

MFSK Kiplenimli İşaretlerde Dalgacık Ayırıştırması Kullanarak Kiplenim Sınıflandırılması Modulation Classification of MFSK Modulated Signals Using Wavelet Decomposition

Burcu Barış¹, Damla Kuntalp², M. Emre Çek³

^{1,2,3}Elektrik-Elektronik Mühendisliği Bölümü, Dokuz Eylül Üniversitesi, İzmir, Türkiye
{burcu.baris, damla.kuntalp, emre.cek}@deu.edu.tr

Özetçe —Bu çalışmada, akıllı haberleşme sistemlerindeki önemli problemlerden birisi olan alıcıya gelen işarete ait kiplenim türünün belirlenmesi için dalgacık ayırıştırması tabanlı bir yöntem önerilmiştir. Bu yöntemde amaç, M-seviyeli frekans kaydırmalı anahtarlama (M-ary FSK) işaretlerinde kiplenim türünün tespit edilmesi için gönderici işaretin tasarlanması ve Ayrık Dalgacık Dönüşümü (ADD) ile her bir frekans bandına düşen enerjilerin tespit edilmesidir. Bunun için alt bantlardaki işaretlerin standart sapmaları öznitelik olarak kullanılmıştır. Sınıflandırıcının performansını değerlendirmek için farklı işaret gürültü oranı (SNR) seviyelerinde benzetim çalışmaları yapılmıştır. Frekans aralığı değiştirilerek elde edilen sonuçlar karşılaştırıldığında, uygun taşıyıcı frekansı ve frekans aralığı seçildiğinde K-ortalama kümeleme algoritması kullanan sınıflandırıcının literatürde raporlanan sonuçlara göre daha yüksek doğru sınıflandırma başarımına sahip olduğu görülmektedir.

Anahtar Kelimeler—M-seviyeli frekans kaydırmalı anahtarlama (MFSK); ayrık dalgacık dönüşümü; dalgacık ayırıştırması; k-ortalama kümeleme algoritması.

Abstract—In this study, a wavelet decomposition based method is proposed for determining the modulation type of the incoming signal to the receiver which is one of the important problems in intelligent communication systems. In this method, it is aimed to design the transmitted signal for determining the type of M-ary FSK modulated signal and to detect the energy in each frequency band by using Discrete Wavelet Transform (DWT). For this, standard deviations in the lower bands are as features. In order to evaluate the performance of the classifier, simulation studies have been performed at different signal-to-noise ratio (SNR) levels. When the results for different frequency settings, i.e. carrier frequency and frequency range, it is seen that the classifier using the K-means clustering algorithm has a higher correct classification performance than the results reported in the literature when the suitable carrier frequency and frequency range are selected.

Keywords—M-ary frequency shift keying (MFSK); discrete wavelet transform; wavelet decomposition; k-means clustering algorithm.

I. GİRİŞ

Kiplenim sınıflama, alıcıda bilgi işaretinin elde edileceği kip çözme (demodulation) işleminden önce gelen işaretin kiplenim türünün ve/veya seviyesinin tespit edildiği aşamadır [1]. Özellikle askeri ve sivil alanlarda, yazılım tanımlı radyo

ve bilişsel radyo gibi akıllı alıcıların kullanıldığı haberleşme sistemlerinde öne çıkmaktadır [1-3].

Kiplenim sınıflama işleminde iki önemli işlem adımı bulunmaktadır. Birincisi, işarete ait olan özniteliklerin çıkarılması, ikincisi ise bu öznitelikler kullanılarak sınıflandırma işleminin yapılmasıdır [4]. Literatürde, farklı öznitelikler ve sınıflandırıcılar bir araya getirilerek farklı kiplenim sınıflandırıcıları önerilmiştir. Sürekli Dalgacık Dönüşümü (SDD) ve Ayrık Dalgacık Dönüşümü (ADD) ile elde edilen öznitelikler kullanılarak bir işaretin kiplenim türünü otomatik olarak belirleyebilen çeşitli çalışmalar yapılmıştır [5-12].

