



KNN and Decision Trees based SPPM demodulators applicable to synchronous modulation techniques

Kubilay Muhammed Sünnetci^{1*}, Ahmet Alkan²

¹Department of Electrical-Electronics Engineering, Faculty of Engineering, Osmaniye Korkut Ata University, Osmaniye, 80010, Turkey

²Department of Electrical-Electronics Engineering, Faculty of Engineering, Kahramanmaraş Sütçü İmam University, Kahramanmaraş, 46000, Turkey

Highlights:

- KNN based Demodulator
- Decision Tree based Demodulator
- Bit error rate and accuracy rate

Keywords:

- Data Mining
- K-Nearest Neighbor Algorithm
- Decision Tree
- Entropy
- Communication

Article Info:

Research Article
Received: 03.03.2021
Accepted: 20.09.2021

DOI:

10.17341/gazimmfd.890721

Correspondence:

Author: Kubilay Muhammed Sünnetci
e-mail:
kubilaysunnetci@osmaniye.edu.tr
phone: +90 328 827 1000

Graphical/Tabular Abstract

In the study, KNN and Decision Trees based demodulators are proposed for M-SPPM technique. In both systems, data bits can be predicted successfully. Here, KNN based demodulators can be applied directly to isochronous systems. However, the information gains of the slots are analyzed for the Decision Trees based system. Herein, the generalized entropy expression is used for Decision Trees. Thus, the suitable system can be determined for Decision Trees based demodulators.

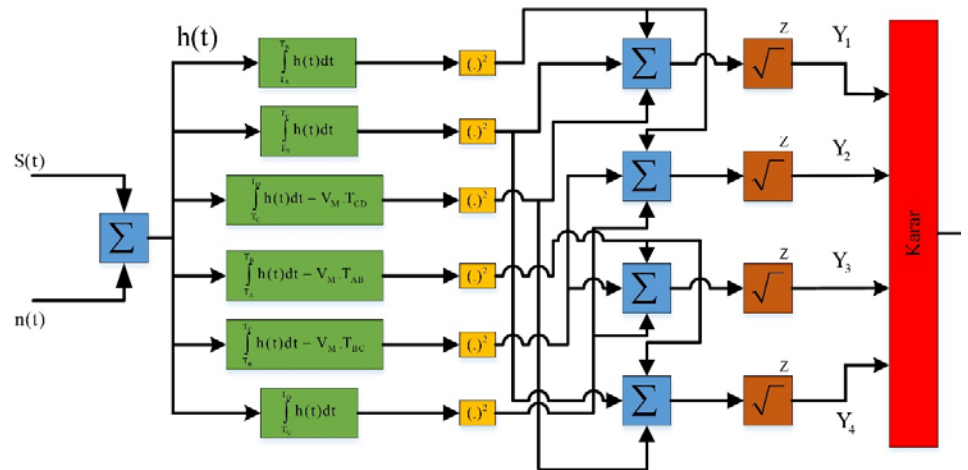


Figure A. KNN demodulator designed for SPPM technique

Purpose: The aim of this study is to design KNN and Decision Trees based demodulators that can be applied to isochronous modulation techniques.

Theory and Methods:

Here, the proposed systems are designed for the SPPM technique. In the training set, M signals are used for the M-SPPM. Herein, the test set has infinite elements. Euclidean, Manhattan or Minkowski distances are determined for the KNN based demodulators. Thus, data bits are estimated according to the minimum distance. In addition, Decision Trees based demodulators have to be created according to the information gain of the slots. They use the generalized entropy expression.

Results:

From the results, it is seen that the bit error rate performances and accuracy rates of KNN and optimally designed Decision Trees based demodulators are the same. Therefore, the proposed systems can be applied to other synchronous modulation techniques.

Conclusion:

KNN and Decision Trees based demodulators have been successfully designed for M-SPPM signals. Herein, the proposed systems can be used for traditional systems.



Senkron modülasyon tekniklerine uygulanabilen KNN ve Karar Ağaçları tabanlı SPPM demodülatörler

Kubilay Muhammed Sünnetci^{1*}, Ahmet Alkan²

¹Osmaniye Korkut Ata Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 80010 Merkez Osmaniye, Türkiye

²Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 46000, Merkez Kahramanmaraş, Türkiye

Ö N E Ç İ K A N L A R

- KNN tabanlı demodülatör tasarımı
- Karar ağaçları tabanlı demodülatör tasarımı
- Bit hata oranı ve doğruluk oranı

Makale Bilgileri

Araştırma Makalesi
Geliş: 03.03.2021
Kabul: 20.09.2021

DOI:

10.17341/gazimmfd.890721

Anahtar Kelimeler:

Veri madenciliği,
K-en yakın komşu
algoritması,
karar ağaçları,
entropi,
haberleşme

ÖZ

Veri madenciliğinin görünür ışık haberleşme sistemlerindeki (Visible Light Communication, VLC) birçok problemi çözebileceği düşünülmektedir. VLC sistemlerde her modülasyon tekniği için farklı alıcı ve verici birimler oluşturulmaktadır. Burada, önerilen sistemler kısaltılmış darbe konum modülasyonu (Shortened Pulse Position Modulation, SPPM) için tasarlanmıştır. Bu çalışmada, senkron modülasyon tekniklerine uygulanabilen K-En Yakın Komşu (K-Nearest Neighbor, KNN) Algoritması ve Karar Ağaçları tabanlı demodülatörler önerilmiştir. Sonrasında, M-SPPM sinyaller için geliştirilmiş bir entropi ifadesi elde edilmiştir. Ayrıca, Manhattan ve Minkowski mesafelerine göre, sinyalleri çözebilen demodülatörler ve diğer demodülatörler doğruluk ve bit hata oranı açısından karşılaştırılmıştır. Nümerik sonuçlardan, önerilen KNN ve Karar Ağaçları tabanlı demodülatörlerin senkron modülasyon teknikleri için geleneksel sistemler olarak kullanılabilmesi görülmektedir. Ayrıca, önerilen KNN tabanlı ve en uygun şekilde tasarlanmış olan karar ağaçları tabanlı demodülatörlerin bit hata oranı performanslarının ve doğruluk oranlarının tamamen aynı olduğu görülmektedir. SNR=10 dB için, 4-SPPM sinyallerde KNN (Demodülatör-1) ve Karar Ağaçları (Demodülatör-3) tabanlı demodülatörlerin doğruluklarının %99,78 olduğu görülmektedir. Burada, 8-SPPM sinyaller için KNN (Demodülatör-2) ve Karar Ağaçları (Demodülatör-5) tabanlı demodülatörlerinin doğrulukları %99,07'dir.

