerine ait histogram üzerindeki tepe noktalarının sayısıdır.

A. Yüksek dereceden logaritmik moment

Yüksek dereceden momentler ve logaritmik momentler, gürültülü işaret yıldız kümesi diyagramının şeklini tanımlamaktadır. Sayısal modülasyon türlerine ait örneklerin karmaşık düzlemde bir nokta olarak gösterilebildiği yıldız kümesi diyagramı, modülasyon türünün şeklini göstermektedir. Belirtilen bu ilişkiden dolayı, sayısal modülasyon türleri için yüksek dereceden momentler ve logaritmik momentler ayırt edici bir öznitelik olarak kullanılmaktadır.

Teorik olarak Gauss dağılıma sahip bir verinin yüksek dereceden logaritmik momentleri sıfır olmaktadır. Logaritmik momentlerin bu özelliğinden dolayı, öznitelik olarak düşük SNR seviyelerinde ve hiçbir dönüşüm gerektirmeden zaman düzleminde uygulanabilmektedir [5].

Momentler ve bu momentlere bağlı olarak Logaritmik momentler Denklem 2-6 ile gösterilen matematiksel ifadeler ile hesaplanmaktadır [6].

$$M_{pq} = E \left[y(k)^{p-q} (y^*(k))^q \right] \quad (2)$$

$$C_{60} = cum(y(n), y(n), y(n), y(n), y(n), y(n)) \quad (3)$$

$$= M_{60} - 15M_{20}M_{40} + 3M_{20}^3$$

$$C_{61} = cum(y(n), y(n), y(n), y(n), y(n), y^*(n)) \quad (4)$$

$$= M_{61} - 5M_{21}M_{40} - 10M_{20}M_{41} + 30M_{20}^2M_{21}$$

$$C_{62} = cum(y(n), y(n), y(n), y(n), y^*(n), y^*(n)) \quad (5)$$


$$= M_{62} - 6M_{20}M_{42} - 8M_{21}M_{41} - M_{22}M_{40}$$

$$+ 6M_{20}^2M_{22} + 24M_{21}^2M_{20}$$

$$C_{63} = cum(y(n), y(n), y(n), y^*(n), y^*(n), y^*(n)) \quad (6)$$


$$= M_{63} - 9M_{21}M_{42} + 12M_{21}^3 - 3M_{20}M_{43}$$

$$- 3M_{22}M_{41} + 18M_{20}M_{21}M_{22}$$



Şekil 1. $|C_{60}|$ logaritmik momentinin farklı işaret-gürültü oranı (SNR) değerlerine göre değişimi.

Farklı QAM işaretlerine ait Şekil 1'de C_{60} logaritmik momentinin ve Şekil 2'de C_{61} logaritmik momentinin farklı işaret-gürültü oranı değerlerine göre değişimleri gösterilmektedir. Her iki şekildeki değişimler logaritmik momentlerin ayrıştırıcı özelliğe sahip olduğunu ve öznitelik olarak kullanılabilceğini göstermektedir.

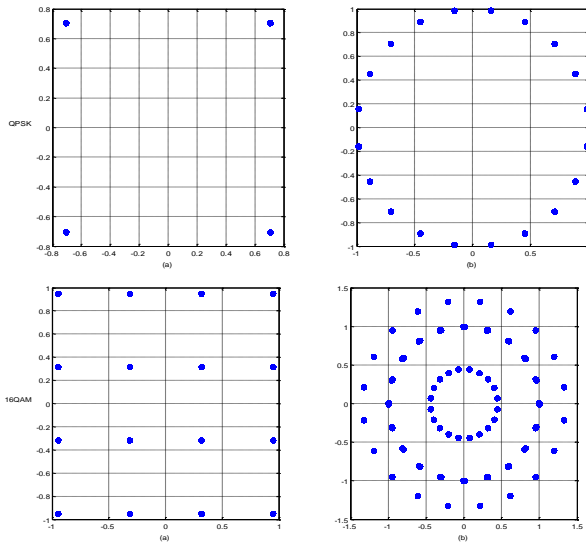


Şekil 2. $|C_{61}|$ logaritmik momentinin farklı işaret-gürültü oranı (SNR) değerlerine göre değişimi

B. Histogram

Sayısal modülasyon türlerinde alınan işarete ait örneklerin Denklem 7 ile gösterilen sabit bir frekans ($\Delta\omega$) değeri ile çarpma işlemi sonucunda yıldız kümesi diyagramı üzerindeki konumlarında zamanla değişen dönme hareketi şeklinde Şekil 3’de gösterildiği gibi kaymalar meydana gelmektedir.