Maliatsos ve arkadaşları (2007), yayınladıkları makalede, MPSK, MFSK, M-seviyeli genlik kaydırmalı anahtarlama (MASK) ve M-seviyeli karesel genlik anahtarlama (MQAM) gibi kiplenim türleri arasında sınıflandırma yapmak için SDD ile elde edilen işaretlerin varyans değerleri öznitelik olarak kullanmıştır. Farklı SNRlarda, bu özniteliklerin eşik değerleri ayrı ayrı hesaplanmış ve karşılaştırma yapılarak kiplenim türlerine karar verilmiştir [5]. Prakasam ve Madheswaran (2008), MPSK, MQAM, GMSK ve MFSK kiplenim türlerini sınıflandırmak için ilk önce SDD katsayılarından histogram tepeleri elde etmiş ve bunların sahip olduğu tepe sayısına bakmıştır. Ardından hesapladığı yüksek dereceli istatistiksel moment ve varyans değerlerini, belirlediği eşik değerleriyle kıyaslamıştır [6]. Hassan ve arkadaşlarının önerdiği yöntem (2010), SDD katsayılarının yüksek dereceli istatistiksel momentlerini öznitelik olarak kullanmıştır. MASK, MPSK, MFSK, MQAM ve Minimum kaydırmalı anahtarlama (MSK) üzerinde çalışılmış kiplenim türleridir. Sınıflandırıcı olarak Yapay Sinir Ağları (YSA) kullanılmıştır. Farklı dalgacık türleri ve kanal modelleri performansları karşılaştırmışlardır. Ayrıca iki farklı öznitelik seçme algoritmasının da performans kıyaslamaları yapılmıştır [7]. Ho ve arkadaşları (2010), MASK, MFSK veya MPSK kiplenim türüne sahip işaretleri SDD katsayılarının çapraz korelasyonundan elde ettiği sonuçlara sıfır test ve çok seviyeli test yöntemlerini uygulayarak sınıflandırma yapmıştır [8]. MASK, MFSK, MPSK, MQAM ve ASK/PSK kiplenim türlerine sahip işaretleri ayırmak için Valipour ve arkadaşları (2012), sistemin kararlılığını arttırmak için spektral ve istatistiksel tabanlı özniteliklerle birlikte SDD tabanlı özniteliklere de çalışmasında yer vermiştir [9].

Chen ve arkadaşları (2005), MFSK ve MPSK işaretlerini ayırt etmek ve MFSK işaretlerin seviyelerini belirlemek için

ADD ile ayrılmış frekans elemanlarının mesafe vektörünü kullanmıştır [10]. Avcı ve Avcı (2007), ADD ile elde ettiği öznitelik vektörlerinin büyüklüğünü azaltmak için dalgacık entropisini hesaplamıştır. MASK, MPSK ve MFSK işaretlerini sınıflandırmak için YSA sınıflandırıcı algoritmasını kullanan iki ayrı sistem önermiştir. Aynı zamanda, Biorthogonal, Coiflets, Daubechies ve Symlets gibi farklı dalgacık ailelerine ait filtrelerin performanslarını kıyaslayarak önerdiği sınıflandırma sistemlerinin etkinliğini arttırmayı hedeflemiştir [11]. Park ve arkadaşları (2008) da MASK, MPSK, MFSK, MSK ve 16-QAM kiplenim türlerine sahip işaretleri sınıflandırmak için ADD katsayılarının standart sapma değerlerini öznitelik olarak kullanmıştır. Destek Vektör Makinesi ve Karar Ağacı sınıflandırma algoritmalarının performansını karşılaştırmıştır [12].

Bu çalışmada, toplanır beyaz Gauss gürültülü (AWGN) kanallarda MFSK kiplenim türüne sahip işaretleri sınıflandırmak için akıllı bir sistem önerilmektedir. Bu işaretlerden ADD yöntemi kullanılarak öznitelik elde edilmiştir. Sınıflandırıcı algoritması olarak K-ortalama kümeleme algoritması tercih edilmiştir. Yapılan uygulamada çıkarılan özniteliklerin bu işaretleri başarılı olarak karakterize ettiği görülmüştür.

