

Automatic Digital Modulation Classification using Extreme Learning Machine in Frequency Offset

Ahmet Güner

Bingöl Üniversitesi, Elektrik-Elektronik Mühendisliği, Bingöl, 12000

Ömer Faruk Alçın

Bingöl Üniversitesi, Elektrik-Elektronik Mühendisliği, Bingöl, 12000

Mehmet Üstündağ

Bingöl Üniversitesi, Elektrik-Elektronik Mühendisliği, Bingöl, 12000

ABSTRACT

One of the major problems in non-cooperative and intelligent communication systems is the determination of the type of modulation of the received signal. The problem becomes more challenging when there are synchronization errors such as frequency offset and timing offset particularly in real scenarios. In this study, we propose a new automatic modulation classifier that can determine the digital modulation of signal during the frequency offset taking place in the receiver. Performance analysis of the proposed system is simulated for different signal to noise ratios. The obtained results show low calculation complexity and thus be highly successful when compared with traditional classifiers in the low SNR values.

Keywords: Automatic modulation classification, extreme learning machine, high order statistical analysis, histogram

Frekans Kayması Varlığında Aşırı Öğrenme Makinası Kullanarak Otomatik Sayısal Modülasyon Sınıflama

ÖZET

İşbirliksiz ve akıllı haberleşme sistemlerinde önemli problemlerden birisi, alınan işarete ait modülasyon türünün belirlenmesidir. Bu problem, frekans kayması ve zamanlama kayması gibi senkronizasyon hataları olduğu zaman gerçek senaryolarda daha zor bir hal almaktadır. Bu çalışmada, frekans kayması durumunda alınan işarete ait sayısal modülasyon türünün belirlenebildiği yeni bir otomatik modülasyon sınıflandırıcı önerilmektedir. Önerilen sistemin başarımını değerlendirmek için farklı SNR seviyelerinde benzetim çalışmaları yapılmıştır. Elde edilen sonuçlar, geleneksel sınıflandırıcılar ile karşılaştırıldığında düşük SNR değerlerinde önerilen sistemin düşük hesaplama karmaşıklığına ve yüksek başarıma sahip olduğu görülmektedir.

Anahtar Kelimeler: Otomatik modülasyon sınıflama, aşırı öğrenme makinası, yüksek dereceden istatistiksel analiz, histogram.

1 GİRİŞ

Son yıllarda haberleşme standartlarından bağımsız, bulunduğu bölgede geçerli olan haberleşme standartlarına otomatik olarak uyum sağlayabilen akıllı alıcıların kullanımı yaygınlaşmaktadır. Akıllı alıcılar sadece alınan işaretten 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. Zaman kayması, frekans kayması ve çok yönlü bozucu etkilerden dolayı oluşan senkronizasyon hatalarının olduğu gerçek haberleşme senaryolarında bu aşama daha çok önem kazanmaktadır. Özellikle bu senaryolar askeri ve sivil alanlarda, yazılım tanımlı radyo ve akıllı radyo gibi yukarıda ifade edilen akıllı alıcıların kullanıldığı haberleşme sistemlerinde daha da öne çıkmaktadır.

Otomatik modülasyon sınıflama işleminde iki önemli işlem adımı bulunmaktadır. Birincisi, işarete ait olan özniteliğin çıkarılması ve ikincisi öznitelik kullanılarak işarete ait olan modülasyon türünün belirlenmesi için sınıflandırma işlemidir. Literatürde yapılan çalışmalara bakıldığında, kullanılan öznitelikler 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 öznitelikler olarak alınan işarete ait anlık genlik, anlık faz ve anlık frekans bilgileri kullanılmaktadır. Sınıflandırmaya çalışılan modülasyon türleri kümesi, 2ASK, 4ASK, 2FSK, 4FSK, BPSK ve QPSK modülasyon türlerini içermektedir. İşaret-Gürültü Oranı (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 öznitelik olarak seçildiği ve sınıflandırıcı olarak hiyerarşik karar ağacı yapısının kullanıldığı bir yöntem sunulmuştur [2]. Bu çalışma özellikle yüksek dereceden logaritmik momentlerin öznitelik olarak kullanan 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, dalgacık detay dizisinin ve anlık fazının öznitelik olarak seçildiği ve sınıflandırıcı olarak PSO-destek vektör makinelerinin kullanıldığı bir yöntem sunulmuştur [3]. Yapılan çalışmada, SNR değeri 5dB olduğunda doğru sınıflama başarımı %93 üzerinde olmaktadır.