KNN and Decision Trees based SPPM demodulators applicable to synchronous modulation techniques

H I G H L I G H T S

- KNN-based demodulator design
- Decision trees-based demodulator design
- Bit error rate and accuracy rate

Article Info

Research Article
Received: 03.03.2021
Accepted: 20.09.2021

DOI:

10.17341/gazimmfd.890721

Keywords:

Data mining,
K-nearest neighbor
algorithm,
decision tree,
entropy,
communication

ABSTRACT

It is thought that data mining can solve many problems in visible light communication. In the VLC systems, different receiver and transmitter units are usually designed for each modulation technique. Here, the proposed systems are designed for shortened pulse position modulation. In the paper, K-Nearest Neighbor algorithm and Decision Trees based demodulators that can be applied to synchronous modulation techniques are proposed. Afterwards, a generalized entropy expression is obtained for M-SPPM signals. Additionally, demodulators that can decode signals according to the Manhattan and Minkowski distance and other demodulators are compared in terms of accuracy and bit error rate. From the numerical results, it can be seen that the proposed KNN and Decision Trees based demodulators can be used as traditional systems for synchronous modulation techniques. Furthermore, it is seen that bit error rate performances and accuracy rates of the proposed KNN based demodulator and decision trees based demodulator that is optimally designed are completely the same. In 4-SPPM signals, it is seen that the accuracy of KNN (Demodulator-1) and Decision Trees (Demodulator-3) is 98.78% for SNR=10 dB. Here, the accuracy of the KNN (Demodulator-2) and Decision Trees (Demodulator-5) is 99.07% for 8-SPPM signals.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : *kubilaysunnetci@osmaniye.edu.tr, aalkan@ksu.edu.tr /

Tel: +90 328 827 1000

1248

1. GİRİŞ (INTRODUCTION)

Son zamanlarda, veri madenciliği bilim insanları arasında oldukça popüler bir çalışma alanı haline gelmiştir. Bunun nedeni, her bilim alanında farklı veri kümelerinin bulunabilmesidir. Yapılan çalışmalarda, bu veri kümeleri içerisinden en doğru bilgilerin elde edilmesi hedeflenmektedir. Her alanda böyle veri kümelerinin bulunması nedeniyle, gün geçtikçe veri madenciliği uygulamalarının dünya çapında hızlı bir şekilde yayıldığı görülmektedir. Ayrıca, veri madenciliği için en çok tercih edilen çalışmalara örnek olarak sinyal işleme ve görüntü işleme tekniklerinin kullanıldığı sistemler verilebilmektedir. Bu noktada, haberleşme alanında mevcut olan modülatör, kanal ve demodülatör ile ilgili olabilen temel problemler, makine öğrenmesi ve veri madenciliği tabanlı sistemler ile günümüzde henüz yeni çözülebilmeye başlanmıştır. Sınırlılıkları ve kısıtları nedeniyle haberleşme alanı için, makine öğrenmesi yöntemlerinin mevcut problemleri oldukça başarılı bir şekilde çözebileceği de yapılan çalışmalarda görülebilmektedir.

Bu kapsamda, yapılan bir çalışmada güneş ışınımının etkilerini azaltmak suretiyle makine öğrenmesi tabanlı adaptif bir filtre önerilmiştir. Bu akıllı filtre sayesinde değişen gürültü durumlarına rağmen kabul edilebilir bir bit hata oranı performansı elde edilmiştir [1]. Bir diğer taraftan, KNN algoritmasının nispeten küçük bir ortalama olan 8 mm'lik bir konumlandırma hatası ve hesaplama süresinde %42-52 oranında bir iyileştirme sağladığı ve ciddi sınırlamaları aştığı görülmüştür [2]. Görünür ışık haberleşmesi tabanlı parmak izi konumlandırma algoritması olan adaptif ağırlıklı-KNN, düşük bir ortalama konumlandırma hatası sağlaması için önerilmektedir [3]. Aynı şekilde, KNN ve birçok makine öğrenmesi tekniği modülasyon tipi sınıflandırması da yapabilmektedir. Burada, en yüksek ortalama sınıflandırma doğruluğunun, Destek Vektör Makinaları (Support Vector Machine, SVM) tarafından elde edildiği görülmektedir [4]. Modülasyon sınıflandırması için, KNN algoritmasının kullanıldığı başka bir çalışmada beş modülasyon tekniği incelenmiştir. Simülasyon sonuçlarına göre, sınıflandırmanın başarılı bir şekilde gerçekleştiği ayrıca gösterilmiştir [5]. Ayrıca, bu algoritmaların verici tarafında kullanılabileceği gibi alıcı tarafında da kullanılabileceği bilinmektedir. Bu noktada, yapılan bir çalışmada görünür ışık haberleşme sistemlerinin fiziksel katmanındaki makine öğrenmesi tabanlı demodülatörler tasarlanmıştır. Deneysel sonuçlara göre, iletim mesafesi artıkça demodülasyon doğruluğunun da düştüğü görülmektedir [6].

Optik kablosuz haberleşme sistemlerinde, birçok modülasyon tekniği, Aç-Kapa Anahtarlama (On-Off Keying, OOK) tekniğinin kod sözcüklerine göre oluşturulmuştur. Sonrasında, bu tekniğin dezavantajları nedeniyle Darbe Konum Modülasyonu (Pulse Position Modulation, PPM) tabanlı birçok sistem önerilmiştir. Bunlardan birisi olan SPPM tekniğinin temel sinyal

özellikleri, matematiksel ifadeleri ve kodlanmış SPPM sinyalleri yapılan bir çalışmada gösterilmektedir [7]. Bu teknik su altı haberleşmesinde yaygın olarak kullanılmaktadır. SPPM tekniği için yapılan bir çalışmada ilk defa onun tam spektral karakterizasyonu doğrulanmış ve sayısal olarak hem sürekli hem de ayrık spektrumun tahmin edildiği ifadeler sunulmuştur [8]. Modülasyon tekniklerinin incelenmesi için bant genişliği verimliliği, güç verimliliği ve kanal kapasitesi gibi birçok performans analizi yapılabilmektedir. SPPM tekniği için, bu performans analizlerinin bir kısmı yapılan çalışmada gösterilmektedir [9].