ADD ile elde edilen öznitelikler 2.Bölümde tanıtılmaktadır. 3.Bölümde K-ortalama kümeleme algoritmasının yapısı sunulmaktadır. Son bölümde ise yapılan benzetim çalışmaları ve elde edilen sonuçlar verilmektedir.

II. ÖZNİTELİK ÇIKARIMI

Gürültü eklenmiş kiplenimli işaretler durağan olmayan zaman serileridir ve bu işaretlerin karakteristiklerini bulabilmek için öznitelik çıkarılması gerekir. Sınıflandırıcının eğitimi ve karar aşamasının kısa süre içinde gerçekleşmesi bu nedenle önemli bir adımdır. Kiplenimli işaretlerin yapısına uygun seçicilikte ve gürültüye karşı gürbüz bir öznitelik çıkarımı kararlı bir sınıflandırıcı sistemin oluşmasında önemli bir etkidir [13].

A. Ayrık Dalgacık Dönüşümü (ADD) Tabanlı Öznitelikler

Dalgacık dönüşümü (DD), bir işaretin zaman frekans içeriğini incelemek için yaygın olarak kullanılır. Üzerinde çalıştığımız MFSK kiplenim türüne sahip işaretler, frekans içeriği zamanla değişen durağan olmayan işaretler olduğundan tanımlayıcı öznitelik bilgileri DD ile çıkarılabilir [14]. İşaretleri farklı frekanstaki bileşenlerine ayırıp ayrı ayrı üzerinde çalışmamıza izin verdiği için ADD MFSK işaretleri için uygun öznitelikler çıkarmaya olanak tanır.

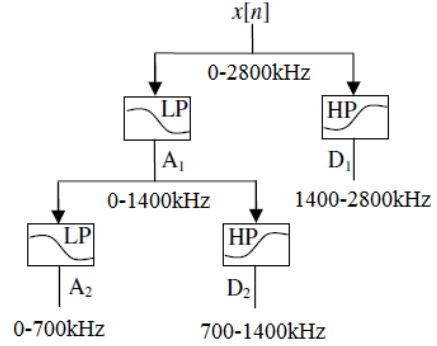
İlke uyarınca, SDD aşağıdaki gibi tanımlanmıştır:

$$\Phi(a, b) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) dt \quad (1)$$

burada a, b , ve $x(t)$ sırasıyla ölçekleme ve kaydırma parametreleri ve işlenecek işaret olarak adlandırılır [15]. Ölçekleme ve kaydırma parametreleri 2'nin katlarına dönüştürülürse, sırasıyla 2^j ve $2^j k$ ile değiştirilir ve ADD aşağıdaki gibi tanımlanabilir [7]:

$$\Theta(j, k) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{|2^j|}} \psi\left(\frac{t-2^j k}{2^j}\right) dt \quad (2)$$

Bir işaretin ADD algoritması, birkaç temel ayrıştırma basamağını gerçekleştirmekten oluşur. ADD ile işaret yüksek geçiren ve alçak geçiren filtrelere sokularak, detay ve yaklaşık katsayıları elde edilir. Bu işlem istenilen frekans bandına erişinceye kadar devam eder. Her ayrıştırma seviyesinde, yarım band filtreler ile frekans çözünürlüğü ikiye katlanır ve zaman çözünürlüğü yarıya indirilir [16].