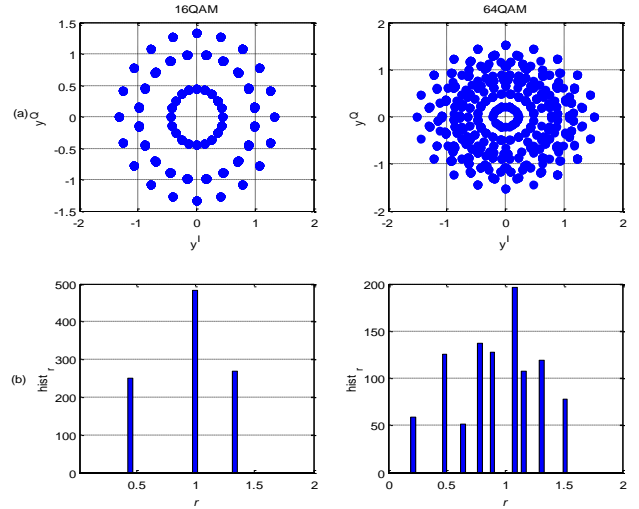
$$\hat{y}_n = e^{jnT\Delta\omega} y_n \quad (7)$$



Şekil 3. QPSK ve 16QAM türlerinin yıldız kümesi diyagramı (a) normal durum (b) dönme etkisi durumu

Şekil 4’de gösterilen yıldız kümesi diyagramı üzerindeki dönme hareketi sonucunda oluşan çemberlerin sayısı, histogram yardımıyla elde edilen tepe sayılarının tespiti ile bulunmaktadır.

Alınan işaretin gücünü normalize ederek yıldız kümesi diyagramının koordinat sınırları sabit bir aralık içerisinde olması sağlanır. Böylelikle histogramın sütunları, 0 ile r arasında seçilen adım büyüklüğüne (Δr) bağlı olarak her bir aralıktaki nokta sayısını gösterir.



Şekil 4. 16QAM ve 64QAM için (a) yıldız kümesi dağılımı (b) histogram dağılımı

Çemberin yarıçapı, adım büyüklüğüne göre artırılarak, belli aralıktaki noktaların sayı adedi belirlenmektedir. Histogram, Tablo 1’deki belirtilen işlem adımlarından oluşmaktadır. Histogram değişimi, seçilen adım büyüklüğüne yada sütun genişliğine hassasiyet göstermektedir. Eğer adım büyüklüğü çok geniş seçilirse, önemli bilgiler kaybolabilmekte veya çok dar seçilirse, ekstra rastgele bilgiler fazla vurgulanmış olabilmektedir. En uygun adım büyüklüğünü teorik olarak belirlemek çok zor olmaktadır. Bu nedenle, uygulamamız için adım büyüklüğü ile histogram sonuçları arasındaki ilişki incelenerek seçilen farklı adım büyüklükleri içerisindeki en uygun olana karar verilmiştir.

Şekil 4.a’da 16QAM ve 64QAM modülasyon türleri için dönme etkisinin olduğu yıldız kümesi diyagramı ve Şekil 4.b’de amaçlanan histogram diyagramı gösterilmektedir. Elde edilen tepe sayısının bir öznitelik olarak kullanılması özellikle QPSK,

16QAM ve 64QAM türlerinin sınıflandırılmasında önem arz etmektedir.