Bu çalışmada, KNN algoritması ve karar ağaçları tabanlı demodülatörler SPPM tekniği için tasarlanmıştır. Burada, M-SPPM için, M tane sinyal eğitim kümesinde kullanılmıştır. Sonrasında, elde edilen bütün gürültülü sinyaller tamamen test aşamasında kullanılmaktadır. Önerilen KNN ve karar ağaçları tabanlı demodülatörlerin SPPM tekniği için oluşturulması nedeniyle, çalışmada SPPM tekniğinin detaylı teorik altyapısı oluşturulmuştur. Ayrıca, bütün senkron modülasyon tekniklerine uygulanabilen önerilen demodülatörlerin matematiksel altyapıları detaylıca verilmiştir. Bu noktada, karar ağaçları tabanlı önerilen demodülatörlerin en uygun şekilde tasarlanabilmesi için izlenebilecek yol haritasının oluşturulması suretiyle, birçok karar ağaçları tabanlı demodülatör tasarlanmıştır. Ayrıca, önerilen yöntemler Manhattan ve Minkowski mesafeleri ile tasarlanmış olan ve sinyalleri demodüle edebilen sistemler ile karşılaştırılmıştır. Önerilen sistemler, bit hata oranı, doğruluk oranı açısından incelenmiştir.

2. SİSTEM MODELLEMESİ (SYSTEM MODELING)

Bu çalışmada, SPPM tekniği için farklı demodülatörler önerilmiştir. Önerilen sistemlerde, K-En Yakın Komşu (K-Nearest Neighbor, KNN) Algoritması ve Karar Ağaçları Tekniklerinden faydalanılmaktadır. Her iki sistemin de avantajları ve dezavantajlarının incelenmesi yapılan çalışmanın amaçlarındandır. Ayrıca, SPPM tekniği sırasıyla, $M=4$ ve $M=8$ için incelenmiştir. Burada, M, sinyal seviyesini ifade etmektedir ($L=\log_2^M$). L ifadesi bit çözünürlüğünü belirtmektedir. Ayrıca, önerilen sistemlerin performans karşılaştırmalarının yapılabilmesi için, SPPM tekniğinin detaylı matematiksel altyapısı oluşturulmuştur. Böylece, önerilen modülatör ve demodülatör blokları, SPPM tekniği için daha iyi anlaşılabilir. Bu noktada, sistemlerin bit hata oranı (Bit Error Rate, BER), hatasız iletilen veri oranı ya da doğruluk oranı (Accuracy Rate, AR) incelenmektedir.

Şekil 1'de, aç-kapa anahtarlama (On-Off Keying, OOK) kod sözcüklerine göre, kodlanmış SPPM sinyalleri ve kullanılan eğitim kümesi verilmektedir. Şekil 1a ve Şekil 1b'de, M değerleri sırasıyla 4 ve 8'e eşittir. Şekilde V_M sinyal darbelerinin genlik değerlerini göstermektedir. Şekil 1a'da, bir bit iletim süresi (T_b), $3T_S$ 'e eşittir. Şekil 1b'de bir bit iletim süresi ise $5T_S$ 'e eşittir. Burada, T_S , bir yuva iletim süresi olarak ifade edilmektedir. Ayrıca, şekilde V_{Max} ve

V_{Min} 'in sırasıyla V_M ve 0'a eşit olduğu görülmektedir. Şekil 1'in daha iyi anlaşılabilmesi için, OOK kod sözcüklerine göre kodlanmış olan SPPM sinyalleri Tablo 1 ve Tablo 2'de verilmiştir.

Tablo 1. OOK kod sözcüklerinin 4-SPPM tekniği ile eşleştirilmesi (Mapping of OOK code into 4-SPPM)

OOK	4-PPM	MPPM(4,2)	4-DPPM	4-OPPM	4-SPPM
00	0001	1100	1	00	0 01
01	0010	0110	01	01	0 10
10	0100	0011	001	10	1 01
11	1000	1001	0001	11	1 10

Tablo 1 ve Tablo 2'de, farklı modülasyon teknikleri için, OOK tekniğine göre kodlanmış sinyaller verilmektedir [7]. Tablo 1'de, çok seviyeli darbe konum modülasyonu (Multi Level Pulse Position Modulation, MPPM) hariç, diğer modülasyon teknikleri için; M, 4'e eşittir. Tabloda gösterilen modülasyon teknikleri için, 2 bit iletelebilmektedir. Tablo 2'de, MPPM (5,2) hariç, diğer modülasyon teknikleri için, M değeri 8'dir. Her iki tabloda da, sinyaller OOK tekniğine göre kodlanmıştır. Ayrıca, Tablo 2'de, L ifadesinin 3'e eşit olduğu görülmektedir. Burada, her iki tabloda da bulunan bütün modülasyon teknikleri için, bir yuva iletim süresi T_s olarak belirlenmiştir. M seviyeli bir SPPM sinyal için, birinci yuvaların işaret bitini ifade ettiği ayrıca tablolarda görülebilmektedir. Önerilen sistemin teorik alt yapısının

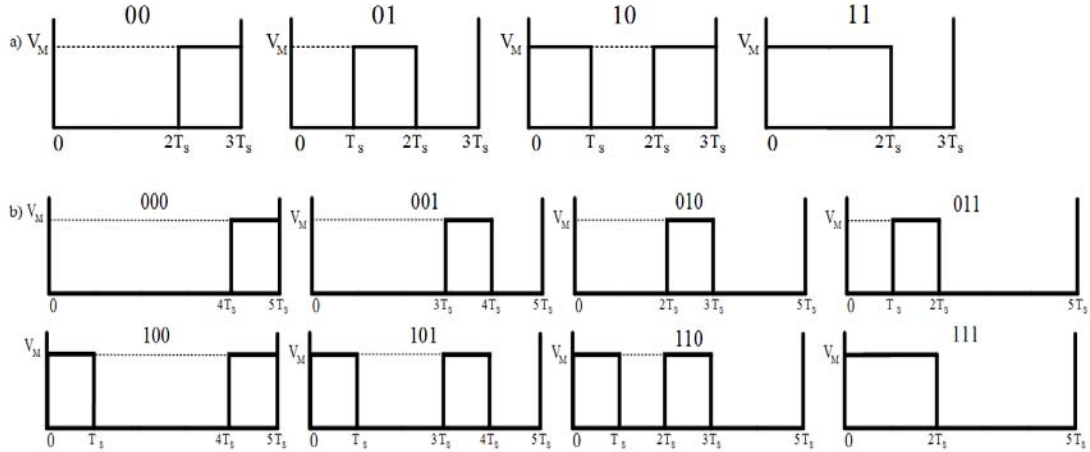
oluşturulabilmesi açısından, T_i ve T_j ifadeleri Eş. 1-Eş. 3'teki gibi yazılabilir.