Şekil 1: İkinci düzey dalgacık ayrıştırmasının yapısı

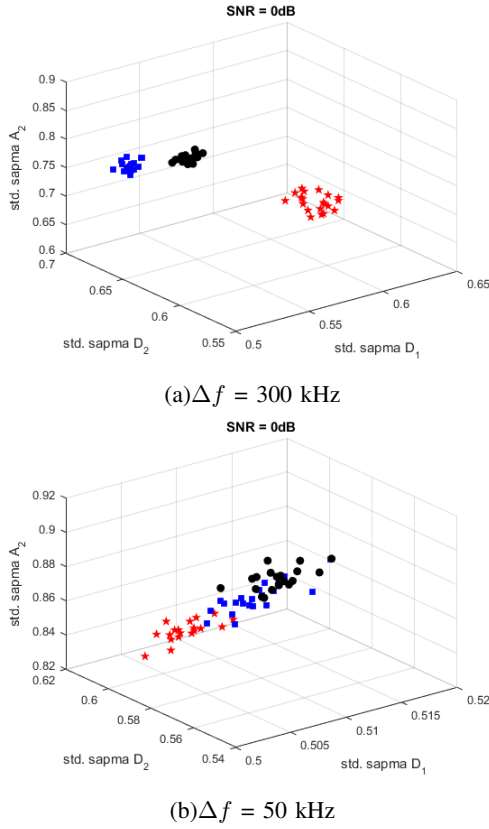
Daubechies dalgacık ailesinin en basit ve en eski olanı Haar (db1) dalgacıdır. Bu dalgacık, kare biçimini andıran bir yapıya sahip, süresiz formdadır [17]. Bu çalışmada, hesaplama kolaylığı ve literatürde sıklıkla kullanıldığından dolayı Haar dalgacı seçilmiştir.

ADD'de dalgacık fonksiyonunun yapısının uygunluğu ve ayrıştırma seviyelerinin sayısı büyük önem taşımaktadır. Şekil 1, 2. düzey dalgacık ayrıştırmasının yapısını göstermektedir. Bu ayrıştırmada, A_1, D_1, A_2 ve D_2 katsayıları işaretin $0-f_s/4, f_s/4-f_s/2, 0-f_s/8$, ve $f_s/8-f_s/4$ bantlarındaki frekans içeriğini temsil eder. f_s işaretin örnekleme frekansıdır. Mevcut çalışmada, Haar ile dağıtılan ADD işaretleri 2 seviyeye ayrıştırmak için uygulandı. Her bir MFSK işaretinden 2 düzey ayrıştırma sonucunda A_1, D_1, A_2 ve D_2 katsayıları olmak üzere toplam 4 işaret elde edildi. Şekil 1, 5600 kHz'de MFSK işaretlerinin ADD tabanlı katsayılarının frekans dağılımını temsil etmektedir. Dalgacık katsayıları, MFSK işaretlerinin ADD kullanılarak alt bantlara ayrılmasıyla her bir segment için elde edildi.

Şekil 2'de görüldüğü üzere, 0 dB SNR seviyesinde frekans aralığı (Δf) değiştirilerek tüm alt bantlardaki katsayıların standart sapma dağılımlarına bakılmıştır. Δf 300 kHz olduğunda A_2 alt bandında bulunan 2 frekans değeri tüm kiplenim değerleri için ortaktır. D_2 alt bandında bulunan 2 frekans değeri ise 4-FSK ve 8-FSK için ortak iken D_1 alt bandı sadece 8-FSK işaretin 4 frekans değerini içerir. Bu sebeple, öznitelik çıkarımı için D_1 ve D_2 alt bantları seçilmiştir. Bu alt bantlardaki dalgacık katsayılarının mutlak değerleri, medyan filtreden geçirilerek standart sapmalarının toplamı çıkarılan öznitelik olarak ele alındı. Bu işlemler (3) numaralı formülde verilmiştir. Δf 50 kHz olduğunda ise tüm kiplenim türlerinin frekans değerleri A_2 alt bandında kalır. D_1 ve D_2 alt bantlarında frekans bileşenleri bulunmaz.

$$y_r = std(med(|D_1|)) + std(med(|D_2|)) \quad (3)$$

burada y önerilen öznitelik değeri, r gerçekleştirme sayısı ($r=1,2,3,...,100$), med ise gürültü bastırmaya yarayan medyan filtrelemeyi gösterir.