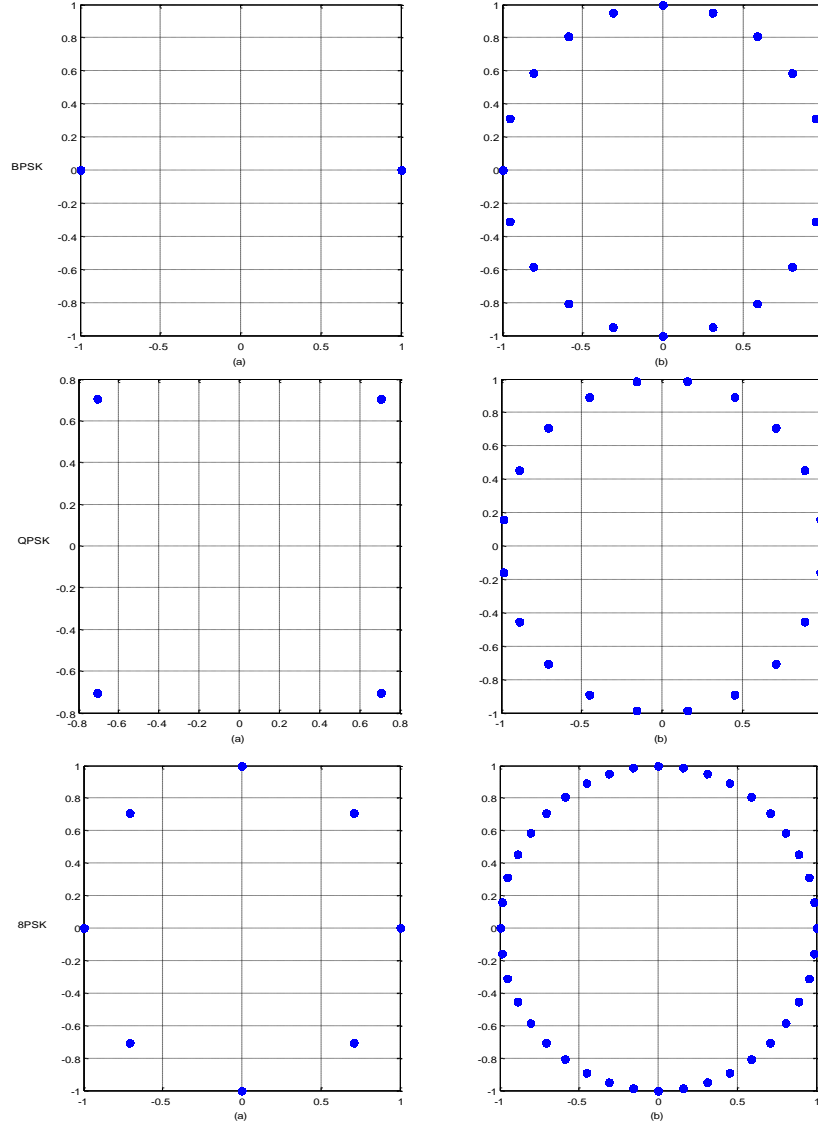
Son yıllarda, karesel genlik modülasyonu (QAM) modem standartlarında ve yüksek kapasiteli radyo sistemlerinde yaygın olarak kullanılmaktadır. Örneğin, 16-QAM modemlerde, 4-QAM ve 64-QAM kablosuz LAN, sayısal video yayınları ve 802.16 WiMAX sistemlerinde kullanılmaktadır. Gelecekteki haberleşme sistemlerinde de bu çok seviyeli modülasyon tiplerinin yaygın olarak kullanılması beklenmektedir [4].

Bu çalışmada, toplanır beyaz Gauss gürültülü (AWGN) kanallarında frekans kaymasının olduğu ASK, PSK ve QAM işaretlerini belirlemek için akıllı bir sistem önerilmektedir. Modüleli işaretlerden yüksek dereceden istatistik ve histogram yöntemleri kullanılarak öznitelikler elde edilmiştir. Sınıflandırıcı için hız ve daha iyi genelleme başarımı gibi üstünlüklerinden dolayı Aşırı Öğrenme Makinası (AÖM) tercih edilmiştir. Ayrıca AÖM yapısı bu alanda yaygın olarak kullanılmadığından dolayı bu alana uygulanabilirliği araştırılmıştır.