Tablo 1: Histogram algoritması

Giriş : $\hat{y}_i = \hat{y}_i^I + j\hat{y}_i^Q$
 for $r = 0 : \Delta r : 2$
 if $\left(\sqrt{(\hat{y}_i^I)^2 + (\hat{y}_i^Q)^2} \in r \right)$
 $hist_r = hist_r + 1$
 end
 Çıkış : $hist = tepesayısı\{hist_r\}$

3. En Küçük Kareler-Destek Vektör Makineleri (EKK-DVM)

Destek Vektör Makinesinin bir çeşidi olan En küçük kareler destek vektör makineleri Suykens ve diğerleri tarafından ileri sürülmüştür [7-9]. EKK-DVM’de ikinci dereceden programlama yöntemleri yerine doğrusal eşitlik kümesi kullanılmaktadır [8,9]. DVM sınıflandırıcı denklemini Suyken tarafından EKK-DVM için geliştirilerek [9];

$$\min_{w,b,e} J(w,e) = \frac{1}{2} w^T w + \gamma \frac{1}{2} \sum_{i=1}^N e_i^2 \quad (8)$$

$$y_i [w^T \varphi(x_i) + b] = 1 - e_i, \quad i = 1, \dots, N$$

burada γ marjın parametresini göstermektedir. Denklem (8)’in Lagrangian eşitlikleri Denklem (9)’de verilmiştir.

$$\begin{cases} \sum_{i=1}^N \alpha_i y_i = 0 \\ \sum_{i=1}^N \sum_{j=1}^N \left(y_i y_j \varphi(x_i)^T \varphi(x_j) + \frac{1}{\gamma} \right) + yb = 1 \end{cases} \quad (9)$$

Denklem (9) doğrusal matris formunda $Ax=B$ gibi yazılabilir [9].

$$A = \begin{bmatrix} 0 & -Y^T \\ Y & H \end{bmatrix}, \quad x = \begin{bmatrix} b \\ \alpha \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ 1 \end{bmatrix} \quad (10)$$

$$H = ZZ^T + \frac{1}{\gamma}, \quad Z = \begin{bmatrix} \varphi(x_1) y_1 & \cdots & \varphi(x_1) y_1 \\ \vdots & \ddots & \vdots \\ \varphi(x_N) y_N & \cdots & \varphi(x_N) y_N \end{bmatrix} \quad (11)$$

Lagrangian çarpanları ve eşik değerleri Denklem (10)’dan elde edilebilir. EKK-DVM çıkışı Denklem (12) yardımıyla hesaplanabilir [9].

$$f(x) = \text{sign} \left[\frac{1}{2} \sum_{i=1}^N \alpha_i y_i \varphi(x) \varphi(x_i) + b \right] \quad (12)$$

Çözümde ikinci dereceden programlama yerine kısa sürede uygulanabilen doğrusal programlamayı kullandığından bazı uygulamalarda EKK-DVM sınıflandırıcı klasik DVM’den daha düşük başarımlı gösterebilir [8]. [8,9] çalışmalarında EKK-DVM ve DVM detaylı bir şekilde anlatılmıştır.

4. Benzetim Sonuçları

Benzetim çalışmalarında, sembol zamanlama hatası ihmal edilirken simge hızı ile taşıyıcı frekansının kestirildiği varsayılmıştır. Ayrıca işaret modeli için sadece $w(n)$ etkisi ele alınmıştır. Bu çalışmada, önerilen OMS sistemi BPSK, QPSK, 16QAM ve 64QAM modülasyon türleri ait sinyaller ile test edilmiştir. Benzetim çalışmaları Matlab ortamında yapılmıştır. Modülasyon veri seti hazırlanırken $M = 2, 4, 16, 64$ seviyeleri ve düzgün dağılımlı rasgele sayı üretici kullanılmıştır. SNR oranları 0dB, 4dB, 6dB, 10dB ve 20dB AWGN gürültülü ve herbir SNR değeri 512, 1024 ve 2048 örnek sayısı dikkate alınarak 15 veri seti hazırlanmıştır. Modülasyon veri seti, her modülasyon türüne ait sinyal eşit olacak şekilde, 40400 sinyalden oluşmaktadır. Hazırlanan veri seti her bir modülasyon türünden eşit sayıda içerecek şekilde eğitim için 400 adet ve test için ise 40000 adet veri ayrılmıştır.