$$T_{PQ} = T_{QP} = |T_P - T_Q| \tag{1}$$

$$T_{AB} = T_{BC} = T_{CD} = T_{DE} = T_{EF} = T_s \tag{2}$$

$$T_{AA} = T_{BB} = T_{CC} = T_{DD} = T_{EE} = T_{FF} = 0 \tag{3}$$

Eş. 1, Eş. 2 ve Eş. 3'te, SPPM tekniğinin teorik alt yapısını oluşturan başlıca formüller verilmiştir. Burada, T_i , zaman düzleminin i. konumunu ifade etmektedir. Ayrıca, T_{ij} , i. ve j. konumlar arasındaki mesafeyi hesaplamaktadır. Bu nedenle, $T_{ij}, T_{ji} \geq 0$ olmak zorundadır. Böylece, Eş. 1 elde edilebilmektedir. Eş. 2'de, bir yuva iletim süresinin T_s olduğu görülmektedir. Burada, A-B-C-D-E-F, yuvaların başlangıç ve bitiş noktalarını göstermektedir. SPPM tekniğinde, M=4 için, AB-BC-CD değişkenleri kullanılmaktadır. 4-SPPM tekniği için, bir bit süresinin $3T_s$ olması, bu durumu açıklayabilmektedir. 8-SPPM tekniğinde, DE ve EF değişkenleri de ayrıca hesaplanmaktadır. Bunun nedeni, 8-SPPM tekniğinin bir bit iletim süresinin $5T_s$ olmasıdır. Ayrıca, Eş. 1'de, T_{ij} ve $i=j$ için, T_{ii} veya T_{jj} elde edilmektedir. Bu noktada, T_{ii} ve T_{jj} ifadelerinin 0'a eşit olduğu Eş. 3'te görülmektedir. Şekil 2'de, SPPM tekniği için, T_i değerleri gösterilmektedir. Şekil 2a ve Şekil 2b için,



Şekil 1. 4-SPPM ve 8-SPPM sinyalleri için kullanılan eğitim kümesi (Training set used for 4-SPPM and 8-SPPM signals)

Tablo 2. OOK kod sözcüklerinin 8-SPPM tekniği ile eşleştirilmesi (Mapping of OOK code into 8-SPPM)

OOK	8-PPM	MPPM(5,2)	8-DPPM	8-OPPM	8-SPPM
000	00000001	11000	1	0000	0 0001
001	00000010	01100	01	0001	0 0010
010	00000100	00110	001	0010	0 0100
011	00001000	00011	0001	0100	0 1000
100	00010000	10001	00001	1000	1 0001
101	00100000	10100	000001	1001	1 0010
110	01000000	00101	0000001	1010	1 0100
111	10000000	01010	00000001	1100	1 1000

sırasıyla M değerleri 4 ve 8'e eşittir. Ayrıca, Şekil 2a'da, mantıksal '10' için kodlanmış 4-SPPM sinyali gösterilmektedir. Şekil 2b'de ise mantıksal '100' kod sözcüğü için, kodlanmış 8-SPPM sinyali verilmiştir.

$$T_A = T_b(k-1) + T_{AA} \quad (4)$$

$$T_B = T_b(k-1) + T_{AB} \quad (5)$$

$$T_C = T_b(k-1) + T_{AC} \quad (6)$$

$$T_D = T_b(k-1) + T_{AD} \quad (7)$$

$$T_E = T_b(k-1) + T_{AE} \quad (8)$$


$$T_F = T_b(k-1) + T_{AF} \quad (9)$$

Eş. 4-Eş. 9'da, T_i ifadesinin matematiksel formülleri verilmiştir. Eş. 1-3 kullanılarak, Eş. 4-Eş. 9 yeniden yazılabilmektedir. Eş. 1- Eş. 3'e göre, $T_{AA}=0$, $T_{AB}=T_S$, $T_{AC}=2T_S$, $T_{AD}=3T_S$, $T_{AE}=4T_S$ ve $T_{AF}=5T_S$ olmaktadır. Burada, 4-SPPM tekniği için, Eş. 4- Eş. 7 kullanılıyorken, 8-SPPM tekniği için, Eş. 4- Eş. 9 kullanılmaktadır. Ayrıca, T_i ifadesi her k ($\forall k$) değeri için güncellenmektedir. Bu noktada, yuvalar, Şekil 2'de ki gibi sürekli olarak kodlanmaktadır. k, değeri, T_i ifadelerinin belirlenmesinde kullanılan pozitif bir tam sayıdır ($k \in \mathbb{Z}^+$). Ayrıca, Eş. 1- Eş. 9, SPPM tekniğinin modülatör ve demodülatör blok diyagramlarında kullanılmaktadır.

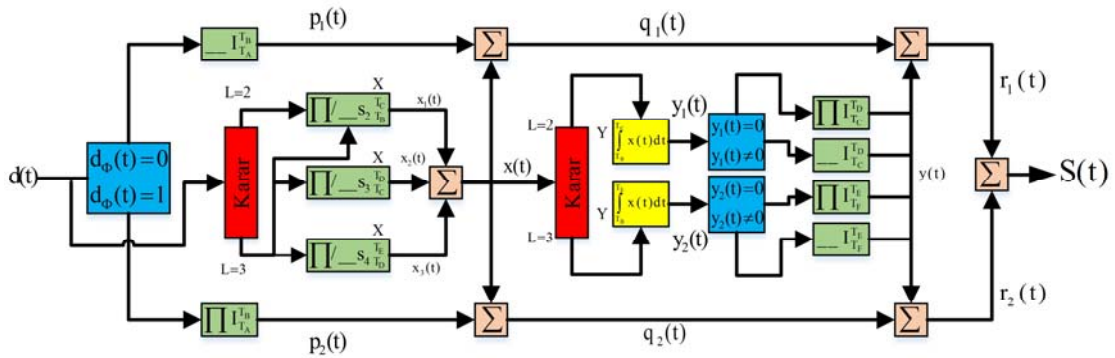
Şekil 3'te, SPPM tekniğinin modülatör blok diyagramı, $M=4$ ve $M=8$ için verilmiştir. Şekilde gösterilen $d(t)$, veri bit