Modülasyon sınıflandırıcı yapısında, alınan işaret üzerinde güç normalizasyonu işleminin uygulanmasıyla yıldız kümesi diyagramı üzerindeki noktaların genlik değerlerinin belli bir aralıkta bulunması sağlanmaktadır. Önerilen sınıflandırıcıda, Şekil 1'de gösterilen işaretin yıldız kümesi diyagramı dikkate alınmaktadır. Dolayısıyla öznitelik olarak, yüksek dereceden logaritmik momentler ve frekans

kayması etkisi ile yıldız kümesi üzerindeki noktaların değişimlerinin histogram tepe sayıları kullanılarak sınıflandırma yapılmaktadır.

Çalışmada kullanılan işaret modeli 2. bölümde verilmektedir. 3. bölümde ise sınıflandırıcı yapısı içerisinde kullanılan öznelikler tanıtılmaktadır. 4. bölümde aşırı öğrenme makinasının yapısı sunulmaktadır. Son bölüm olan 5. bölümde ise yapılan benzetim sonuçları verilmektedir.



Şekil 1: Farklı modülasyon türlerinin yıldız kümesi diyagramı (a) normal durum (b) frekans kaymasının olduğu durum ($\Delta f=0.05$)

2 İŞARET MODELİ

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

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

Burada $x(n)$ gönderilen işareti, θ faz kaymasını, ε normalize edilmiş taşıyıcı frekans kaymasını ($\Delta f T_s = \varepsilon$), p alınan işarettaki gücü ve $w(n)$, σ_w^2 varyanslı toplanır beyaz Gaussian gürültüyü göstermektedir. Ayrıca Δf ve T_s taşıyıcı frekans kaymasını ve örnekler arası simge hızını ifade etmektedir.

Bu çalışmada, simge hızı ve taşıyıcı frekansı kestirimlerinin yapıldığı kabul edilmekte ve sembol zamanlama hatası ihmal edilmektedir.

3 ÖZNETELİK ÇIKARMA

Bu çalışmada, alınan işaret $y(n)$ kullanılarak oluşturulan öznitelik seti, üç adet öznitelikten oluşmaktadır. Öznitelik setinin ilk ikisi altıncı dereceden logaritmik momentler olan C_{61} ve C_{63} 'den ve üçüncüsü histogram temelli bir öznitelikten oluşmaktadır. C_{61} özniteliğini çıkarmadan önce alınan işarete faz farkı yöntemi [5] uygulanmaktadır. Bunun nedeni ise faz farkı yöntemi ile PSK modülasyon türlerinde (BPSK, QPSK ve 8PSK) oluşan ve Şekil 1.b'de gösterilen frekans kayması etkisini azaltabilmektir.

3.1 Yüksek Dereceden Logaritmik Moment

Sayısal modülasyonların sınıflandırılmasında en yaygın kullanılan öznitelik, yüksek dereceden istatistiktir. Öznitelik olarak yüksek dereceden istatistik içerisinde n . dereceden momentler ve logaritmik momentler (cumulant) bulunmaktadır. Bu istatistikler, gürültülü işaret yıldız kümelerinin veya gürültülü temel bant örneklerinin şeklini tanımlamaktadır. Ayrıca bu öznitelikler, PSK, ASK ve QAM modülasyon türlerini farklı alt gruplara ayırmak ve her bir alt grup içerisinde sınıflama yapabilmek için etkin bir şekilde uygulanmaktadır[6].

Logaritmik momentlerin öznitelik olarak kullanılmasındaki asıl neden, Gaussian dağılımlı bir verinin yüksek dereceden logaritmik momentlerinin hepsinin sıfır olmasıdır. Bu sebepten dolayı logaritmik moment kullanımıyla, AWGN gürültüsünün etkisi azaltılabilmekte ve hiçbir dönüşüm gerektirmeden zaman düzleminde uygulanabilmektedir [7].