Hazırlanan veri setinden C_{60} ve C_{61} logaritmik momentleri ve histogram parametreleri kullanılarak toplam 3 adet öznelik çıkarılmıştır. Histogram parametresi modüleli bir sinyalin yıldız kümesi dağılımının histogramında ki toplam tepe sayısı olarak hesaplanmıştır. Bu çalışmada otomatik modülasyon belirleme sistemi için sınıflandırıcı olarak Suyken ve diğ. tarafından geliştirilen EKK-DVM açık kaynak kodu kullanılmıştır. EKK-DVM parametreleri kullanılan açık kaynak kodda mevcut olan fonksiyon ile tarafından elde edilmiştir. Sistem, her bir modülasyon türü için

farklı SNR ve örnek sayısından oluşan 100 veri paketiyle eğitilmiş ve 10000 veri paketiyle test edilmiştir. Elde edilen sonuçlar Tablo 2’de gösterilmektedir.

Tablo 2: Farklı SNR ve örnek sayısı için EKK-DVM sınıflandırıcı başarımları sonuçları

| SNR (dB) | Örnek sayısı doğruluğu (%) | | |
|----------|----------------------------|--------|--------|
| | 512 | 1024 | 2048 |
| 0 | 72.600 | 78.800 | 85.172 |
| 4 | 90.985 | 96.680 | 98.700 |
| 6 | 98.570 | 99.457 | 99.775 |
| 10 | 99.865 | 99.890 | 99.987 |
| 20 | 99.940 | 100 | 100 |

Tablo 2’den açıkça görüleceği gibi örnek sayısı artması sınıflandırıcı başarımları olumlu yönden etkilemektedir. Örnek sayısı 2048 için farklı SNR değerlerinde önerilen sınıflandırıcı yapısının başarımları her bir modülasyon türü için ayrı ayrı olarak Tablo 3’de gösterilmektedir. 0dB SNR değerinde BPSK ve QPSK için %98±1 değerlerinde başarımları sergilerken 16QAM ve 64QAM için bu başarımları yüzdesi SNR’nin 4dB değerinde elde edilebilmektedir.

Tablo 3: Farklı SNR ve 2048 örnek sayısı için sınıf doğruluk tablosu

| SNR | Modülasyon türü | BPSK | QPSK | 16QAM | 64QAM |
|------|-----------------|-------|------|-------|-------|
| 0dB | BPSK | 9995 | 5 | 0 | 0 |
| | QPSK | 0 | 9786 | 214 | 0 |
| | 16QAM | 0 | 253 | 7154 | 2593 |
| | 64QAM | 0 | 21 | 2845 | 7134 |
| 4dB | BPSK | 10000 | 0 | 0 | 0 |
| | QPSK | 0 | 9944 | 17 | 39 |
| | 16QAM | 0 | 6 | 9945 | 49 |
| | 64QAM | 0 | 0 | 409 | 9591 |
| 6dB | BPSK | 10000 | 0 | 0 | 0 |
| | QPSK | 0 | 9989 | 11 | 0 |
| | 16QAM | 0 | 0 | 9975 | 25 |
| | 64QAM | 0 | 0 | 54 | 9946 |
| 10dB | BPSK | 10000 | 0 | 0 | 0 |
| | QPSK | 0 | 9999 | 1 | 0 |
| | 16QAM | 0 | 0 | 10000 | 0 |
| | 64QAM | 0 | 0 | 53 | 9947 |

Seçilen dört modülasyon türleri içerisinde 16QAM ve 64QAM türlerini ayırt edebilmek

karşılaşılan problemlerden birisidir. Bu problemin asıl kaynağı seçilen özneliktir. Farklı çalışmalarda seçilen özneliklere göre farklı sonuçlar elde edilmiştir. Örneğin Swami ve Sadler [2], C40 logaritmik momenti öznelik kullanarak gürültü etkisi olmadan ve 10000 adet örnek kullanarak SNR=20dB değerinde %90 başarı elde etmişlerdir. Dobre, Ness ve Su [11], yüksek dereceden çevrimsel logaritmik momentleri öznelik kullanarak 2000 adet örnek ile SNR=10dB değerinde %70 başarı elde etmişlerdir. Ayrıca Şekil 1 ve Şekil 2’de gösterilen değişim eğrileri logaritmik momentlerin öznelik olarak seçilmesi durumlarında 16QAM ve 64QAM türlerinin yakın değişimler sergilediğini göstermektedir.

Bu çalışmada öznelik olarak seçilen iki adet logaritmik momentlerin sınıflandırmadaki etkinliklerini artırmak için histogram öznelik olarak eklenerek 2048 adet örnek ve SNR=4dB değerinde BPSK, QPSK, 16QAM ve 64QAM modülasyon türlerinin sınıflandırılması %98.7’lik başarımları elde edilmiştir.