fonsiyonu olarak adlandırılmaktadır. $d_\Phi(t)$, OOK kod sözcüklerinin Φ . elemanını göstermektedir. Ayrıca, Φ değişkeni, $L.k-(L-1)$ ifadesi yardımıyla hesaplanabilmektedir. $d_\Phi(t)$ fonksiyonu, veri bitlerinin mantıksal durumlarına göre, SPPM sinyallerinin birinci yuvalarını kodlamaktadır. Böylece, $p_i(t)$ fonksiyonları elde edilebilmektedir. Aynı zamanda, L değerlerine göre, ikinci veya ikinci-üçüncü-dördüncü yuvalar kodlanmaktadır. Burada, s_i , i. yuvayı belirtmektedir. Birinci karar aşamasında, veri bitleri bilindiği için, X blokları, \prod ve $\bar{\prod}$ sinyallerini veri bitlerine göre kodlamaktadır. Böylece, $x_i(t)$ fonksiyonları elde edilebilmektedir. Sonrasında, $\sum_i x_i(t)$ ifadesi sayesinde, $x(t)$ fonksiyonu bulunabilmektedir. $p_i(t)$ ve $x(t)$ fonksiyonları toplanarak, $q_i(t)$ fonksiyonları elde edilebilmektedir. Böylece, ikinci karar aşamasında son yuvalar kodlanabilmektedir. $x_i(t)$ fonksiyonlarının sınır değerleri, Y integratör bloklarının sınır değerlerini belirlemektedir. Bu sayede, $y_i(t)$ fonksiyonları elde edilmektedir. Elde edilen $y_i(t)$ fonksiyonları ve L değerlerine göre, SPPM sinyallerin son yuvaları kodlanabilmektedir. Sonrasında, $q_i(t)$ ve $y(t)$ fonksiyonları toplanarak $r_i(t)$ fonksiyonu belirlenir. $\sum_i r_i(t)$ ifadesi yardımıyla, $S_{4-SPPM,8-SPPM}(t)$ fonksiyonları bulunabilmektedir. Ayrıca, $S_{4-SPPM,8-SPPM}(t)$, modüasyonlu bilgi sinyalleri fonksiyonu olarak adlandırılmaktadır.

$$S_{4-SPPM}(t) = \left(\prod_{k=1}^{\infty} \left(\frac{t - \frac{T_A + T_B}{2}}{T_{AB}} \right) * f(d_\Phi^k(t)) + \prod_{k=1}^{\infty} \left(\frac{t - \frac{T_B + T_C}{2}}{T_{BC}} \right) * f(d_{\Phi+1}^k(t)) \right) + \left(\prod_{k=1}^{\infty} \left(\frac{t - \frac{T_C + T_D}{2}}{T_{CD}} \right) * (1 - f(d_{\Phi+1}^k(t))) \right) \quad (10)$$



Şekil 2. 4-SPPM ve 8-SPPM sinyalleri için T_i değerleri (T_i values for 4-SPPM and 8-SPPM signals)



Şekil 3. M=4 ve M=8 için SPPM tekniğinin modülatör blok diyagramı (Modulator block diagram of the SPPM technique for M=4 and M=8)

$$S_{8\text{-SPPM}}(t) = \sum_{k=1}^{\infty} V_M \left(\prod_{i=1}^k \left(\frac{t - T_A + T_B}{T_{AB}} \right) * f(d_{\Phi}^k(t)) + \prod_{i=1}^k \left(\frac{t - T_B + T_C}{T_{BC}} \right) * g_1(t) + \prod_{i=1}^k \left(\frac{t - T_C + T_D}{T_{CD}} \right) * g_2(t) + \prod_{i=1}^k \left(\frac{t - T_D + T_E}{T_{DE}} \right) * g_3(t) + \prod_{i=1}^k \left(\frac{t - T_E + T_F}{T_{EF}} \right) * g_4(t) \right) \quad (11)$$

$$g_i(t) = \left(\begin{array}{l} g_1(t) = g_2(t) = g_3(t) = 0, g_4(t) = 1; \\ d_{\Phi+1}^k(t) = d_{\Phi+2}^k(t) = 0, \\ g_1(t) = g_2(t) = g_4(t) = 0, g_3(t) = 1; \\ d_{\Phi+1}^k(t) + 1 = d_{\Phi+2}^k(t) = 1, \\ g_1(t) = g_3(t) = g_4(t) = 0, g_2(t) = 1; \\ d_{\Phi+1}^k(t) = d_{\Phi+2}^k(t) + 1 = 1 \\ g_2(t) = g_3(t) = g_4(t) = 0, g_1(t) = 1; \\ d_{\Phi+1}^k(t) = d_{\Phi+2}^k(t) = 1 \end{array} \right) \quad (12)$$

Eş. 10 ve Eş. 11’de, sırasıyla 4-SPPM ve 8-SPPM tekniklerinin modülasyonlu bilgi sinyalleri fonksiyonları verilmiştir. Bu nedenle, M değerleri eşitlik 10 ve 11 için sırasıyla 4 ve 8’e eşit olmaktadır. Eşitliklerde $\prod(t)$, darbe işaret fonksiyonu olarak tanımlanmaktadır. $(T_i+T_j)/2$ ifadesi, sinyal darbelerinin merkez noktalarını kodlamaktadır. Ayrıca, T_{AB} , T_{BC} , T_{CD} , T_{DE} ve T_{EF} ifadeleri sinyal darbelerinin genişliklerini belirlemektedir. Bu noktada, $f(t)$ ve $g_i(t)$ fonksiyonlarına ihtiyaç duyulmaktadır. Çünkü, OOK kod sözcüklerine göre, kodlanmış sinyallerin genlik değerlerinin de kodlanması gerekmektedir. Eşitliklerde, $f(t)$ birim fonksiyon olarak tanımlanmıştır ($f: R \rightarrow R$, $f(t)=t$). Ayrıca, $d_i^j(t)$ fonksiyonu, j. OOK kod sözcüğünün i. elemanını ifade etmektedir. Eş. 10 ve Eş. 11’de, işaret bitlerinin $f(t)$ fonksiyonu yardımıyla kodlandığı görülebilmektedir. 8 seviyeli SPPM sinyalleri için, $g_i(t)$

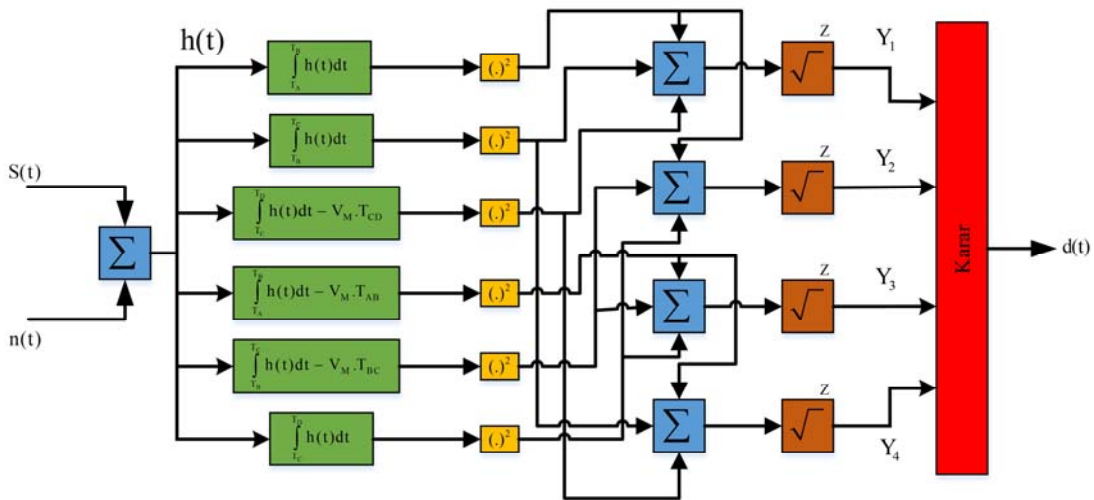
fonksiyonları kullanılmaktadır. Burada, OOK kod sözcüklerine göre, $g_1(t)$, $g_2(t)$, $g_3(t)$ ve $g_4(t)$ fonksiyonları belirlenmektedir. Böylece, 8-SPPM sinyaller için, modülasyonlu bilgi sinyali fonksiyonu ($S_{8\text{-SPPM}}(t)$) oluşturulabilmektedir.