Karmaşık değerli durağan bir işaretin $y(n)$, ikinci, dördüncü ve altıncı dereceden logaritmik momentleri,

$$C_{20} = M_{20} = E [y(n) y(n)] = E [y^2(n)] \quad (2)$$

$$C_{21} = M_{21} = E [y(n) y^*(n)] = E [|y(n)|^2] \quad (3)$$

$$C_{40} = M_{40} - 3M_{20}^2 \quad (4)$$

$$C_{41} = M_{41} - 3M_{20}M_{21} \quad (5)$$

$$C_{42} = M_{42} - |M_{20}|^2 - 2M_{21}^2 \quad (6)$$

$$C_{61} = M_{61} - 5M_{21}M_{40} - 10M_{20}M_{41} + 30M_{20}^2M_{21} \quad (7)$$

$$C_{63} = M_{63} - 9M_{21}M_{42} + 12M_{21}^3 - 3M_{20}M_{43} + 3M_{22}M_{41} + 18M_{20}M_{21}M_{22} \quad (8)$$

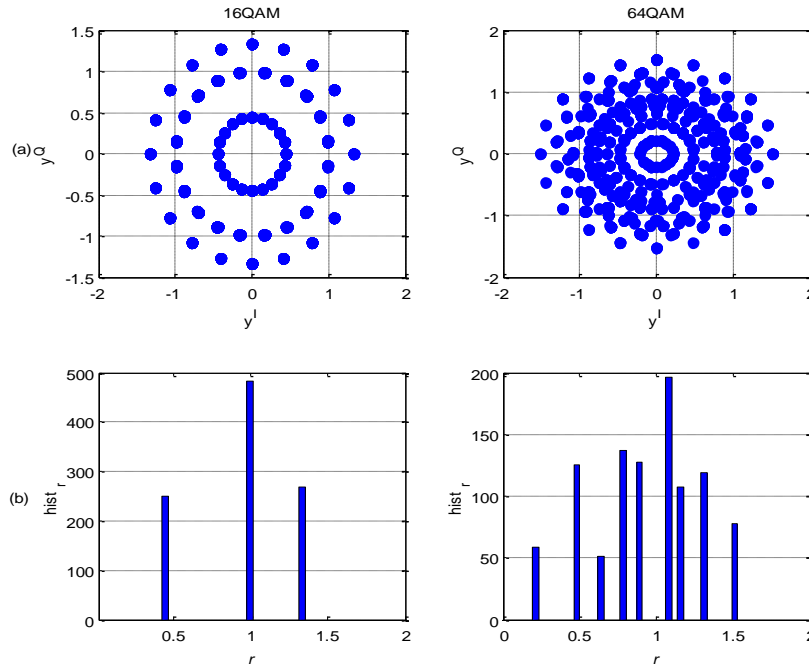
Bu çalışmada sınıflandırma için seçilen modülasyon türlerinin logaritmik moment değerlerinin frekans kayması varken ve yokken elde edilen değerleri Tablo 1'de gösterilmektedir.

Tablo 1. Farklı yıldız kümesi türlerinin logaritmik momentlerinin değerleri

C_{pq}	BPSK	QPSK	8PSK	16QAM	64QAM	4ASK	
C_{20}	0	0	0	0	0	0	
C_{21}	1	1	1	1	1	1	
C_{40}	0	0	0	0	0	0	
C_{41}	0	0	0	0	0	0	
C_{42}	-1	-1	-1	-0.675	-0.619	-0.369	
C_{60}	0	0	0	0	0	0	
C_{61}	0	0	0	0	0	0	
C_{62}	0	0	0	0	0	0	
C_{63}	4	4	4	2.053	1.803	0.203	
$\Delta f=0$	C_{61}	16	-4	0	2.08	1.7972	8.32

3.2 Histogram

Frekans kaymasının etkisi sonucunda alınan işarete ait yıldız kümesi üzerindeki noktalar dairesel olarak dağılmaktadır. BPSK, QPSK ve 8PSK için Şekil 1'de gösterildiği gibi noktaların dağılımları tek bir çember üzerindedir, 16QAM ve 64QAM için Şekil 2.a'da gösterildiği gibi noktaların dağılımları birçok sayıda çember üzerinde bulunmaktadır.