Şekil 2: 0 dB'de 2-FSK, 4-FSK ve 8-FSK (20 gerçekleştirme) için A_2 , D_1 ve D_2 katsayılarının standart sapma dağılımları

III. SINIFLANDIRICI

A. K-ortalama Kümeleme Algoritması

Bir kümeleme yöntemi, veriyi öznitelikler arasındaki benzerliklere veya farklılıklara göre gruplara ayırır. K-ortalama kümeleme algoritması, en basit ve en popüler kümeleme algoritmalarından biridir. Bu algoritma, karesel hata tabanlı amaç fonksiyonu adı verilen fonksiyonu minimuma indirgeyerek küme merkezlerini ve bunlara ait elemanları belirler. Algoritmanın amacı, küme merkezlerini mümkün olduğunca birbirinden uzakta konumlandırmak ve her elemanın bulunduğu noktayı en yakın küme merkezine birleştirmektir [18].

Uzaklık ölçüsü olarak öklid uzaklığı kullanılmıştır. Amaç fonksiyonu J aşağıdaki şekilde tanımlanır:

$$J = \sum_{m=1}^M \left(\sum_r ||y_r - c_m||^2 \right) \quad (4)$$

burada M kümelerin sayısı, c_m kümelerin merkezleri ve y_r da m . kümedeki r . eleman noktasıdır. Bir elemanın bulunduğu nokta merkezi bu noktaya en yakın olan bir kümeye aittir [18]. Üyelik matrisi aşağıdaki gibi temsil edilir:

$$u_{mn} = \begin{cases} 1, & \text{eğer } ||y_n - c_m||^2 \leq ||y_n - c_p||^2, \forall p \neq m. \\ 0, & \text{diğer durumlarda.} \end{cases} \quad (5)$$

burada u_{mn} , n . elemanın bulunduğu noktanın m . kümeye ait olup olmadığını gösterir [18]. Amaç fonksiyonunu minimuma

çeken küme merkezleri aşağıdaki gibi tanımlanmıştır:

$$c_m = \frac{\sum_{n=1}^N u_{mn} x_n}{\sum_{n=1}^N u_{mn}} \quad (6)$$

N eleman noktası sayısıdır [18].

IV. BENZETİM SONUÇLARI

Bu çalışmada, MFSK kiplenim türüne sahip işaretlerin sınıflandırılmasına yönelik, ADD tabanlı öznitelik çıkarımı gerçekleştirilmiştir. Önerilen öznitelikler, D_1 ve D_2 ADD katsayılarının standart sapmalarının toplam değeridir. Bilgisayar benzetimleri için MATLAB 2016 programı kullanılmıştır. İşaretlerin benzetimi için kullanılan parametreler ise şöyledir: İşaretler 100 sembolden oluşmakta, örnekleme frekansı (f_s) 5600 KHz, taşıyıcı frekansı (f_c) 300 KHz ve frekans aralığı (Δf) ise 300 kHz dir. Sembol süresi boyunca örnek sayısı 560'tır.

Tablo I: -5 dB, 0 dB ve 5 dB SNR değerlerinde doğru sınıflandırma yüzdeleri $\Delta f = 300$ kHz

SNR = -5 dB			
PCC	2-FSK	4-FSK	8-FSK
2-FSK	%87	%13	%0
4-FSK	%0	%61	%39
8-FSK	%0	%2	%98
SNR = 0 dB			
PCC	2-FSK	4-FSK	8-FSK
2-FSK	%100	%0	%0
4-FSK	%0	%96	%4
8-FSK	%0	%0	%100
SNR = 5 dB			
PCC	2-FSK	4-FSK	8-FSK
2-FSK	%100	%0	%0
4-FSK	%0	%100	%0
8-FSK	%0	%0	%100

Tablo II: -5 dB, 0 dB ve 5 dB SNR değerlerinde doğru sınıflandırma yüzdeleri $\Delta f = 50$ kHz