Şekil 4’te, SPPM tekniğinin KNN (K=1) tabanlı önerilen demodülatör (Demodülatör-1) blok diyagramı M=4 için verilmiştir. Şekilde, $n(t)$ gürültü sinyali olarak tanımlanmaktadır. Ayrıca, $h(t)$ fonksiyonunun, $S(t)$ ve $n(t)$ fonksiyonlarının toplanmasıyla elde edildiği görülmektedir. Böylece, $h(t)$ fonksiyonu integratör bloklarına iletelebilmektedir. Elde edilen integratör çıkışları, $(.)^2$ fonksiyonlarının girişlerine uygulanmaktadır. $(.)^2$ fonksiyonu, giriş değerlerinin karesini almaktadır. Bu sayede, elde edilen pozitif değerler, Şekil 4’te de görüldüğü gibi toplanabilmektedir. Sonrasında, toplam sonuçları, Z bloklarına iletilmektedir. Z blokları, giriş değerlerinin karekökünü almaktadır. Böylece, Y_1 , Y_2 , Y_3 , Y_4 değerleri hesaplanabilmektedir. Karar aşamasında, Y_i değerlerine göre, veri bitleri tahmin edilmektedir. Bu noktada, $d(t)$ fonksiyonu elde edilebilmektedir.

$$Y_i = \sqrt{\sum_{j=A}^C \left(\int_j^{j+} h(t)dt - V_M \cdot T_{j,j+} \cdot \theta_{j,j+}(t) \right)^2} \quad (13)$$

$$\theta_{j,j+}(t) = \left(\begin{array}{ll} \theta_{AB}(t) = \theta_{BC}(t) = 0, \theta_{CD}(t) = 1, & Y_i = Y_1 \\ \theta_{AB}(t) = \theta_{CD}(t) = 0, \theta_{BC}(t) = 1, & Y_i = Y_2 \\ \theta_{AB}(t) = \theta_{BC}(t) = 1, \theta_{CD}(t) = 0, & Y_i = Y_3 \\ \theta_{AB}(t) = \theta_{CD}(t) = 1, \theta_{BC}(t) = 0, & Y_i = Y_4 \end{array} \right) \quad (14)$$

Eş. 13’te, KNN tabanlı önerilen demodülatör için, Y_i değerleri verilmiştir. Eş. 13, 4-SPPM sinyaller için kullanılabilir. Bu nedenle, $j_{Max}=C$ olmaktadır. Eşitliğe göre, j, {A,B,C} kümesinin elemanıdır. Eğer j, A ve C’ye eşit olursa, j+ ifadesi sırasıyla B ve D olmaktadır.



Şekil 4. M=4 için, KNN tabanlı demodülatörün blok diyagramı (Block diagram of KNN based demodulator for M=4)

Ayrıca, $\theta_{j,j^+}(t)$ fonksiyonu, Şekil 4'te gösterilen demodülatör blok diyagramına göre oluşturulmuştur. Y_i değişkenlerinin i. indisine göre değişen $\theta_{AB}(t)$, $\theta_{BC}(t)$ ve $\theta_{CD}(t)$ fonksiyonları Eş. 14'te verilmektedir.

$$Y_1 = \sqrt{\left(\int_{T_A}^{T_B} h(t)dt\right)^2 + \left(\int_{T_B}^{T_C} h(t)dt\right)^2 + \left(\int_{T_C}^{T_D} h(t)dt - V_M \cdot T_{CD} \cdot \theta_{CD}(t)\right)^2} \quad (15)$$

$$Y_2 = \sqrt{\left(\int_{T_A}^{T_B} h(t)dt\right)^2 + \left(\int_{T_B}^{T_C} h(t)dt - V_M \cdot T_{BC} \cdot \theta_{BC}(t)\right)^2 + \left(\int_{T_C}^{T_D} h(t)dt\right)^2} \quad (16)$$

$$Y_3 = \sqrt{\left(\int_{T_A}^{T_B} h(t)dt - V_M \cdot T_{AB} \cdot \theta_{AB}(t)\right)^2 + \left(\int_{T_B}^{T_C} h(t)dt - V_M \cdot T_{BC} \cdot \theta_{BC}(t)\right)^2 + \left(\int_{T_C}^{T_D} h(t)dt\right)^2} \quad (17)$$

$$Y_4 = \sqrt{\left(\int_{T_A}^{T_B} h(t)dt - V_M \cdot T_{AB} \cdot \theta_{AB}(t)\right)^2 + \left(\int_{T_B}^{T_C} h(t)dt\right)^2 + \left(\int_{T_C}^{T_D} h(t)dt - V_M \cdot T_{CD} \cdot \theta_{CD}(t)\right)^2} \quad (18)$$

Eş. 15- Eş. 18, Eş. 13 ve Eş. 4 birleştirilerek elde edilmiştir. Bu eşitliklerde, Y_1 , Y_2 , Y_3 ve Y_4 değerleri sırasıyla verilmektedir. Ayrıca, Eş. 15- Eş. 18'de $\theta_{j,j^+}(t)$ fonksiyonu, Eş. 14'te ki gibi kullanılabilir.

$$d(t) = \begin{cases} 00, & \arg \min_Y [Y_i] = Y_1 \\ 01, & \arg \min_Y [Y_i] = Y_2 \\ 11, & \arg \min_Y [Y_i] = Y_3 \\ 10, & \arg \min_Y [Y_i] = Y_4 \end{cases} \quad (19)$$