Şekil 2: 16QAM ve 64QAM için frekans kayması varken (a) yıldız kümesi dağılımı (b) histogram dağılımı

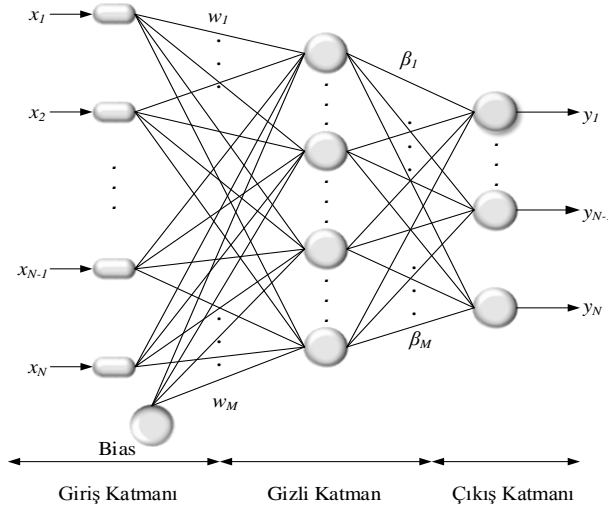
Frekans kayması sonucunda oluşan bu çemberlerin sayısı, 16QAM ve 64QAM modülasyon türlerini frekans kayması varlığında sınıflamak için bir öznitelik olarak kullanılmaktadır. Şekil 2.b'de gösterilen histogramlar üzerindeki tepe noktalarının sayısı (hist), bu özneliğin değerini belirlemektedir.

3.3 Normalizasyon

Normalizasyon, eğitim ve test süreçleri için AÖM sınıflandırıcı için çıkarılan öznitelik matrisini uygulamadan önce gerçekleştirilen bir işlemdir. Öznitelikleri normalize etmekteki amaç, özniteliklerin sıfır ortalamalı ve birim varyanslı olmalarıdır.

4 AŞIRI ÖĞRENME MAKİNASI

AÖM, Tek Gizli Katmanlı İleri Beslemeli (TGKİB) sinir ağı için önerilen bir öğrenme algoritmasıdır [8-10]. AÖM'nin giriş ağırlıkları ve gizli katman eşik değerleri geleneksel ileri beslemeli ağların aksine rastgele üretilir ve tüm süreç boyunca sabit kalır. AÖM'nin çıkış ağırlıkları ise analitik yolla hesaplanır. Bu yaklaşım ile hızlı öğrenme süreci gerçekleştirilir. Ayrıca AÖM geleneksel ileri beslemeli ağlar ile karşılaştırıldığında daha iyi bir genelleme başarımı sergilemektedir [11]. TBKİB ağ modeli Şekil 3'te verilmiştir.



Şekil 3: TGKİB ağ mimarisi

Şekil 3'te verilen TGKİB ağı için bir girdi-çıkı ($x_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T$, $y_i = [y_{i1}, y_{i2}, \dots, y_{in}]^T$) ikilisi olsun. Bu girdi-çıkı ikilisi ve N tane gizli katman nörona ve $g(x)$ aktivasyon fonksiyonuna sahip TGKİB ağı matematiksel modeli;

$$\sum_{i=1}^M \beta_i g(w_i \cdot x_j + b_i) = o_j, \quad j = 1, \dots, N \quad (9)$$

olarak verilebilir. Burada $w_i = [\omega_{i1}, \omega_{i2}, \dots, \omega_{in}]^T$ giriş ağırlık vektörünü, $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ çıkış katmanı ağırlık vektörünü, b_i i'ninci gizli sinir hücresinin eşik değerini ve $o_j = [o_1, o_2, \dots, o_j]^T$ ise TGKİB ağına çıkışı göstermektedir. Eşitlik (9)'da $(w_i \cdot x_j)$ w_i ve x_j 'nin içsel çarpımıdır. TGKİB ağı sıfır hataya yakınsadığı kabul edilirse model;

$$\sum_{i=1}^M \beta_i g(w_i \cdot x_j + b_i) = y_j, \quad j = 1, \dots, N \quad (10)$$

şeklinde yazılabilir. Burada verilen N tane eşitlik matris formunda;

$$Y = H \beta \quad (11)$$

olarak ifade edilebilir. Burada H gizli katman çıkış matrisini, β çıkış katmanı ağırlıklarını ve Y ise çıkış vektörünü ifade etmektedir ve H , β ve Y ifadeleri Eşitlik (12)'de verilmiştir.