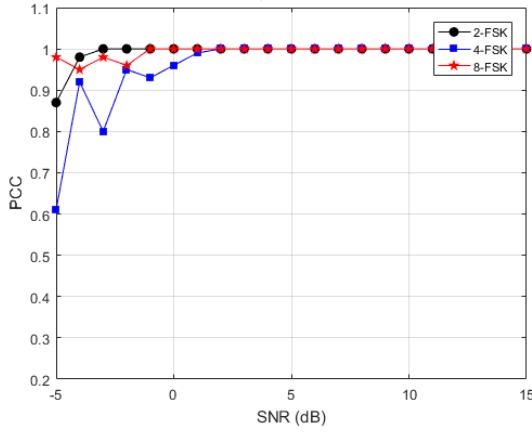
SNR = -5 dB			
PCC	2-FSK	4-FSK	8-FSK
2-FSK	%63	%37	%0
4-FSK	%12	%88	%0
8-FSK	%0	%69	%31
SNR = 0 dB			
PCC	2-FSK	4-FSK	8-FSK
2-FSK	%99	%1	%0
4-FSK	%3	%97	%0
8-FSK	%0	%15	%85
SNR = 5 dB			
PCC	2-FSK	4-FSK	8-FSK
2-FSK	%100	%0	%0
4-FSK	%1	%99	%0
8-FSK	%0	%2	%98

Her bir kiplenim türü için 100 adet, toplamda ise 300 adet veri seti oluşturuldu. SNR oranları -5 dB, 0 dB, 5 dB, 10 dB ve 15 dB olacak şekilde AWGN gürültü eklendi. Önerilen sınıflandırma sisteminin başarımını test etmek amacıyla Δf değiştirilerek etkisi gözlemlendi.

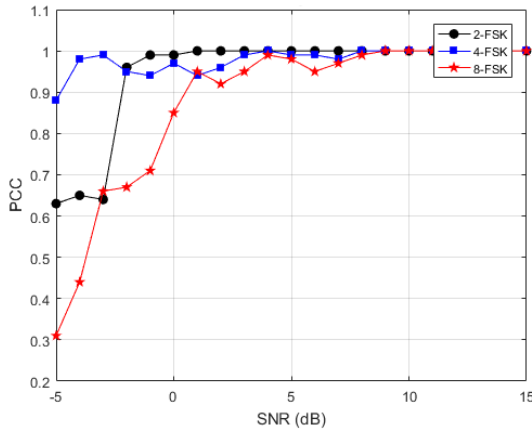
Farklı SNR değerlerinde önerilen sınıflandırıcı sistemin doğru sınıflandırma yüzdesi her bir kiplenim türü için ayrı ayrı olarak Tablo I ve Tablo II de gösterilmektedir. Tablo I de görüldüğü gibi f_s ve Δf değerleri uygun seçildiğinde, sistem düşük SNR larda %100 e yakın sonuçlar vermiştir. 0 dB SNR'de 2-FSK ve 8-FSK kiplenim türleri için %100 başarımlar elde edilirken, 4-FSK, 8-FSK ile karıştırılmıştır. Tablo II ye bakıldığında, Δf , 50 kHz değerine çekildiği zaman, 0 dB SNR değerinde, başarımlar düşmüş sistem özellikle 4-FSK ve 8-FSK kiplenim türlerini ayırt etmede iyi bir başarımlar gösterememiştir.

V. SONUÇ

Bu çalışmada, 2-FSK, 4-FSK ve 8-FSK işaretlerinin ADD katsayılarının standart sapmalarının toplam değerlerini kullanarak basit bir K-ortalama kümeleme algoritması ile pratik bir şekilde sınıflandırılmasını önerdik. Üretilen MFSK işaretlerinin Δf değeri değiştirilerek, 2-FSK, 4-FSK ve 8-FSK işaretlerinin farklı ve aynı bant içinde tutulması sağlanarak performans yüzdeleri kıyaslandı.