Eş. 19'da tahmin edilen veri bitleri fonksiyonu verilmektedir. Eş. 15- Eş. 18'de, hesaplanabilen Y_i değerlerine göre, veri bitleri tahmin edilebilmektedir. Bu noktada, en küçük Y_i değeri bulunmaktadır. Eğer, $Y_1 < Y_2, Y_3, Y_4$ ise tahmin edilen veri bitinin mantıksal durumu '00', $Y_3 < Y_1, Y_2, Y_4$ ise veri bitinin mantıksal durumu '11' olarak belirlenmektedir. Şekil 5'te, SPPM tekniğinin KNN ($K=1$) tabanlı önerilen demodülatör (Demodülatör-2) blok diyagramı $M=8$ için verilmiştir. Şekil 4 ve Şekil 5'te de

görüldüğü gibi, 4-SPPM ve 8-SPPM teknikleri için kullanılan demodülatör mimarileri tamamen aynıdır. 8-SPPM sinyallerde, $M=8$ olduğu için, $Y_{Max}=Y_8$ olmaktadır ($Y_{Max}=Y_M$). Böylece, Y_i değerlerine göre, karar aşamasında veri bitleri tahmin edilebilmektedir.

$$Y_i = \sqrt{\sum_{j=A}^E \left(\int_j^{j^+} h(t)dt - V_M \cdot T_{j,j^+} \cdot \theta_{j,j^+}(t)\right)^2} \quad (20)$$

$$d(t) = \begin{cases} 000, & \arg \min_Y [Y_i] = Y_1 \\ 100, & \arg \min_Y [Y_i] = Y_2 \\ 001, & \arg \min_Y [Y_i] = Y_3 \\ 101, & \arg \min_Y [Y_i] = Y_4 \\ 010, & \arg \min_Y [Y_i] = Y_5 \\ 110, & \arg \min_Y [Y_i] = Y_6 \\ 011, & \arg \min_Y [Y_i] = Y_7 \\ 111, & \arg \min_Y [Y_i] = Y_8 \end{cases} \quad (21)$$

Eş. 20 ve Eş. 21'de, 8-SPPM sinyallerinin demodüle edilebilmesi için, kullanılan matematiksel ifadeler verilmiştir. Ayrıca, $M=8$ için j , $\{A,B,C,D,E\}$ kümesinin elemanıdır. Eş. 21'de de görüldüğü gibi, en küçük Y_i değerine göre, veri bitleri tahmin edilmektedir.

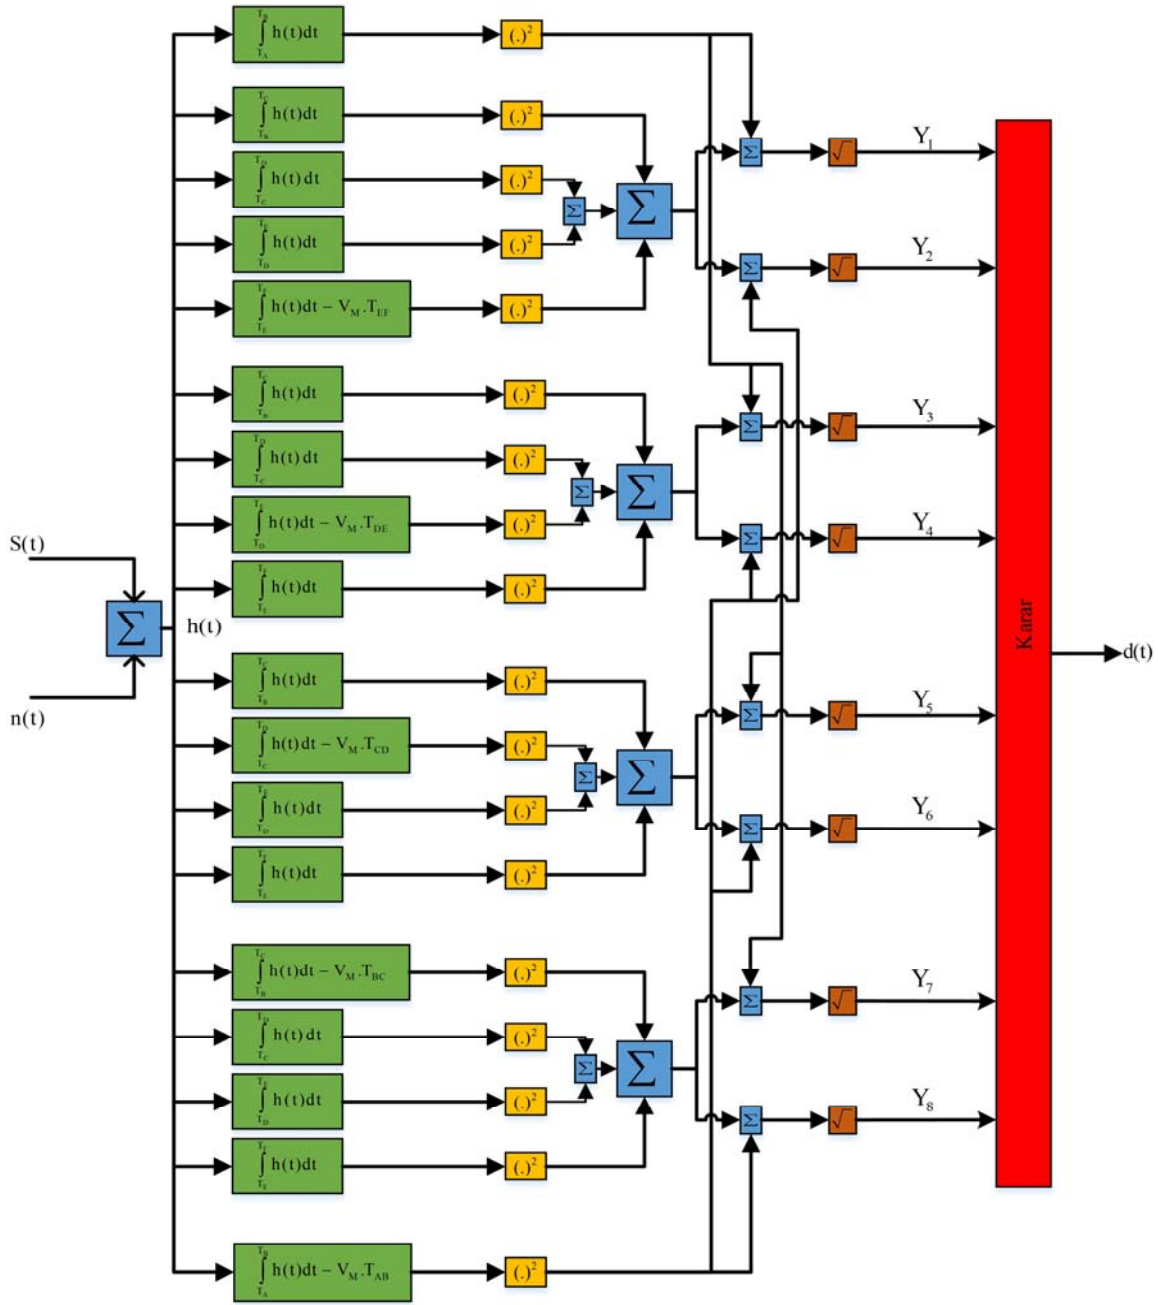
$$H = -\sum_{i=1}^M P_i \cdot \log_2 P_i = -\log_2 \left(\prod_{i=1}^M P_i\right) \quad (22)$$