$$H = \begin{bmatrix} g(w_1 x_1 + b_1) & \cdots & g(w_N x_1 + b_N) \\ \vdots & \cdots & \vdots \\ g(w_1 x_M + b_1) & \cdots & g(w_N x_M + b_N) \end{bmatrix}_{N \times M}, \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times 1}, Y = \begin{bmatrix} y_1^T \\ \vdots \\ y_N^T \end{bmatrix}_{N \times 1} \quad (12)$$

Eşitlik (11)'den görülebileceği gibi TGKİB ağı doğrusal bir denklem ile ifade edilebilmektedir. AÖM de ağı eğitilmesi β 'nin hesaplanması ile gerçekleştirilmektedir. Bu durum;

$$\beta = H^\dagger Y \quad (13)$$

olarak gösterilebilir. Burada H^\dagger , H 'ın Moore Penrose genelleştirilmiş tersini göstermektedir [8-10].

5 BENZETİM SONUÇLARI

Bu bölümde, BPSK, QPSK, 8PSK, 16QAM, 64QAM ve 4ASK gibi altı farklı sayısal modülasyon türü otomatik modülasyon sistemi ile sınıflandırıldı. Hazırlanan modülasyon seti MATLAB ortamında $M = 2,4,8,16$ seviyelerine kadar rasgele sayıları, düzgün dağılımlı rasgele sayı üretici ile üretilmektedir. Daha sonra her bir modülasyon türü için 2048 örnekten oluşan 1000 adet, toplamda ise 6000 adet veri seti oluşturulmuştur. Ayrıca önerilen otomatik modülasyon sınıflandırıcının başarımını test etmek amacıyla frekans kayması etkisi ve SNR oranları -5dB, -3dB, -2dB, -1dB, 0dB, 1dB, 2dB, 3dB, 5dB, 8dB 10dB ve 15dB olacak şekilde AWGN gürültü eklenmiş ve 12 adet veri paketi hazırlanmıştır. Hazırlanan veri seti her bir modülasyon türünden eşit sayıda içerecek şekilde eğitim için 4200 adet ve test için ise 1800 adet veri ayrılmıştır.

Bu çalışmada otomatik modülasyon belirleme sistemi için sınıflandırıcı olarak AÖM kullanılmıştır. Ampirik yaklaşımla; AÖM'nin gizli katman nöron sayısı 150 ve aktivasyon fonksiyonu "tribas" olarak belirlenmiştir. Frekans kayması olmayan ve gürültüsüz verilerde %100 başarımla elde edilmiştir. Daha sonra benzetim çalışmaları frekans kayması etkisi ve gürültülü veri setleri ile sürdürülmüştür. Yapılan benzetim çalışmalarından elde edilen sonuçlar Tablo 2'de verilmiştir. Tablo 2'de Doğr. doğruluğu, Süre ise toplam eğitim ve test süresini göstermektedir.

Tablo 2. AÖM Sınıflandırıcı sonuçları

	Gürültü (dB)										
	-5	-3	-2	-1	0	1	2	3	5	10	15
Doğr. (%)	71.05	81.94	82.5	85	87.88	87.33	91.38	99	99.67	100	100
Süre (ms)	62.5	15.6	125	125	78.1	125	78.1	15.6	62.5	62.5	125

Tablo 2'den görüleceği gibi AÖM sınıflandırıcısı 2dB ve üstü SNR değerleri için iyi bir başarımla göstermiştir. Ayrıca 0dB, 2dB, 3dB ve 5dB SNR değerleri için sınıf doğruluk matrisi Tablo 3'te verilmiştir. Tablo 3'den görüleceği gibi 0dB SNR'de 4ASK için %100 başarımla elde edilirken 16QAM ve 64QAM modülasyon türleri birbiri ile karıştırılmıştır. 2dB SNR değerinde BPSK, 8PSK ve 4ASK değerleri için %100 başarımla karşılık sınıflandırıcı 16QAM ve 64QAM modülasyon türlerini ayırt etmede iyi bir başarımla gösterememiştir. AÖM sınıflandırıcısı 3dB SNR değerinde 16QAM modülasyon türünde en düşük başarımla elde edilmiştir. 5dB SNR değerlerinde sınıflandırıcı 8PSK modülasyonunu 16QAM ve 64QAM ile karıştırarak en düşük başarımla sergilemiştir.