Wong ve Nandi [10], benzer modülasyon türlerini Naive Bayes, DVM ve enbüyük olasılık yöntemleriyle sınıflandırmışlardır ve bu yöntemlerin içerisinde en iyi sonuçları Tablo 4’de gösterilen DVM yöntemi vermiştir. Tablo 4’de benzer durumlar için Wong ve Nandi’nin DVM ile elde ettiği sonuçlarla önermiş olduğumuz sınıflayıcı sonuçları karşılaştırılmıştır.

Tablo 4: SNR=10dB değeri için DVM sınıflandırıcı ile EKK-DVM sınıflandırıcısının başarımları sonuçları

| Örnek Sayısı | DVM [10] | EKK-DVM (Bu çalışma) |
|--------------|----------|----------------------|
| 512 | % 91.20 | % 99.86 |
| 1024 | % 94.80 | % 99.89 |
| 2048 | %97.90 | % 99.98 |

5. Sonuçlar

Bu çalışmada BPSK, QPSK, 16QAM ve 64QAM türlerini sınıflamak için öznelik çıkarım analizi yapılmıştır. Özellikle logaritmik moment kullanılarak ayırt edilmesi zor olan 16QAM ve 64QAM türleri için histogram özneliği kullanılmıştır. Bu çalışmada önerilen öznelik çıkarım ile dört modülasyon türü için

literatürde yapılan çalışmalarla karşılaştırıldığında daha iyi başarımlar elde edilmiştir.

6. Kaynaklar

1. Azzouz, E.E., and Nandi, A.K., (1996). Automatic Modulation Recognition of Communication Signals. Boston, MA: Kluwer.
2. Swami, A. and Sadler, B. M., (2000). Hierarchical digital modulation classification using cumulants, *IEEE Trans. Commun.*, vol. 48, pp. 416-429.
3. Yu-e, W., Tian-qi, Z., Juan, B. and Rui, B., (2011). Modulation Recognition Algorithms for Communication Signals Based on Particle Swarm Optimization and Support Vector Machines, *Seventh International Conference on Intelligent Information Hiding and Multimedia Signal Processing (IIH-MSP)*, pp. 266 – 269.
4. Liang Hong, (2009). Low-Complexity Identifier for M-ary QAM Signals, *IEEE Southeast CON '09*, pp.164-168.
5. Shih, P. and Chang, D., (2011). An automatic modulation classification technique using high-order statistics for multipath fading channels, *ITST*, pp. 691-695.
6. Zhu, Z., Aslam, M.W. and Nandi, A.K., (2011). Support Vector Machine Assisted Genetic Programming for MQAM Classification, *IEEE International Symposium on Signals, Circuits and Systems*, pp. 1-6.
7. Suykens, J.A.K. and Vandewalle, J., (1999). Least squares support vector machine classifiers, *Neural Processing Letters*, pp. 293-300.
8. Kaytez, F., (2012). En Küçük Kareler Destek Vektör Makineleri ile Türkiye'nin Uzun Dönem Elektrik Tüketim Tahmini ve Modellemesi, Doktora Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
9. Carvalho, B. P. R., and Braga, A. P., (2009). IP-LSSVM: A two-step sparse classifier, *Pattern Recognition Letters*, vol. 30(16), pp. 1507-1515.
10. Wong, M. L. D. and Nandi, A. K., (2008). Naïve Bayes classification of adaptive broadband wireless modulation types with higher order cumulants, in *Proc. of the International Conference on Signal Processing and Communication Systems*.
11. Dobre, O. A., Bar-Ness, Y. and Su, W., (2004). Robust QAM modulation classification algorithm based on cyclic cumulants, *IEEE WCNC*, vol. 2, pp. 745-748.
12. Güner, A., and Kaya, I., (2013). Novel automatic modulation classification method employing higher-order cumulants and constellation histogram in the presence of CFO, *21st Signal Processing and Communications Applications Conference (SIU)*.
13. Güner, A., Alçin, O.F. and Üstündağ, M., (2016). Feature Analysis of Time and Frequency Domain for Automatic Modulation Classification, *International Artificial Intelligence and Data Processing Symposium*, pp. 404-408.