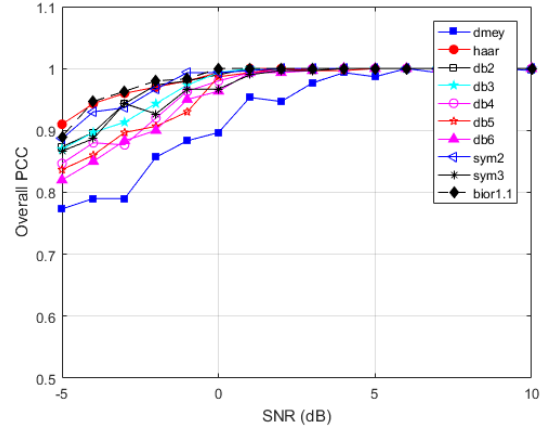
Şekil 3: Farklı SNR değerleri için doğru sınıflandırma olasılığı $\Delta f = 300$ kHz



Şekil 4: Farklı SNR değerleri için doğru sınıflandırma olasılığı $\Delta f = 50$ kHz

Şekil 3'e bakılırsa, SNR değeri 1 dB'nin üzerindeyken sistem %100 başarımla ulaşmaktadır. Şekil 4'te ise Δf 50 kHz değerine çekildiğinde SNR değeri 9 dB'nin üzerindeyken sistemin %100 başarımla yüzdesine sahip olduğu görülmektedir. Önerdiğimiz yöntemin doğru sınıflandırma başarımlar yüzdeleri 0dB SNR da 2-FSK için %100, 4-FSK için %96 ve 8-FSK için %100'dür. Bu sonuçları, yine 0dB SNR seviyesinde, literatürdeki diğer yöntemlerle kıyaslayabiliriz. Chen ve arkadaşlarının yaptığı çalışmada 2-FSK için %100 iken 4-FSK için %98 civarında ve 8-FSK için yaklaşık %96.5 civarındadır [10]. Park ve arkadaşlarının önerdiği yöntem ile elde edilen sonuçlara bakıldığında ise, 0dB SNR'da, 2-FSK işareti için doğru sınıflandırma yüzdesi %45 seviyelerinde iken 4-FSK işareti için bu değer %75 civarındadır [12].

Şekildeki iyi sonuçlar, gürültünün değişmesine duyarlı olma özelliğine sahip ADD katsayılarının özelliklerinden kaynaklanmıştır. Önerilen yöntemin doğru seçilen f_s , f_c ve Δf değerleri ile 0 dB SNR'a kadar tatmin edici bir performans sağlayabileceği kanıtlanmıştır.



Şekil 5: Farklı dalgacıkların doğru sınıflandırma olasılıkları $\Delta f = 300$ kHz

Avcı ve Avcı çalışmasında farklı dalgacık filtreleri ile elde edilen doğru sınıflandırma başarımlarını kıyaslayarak önerdikleri sistemin en yüksek Symlets dalgacık ailesinden "sym2" dalgacığı ile sonuç verdiğini tespit etmişlerdir. Kıyaslamaya Haar dalgacığı dahil edilmemiştir [11]. Bu çalışmada ise Daubechies, Symlets, Discrete Meyer, Biorthogonal dalgacık ailelerinden Haar (db1), db2, db3, db4, db5, db6, sym2, sym3 ve bior1.1 dalgacık filtreleri kullanılarak elde edilen başarımlar kıyaslanmıştır. Şekil 5'te görüldüğü gibi Haar dalgacığı doğru sınıflandırma başarımlarını en yüksek çıkan filtre olmuştur.

Sonraki çalışmalarda farklı kanal modelleri kullanılarak sistemin performansı değerlendirilebilir.

KAYNAKÇA

- [1] P. Ghanekar, S.D. Borde, "Automatic Modulation Classification for Cognitive Radio", *International Journal of Innovative Research in Computer Communication Engineering*, ISSN: 2320-9801, Vol.3, Issue 11, 10556-10561, 2015.
- [2] M.L.D. Wong, A.K. Nandi, "Automatic Digital Modulation Recognition Using Artificial Neural Network and Genetic Algorithm", *Elsevier Signal Processing*, 84(2004), 351-365, 2004.