Tablo 3. Seçilmiş SNR değerleri için sınıf doğruluk tablosu


%	SNR = 0dB						SNR = 2dB					
	BPSK	QPSK	8PSK	16QAM	64QAM	4ASK	BPSK	QPSK	8PSK	16QAM	64QAM	4ASK
BPSK	96,67	0	3,33	0	0	0	100	0	0	0	0	0
QPSK	0	94,67	0	4	1,33	0	0	88,67	0	8,66	2,66	0
8PSK	1,333	0,333	98,33	0	0	0	0	0	100	0	0	0
16QAM	0	10,67	0	63	26,33	0	0	7	0	79	14	0
64QAM	0	2,667	0	26	71,33	0	0	3	0	16,33	80,67	0
4ASK	0	0	0	0	0	100	0	0	0	0	0	100
%	SNR = 3dB						SNR = 5dB					
	BPSK	QPSK	8PSK	16QAM	64QAM	4ASK	BPSK	QPSK	8PSK	16QAM	64QAM	4ASK
BPSK	100	0	0	0	0	0	100	0	0	0	0	0
QPSK	0	100	0	0	0	0	0	100	0	0	0	0
8PSK	0	0	100	0	0	0	0	0	98,67	0,67	0,67	0
16QAM	0	0	0	96,67	3,33	0	0	0	0,33	99,67	0	0
64QAM	0	0	0	2,67	97,33	0	0	0	0	0,33	99,67	0
4ASK	0	0	0	0	0	100	0	0	0	0	0	100

Benzetim çalışmaları Yapay Sinir Ağları (YSA) ile önerilen otomatik modülasyon yönteminin karşılaştırması yapılarak sürdürülmüştür. YSA biyolojik sinir sistemlerinden ilham alınmış hesaplama yöntemidir [12]. YSA sınıflandırıcı parametreleri ampirik yolla elde edilmiştir YSA parametreleri şu şekilde özetlenebilir: 2 gizli katmanlı her katmanda 50 nöron, gizli katmanlar için “tansig” ve çıkış katmanında ise “purelin” aktivasyon fonksiyonu ve öğrenme algoritması olarak “Levenberg-Marquardt” kullanılmıştır. YSA ve AÖM karşılaştırmasından elde edilen sonuçlar Tablo 4’de verilmiştir.

Tablo 4. YSA ve AÖM tekniklerinin farklı SNR değerlerindeki sınıflandırıcı başarımları

		Gürültü (dB)										
		-5	-3	-2	-1	0	1	2	3	5	10	15
Doğr. (%)	AÖM	71.05	81.94	82.5	85	87.88	87.33	91.38	99	99.67	100	100
	YSA	70.44	80.44	81.66	84.83	87.16	86.77	90.94	98.94	99.5	99.94	100
Süre (ms)	AÖM	62.5	15.6	125	125	78.1	125	78.1	15.6	62.5	62.5	125
	YSA	12e3	13e3	13e3	12e3	21e3	20e3	18e3	13e3	26e3	7e3	12e3

Tablo 4’den görüleceği üzere bütün SNR değerlerinde AÖM yöntemi YSA yönteminden daha iyi bir doğruluk yüzdesine sahiptir. Süre açısından bakıldığında ise AÖM çok büyük bir üstünlüğe sahip olduğu görülmektedir. AÖM ve YSA yöntemlerinin farklı SNR değerleri için Doğruluk değişim eğrisi Şekil 4’de verilmiştir. Şekil 4’ten anlaşılacağı gibi AÖM yöntemi YSA yöntemine göre daha iyi sınıflandırma doğruluğuna sahiptir.



Şekil 4: AÖM ve YSA sınıflandırıcının farklı SNR değerleri için Doğruluk değişimi

[1]'de otomatik modülasyon sınıflandırma teknikleri karar-ağacı ve örüntü tanıma yöntemleri olarak iki ana başlık altında gruplandırılmaktadır. Bu amaçla frekans kayması etkisi olan ve 0dB, 2dB, 3dB, 5dB, 8dB ve 10dB SNR değerlerinde ki veri setleri için aynı koşullar altında AÖM ile [12]'de önerilen karar-ağacı yöntemlerinin karşılaştırılması yapılmıştır. Karar-ağacı ile AÖM sınıflandırıcı karşılaştırmasından elde edilen sonuçlar Tablo 5'de verilmiştir.