- [3] S.S. Adjemov, N.V. Klenov, M.V. Tereshonok, D.S. Chirov, "Methods for the Automatic Recognition of Digital Modulation of Signals in Cognitive Radio Systems", *International Journal of Innovative Research in Computer Communication Engineering*, ISSN: 0027-1349, Vol.70, No.6, 448-456, 2015.
- [4] J.J. Popoola, R.V. Olst, "Development and Comparative Study of Effects of Training Algorithms on Performance of Artificial Neural Network Based Analog and Digital Automatic Modulation Recognition", *International Journal of Engineering Science and Technology Review*, 8(4), 135-144, 2015.
- [5] K. Maliatsos, S. Vassaki, P. Constantinou, "Interclass and Intraclass Modulation Recognition Using the Wavelet Transform", *The 18th Annual IEEE International Symposium on Personal, Indoor and Mobile Radio Communications*, 2007.
- [6] P. Prakasam, M. Madheswaran, "Digital Modulation Identification Model Using Wavelet Transform and Statistical Parameters", *Hindawi Publishing Corporation, Journal of Computer Systems, Networks, and Communications*, Vol. 2008, 1-8, 2008.
- [7] K. Hassan, I. Dayoub, W. Hamouda, M. Berbineau, "Automatic Modulation Recognition Using Wavelet Transform and Neural Networks in Wireless Systems", *Hindawi Publishing Corporation, EURASIP Journal on Advances in Signal Processing*, Vol. 2010, 1-13, 2010.
- [8] K. Ho, C. Vaz, D.G. Daut, "Automatic Classification of Amplitude, Frequency, and Phase Shift Keyed Signals in the Wavelet Domain", *IEEE Sarnoff Symposium*, 1-6, 2010.
- [9] M.H. Valipour, M.M. Homayounpour, M.A. Mehralian, "Automatic Digital Modulation Recognition in Presence of Noise Using SVM and PSO", *IEEE 6th International Symposium on Telecommunications*, 378-382, 2012.
- [10] J. Chen, Y. Kuo, J. Li, F. Fu, Y. Ma, "Digital Modulation Identification by Wavelet Analysis", *IEEE 6th International Conference on Computational Intelligence and Multimedia Applications*, 1-6, 2005.
- [11] E. Avci, D. Avci, "The Performance Comparison of Discrete Wavelet Neural Network and Discrete Wavelet Adaptive Network Based Fuzzy Inference System for Digital Modulation Recognition", *Elsevier Expert Systems with Applications*, 35(2008), 90-101, 2008.
- [12] C.S. Park, J.H. Choi, S.P. Nah, W.Jang, "Automatic Modulation Recognition of Digital Signals Using Wavelet Features and SVM", *IEEE 10th International Conference on Advanced Communication Technology*, 387-390, 2008.
- [13] Z. Yaqin, R. Guanghui, W. Xuexia, W. Zhilu, G. Xuemai, "Automatic Digital Modulation Recognition Using Artificial Neural Networks", *IEEE Int. Conf. Neural Networks & Signal Processing*, 257-260, 2003.
- [14] S.S. Hussain, U. Zabit, O.D. Bernal, "Real Time Discrete Wavelet Transform Architecture for Self Mixing Interferometry Signal Processing", *14th International Bhurban Conference on Applied Sciences and Technology*, 323-327, 2017.
- [15] S. Mallat, *A Wavelet Tour of Signal Processing: The Sparse Way*, ISBN: 9780123743701, Elsevier Academic Press, 2008.
- [16] H. Ocak, "Automatic Detection of Epileptic Seizures in EEG Using Discrete Wavelet Transform and Approximate Entropy", *Elsevier Expert Systems with Applications*, 36(2009), 2027-2036, 2009.
- [17] M. Misiti, Y. Misiti, G. Oppenheim, J.M. Poggi, "Chapter 3: From Wavelet Bases to the Fast Algorithm", *Wavelets and Their Applications* içinde kitap bölümü, ISBN: 978-1905209316, Wiley-ISTE, 2007.
- [18] R.O. Duda, P.E. Hart, D.G. Stork, "Chapter 10: Unsupervised Learning and Clustering", *Pattern Classification* içinde kitap bölümü, ISBN:978-0-471-05669-0, Wiley & Sons, 2000.