Tablo 5. Karar-ağacı ve AÖM tekniklerinin farklı SNR değerlerindeki sınıflandırıcı başarımları

SNR	0 dB	2 dB	3 dB	5 dB	8 dB	10 dB
Karar-ağacı	% 33.23	% 40.33	% 48.63	% 66.53	% 99.13	% 99.96
AÖM	% 87.88	% 91.38	% 99	% 99.66	% 100	% 100

Tablo 5 incelendiğinde AÖM sınıflandırıcısı özellikle 0dB, 2dB, 3dB ve 5dB SNR değerlerinde Karar-ağacı sınıflandırıcısından çok daha iyi bir başarımlar göstermektedir. Karar-ağacı yöntemi 8dB SNR değerine kadar kötü bir başarımlar göstermektedir.

6 SONUÇ

Bu çalışmada otomatik modülasyon sınıflandırma sistemi önerilmiştir. Bu modülasyon işaretlerinden yüksek dereceden istatistik ve histogram kullanılarak 3 adet öznelik elde edilmiştir. Önerilen yöntemde sınıflandırıcı olarak AÖM yöntemi düşünülmüştür. Yapılan benzetim çalışmalarında AÖM çok iyi başarımlar göstermektedir. Önerilen sistemin geçerliliğini göstermek amacıyla YSA ve Karar-ağacı yöntemleri ile karşılaştırma yapılmıştır. Karşılaştırmadan elde edilen sonuçlar otomatik modülasyon belirleme sistemi için AÖM yönteminin hem sınıflandırma doğruluğu hem de süre açısından daha etkili olduğunu göstermektedir.

REFERANSLAR

- [1] Nandi, A. K. ve Azzouz, E. E. (1998), "Algorithms for automatic modulation recognition of communication signals", IEEE Transactions Communication, 46, 431-436.

- [2] Swami, A. ve Sadler, B. M. (2000), "Hierarchical digital modulation classification using cumulants", IEEE Transactions on Communications, 48, 3, 416 - 429.
- [3] Yu-e, W., Tian-qi, Z., Juan, B. ve Rui, B., "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), 2011, 266 – 269.
- [4] Liang Hong, "Low-Complexity Identifier for M-ary QAM Signals," SoutheastCON '09.IEEE, pp.164-168, July. 2009
- [5] Tan, X., Zhang, H., Sheng, Y. ve Lu, W., "Blind modulation recognition of PSK signals based on constellation reconstruction", WCSP, 2010, 1-6.
- [6] Ye, Z., Memik, G. ve Grosspietsch, J., "Digital modulation classification using temporal waveform features for cognitive radios", PIMRC, Athens, 2007, 1–5.
- [7] Shih, P. ve Chang, D., "An automatic modulation classification technique using high-order statistics for multipath fading channels", ITST, 2011, 691-695.
- [8] Huang, G. B., Zhu, Q. Y., ve Siew, C. K. (2006). "Extreme learning machine: theory and applications", Neurocomputing, 70(1), 489-501.
- [9] Alçin, Ö. F., Şengür, A. ve İnce, M. C. (2015), İleri-geri takip algoritması tabanlı seyrek aşırı öğrenme makinesi. Journal of the Faculty of Engineering & Architecture of Gazi University, 30(1), 126-132.
- [10] Huang, G. B., Zhu, Q. Y., ve Siew, C. K. (2004), Extreme learning machine: a new learning scheme of feedforward neural networks, IEEE International Joint Conference on Neural Networks, Budapest, 25-29 July, 2, 985-990.
- [11] Hepner, G. F. (1990), "Artificial neural network classification using a minimal training set. Comparison to conventional supervised classification" Photogrammetric Engineering and Remote Sensing, 56(4), 469-473.
- [12] GÜNER, A., KAYA, I., (2013) "Novel Automatic Modulation Classification Method Employing Higher-Order Cumulants and Constellation Histogram in the Presence of CFO", IEEE 21th Signal Processing and Communications Applications, 1(1)