$$H = \log_2^M = L \quad (23)$$

Eş. 22'de, M seviyeli SPPM sinyaller için de kullanılabilen entropi formülü verilmiştir. Burada, H entropi olarak adlandırılmaktadır [10]. Ayrıca, P_i , i. olayın meydana gelme olasılığını ifade etmektedir. Bu noktada, doğal logaritma kurallarından faydalanılarak, toplam sembolü çarpım sembolüne dönüştürülebilmektedir. Ayrıca, M-SPPM tekniği için, üst indis sınırı M olarak belirlenebilmektedir. Eş. 22'deki entropi ifadesi kullanılarak Eş. 23, M seviyeli bir SPPM sinyali için elde edilebilmektedir. Eş. 23'te hesaplanan entropi değerinin, bit çözünürlüğüne eşit olduğu görülmektedir.

Tablo 3, 4-SPPM sinyalleri için, karar tablosunu ve veri dağılım tablosunu göstermektedir. Tablo 4 ve Tablo 5, sırasıyla 8-SPPM ve 16-SPPM sinyaller için oluşturulmuştur. Burada s_i , i. yuvayı temsil etmektedir. Ayrıca, Tablo 3, Tablo 4 ve Tablo 5, OOK kod sözcüklerine göre oluşturulmuştur. Bu tablolarda, karar ifadesi OOK kod sözcüklerini ifade etmektedir. Bu tablolarda, i. yuvada bulunan mantıksal '0' ve '1' bit sayıları gösterilmektedir. Üstelik, Tablo 3, Tablo 4 ve Tablo 5, M-SPPM sinyal yuvalarının bilgi kazançlarının bulunması için verilmiştir.

$$G(s_i) = H - \sum_i P_i \cdot H(s_i, 0/1) \quad (24)$$



Şekil 5. M=8 için, KNN tabanlı demodülörün blok diyagramı (Block diagram of KNN based demodulator for M=8)

Tablo 3. 4-SPPM sinyaller için karar ve veri dağılım tabloları
(Decision and data distribution tables for 4-SPPM signals)

s ₁	s ₂	s ₃	Karar
0	0	1	00
0	1	0	01
1	0	1	10
1	1	0	11
Toplam			
2	2	2	0
2	2	2	1

Eş. 24’te, i. yuvanın bilgi kazancını hesaplayabilen matematiksel ifade verilmiştir [15]. Bu noktada, M-SPPM sinyaller için, karar ağaçları tabanlı demodülörler tasarlanmıştır. Ayrıca, eşitlikte, $H(s_i,0)$ ve $H(s_i,1)$ ayrı ayrı hesaplanmaktadır. M-SPPM sinyaller için, her bir kararın birbirinden farklı olduğu Tablo 3, Tablo 4 ve Tablo 5’te görülmektedir. Böylece, M seviyeli SPPM sinyallerin bütün yuvaları için, bilgi kazançları bulunabilmektedir. Burada, yuvaların bilgi kazançları karar ağaçları tabanlı demodülörlerin oluşturulabilmesi için kullanılmaktadır. Tablo 6’da, 4-SPPM, 8-SPPM ve 16-SPPM teknikleri için, s_i yuvalarının bilgi kazançları verilmektedir. Bilgi

kazançlarına göre, karar ağaçlarının düğüm noktaları belirlenmektedir. Bilgi kazancı yüksek olan yuva, karar ağaçlarında ana düğüm olarak atanır. Burada, bütün yuvaların bilgi kazançlarının Eş. 23 yardımıyla hesaplanmasına ihtiyaç duyulmaktadır. $L > 2$ için, bütün M seviyeli SPPM sinyallerde s_1 yuvasının bilgi kazancının daha büyük olduğu tablolarda görülmektedir. $L=2$ için, 4-SPPM sinyallerde bütün yuvaların bilgi kazançları eşittir. Burada, SPPM tekniğinin işaret bitlerinin konumlandığı yuva değerlendirilmektedir. L arttıkça, $G(s_2), G(s_3), \dots, G(s_i)$ bilgi kazançlarının azaldığı görülmektedir. Ayrıca, karar ağaçlarında dallanma sayısı gereksiz bir şekilde arttıkça, sistem performansı olumsuz bir şekilde etkilenmektedir. Bu noktada, SPPM tekniğinin bit hata oranı performansı değişebilmektedir.


Tablo 4. 8-SPPM sinyaller için karar ve veri dağılım tabloları
(Decision and data distribution tables for 8-SPPM signals)

s_1	s_2	s_3	s_4	s_5	Karar
0	0	0	0	1	001
0	0	0	1	0	001
0	0	1	0	0	010
0	1	0	0	0	011
1	0	0	0	1	100
1	0	0	1	0	101
1	0	1	0	0	110
1	1	0	0	0	111
Toplam					
4	6	6	6	6	0
4	2	2	2	2	1

$$X_1 = \int_{T_A}^{T_B} h(t)dt, X_2 = \int_{T_B}^{T_C} h(t)dt, X_3 = \int_{T_C}^{T_D} h(t)dt \quad (25)$$

Tablo 6. M-SPPM sinyaller için yuvaların bilgi kazançları (Information gains of slots for M-SPPM signals)

...	$G(s_1)$	$G(s_2)$	$G(s_3)$	$G(s_4)$	$G(s_5)$	$G(s_6)$	$G(s_7)$	$G(s_8)$	$G(s_9)$
16-SPPM	1*	0,544	0,544	0,544	0,544	0,544	0,544	0,544	0,544
8-SPPM	1*	0,815	0,815	0,815	0,815				
4-SPPM	1*	1*	1*						



Şekil 6. M=4 için, karar ağaçları tabanlı demodülatörler (Decision tree based demodulators for M=4)

$$Th = \frac{T_s(V_{Min} + V_{Max})}{2} \quad (26)$$

Tablo 5. 16-SPPM sinyaller için karar ve veri dağılım tabloları

(Decision and data distribution tables for 16-SPPM signals)

s_1	s_2	s_3	s_4	s_5	s_6	s_7	s_8	s_9	Karar
0	0	0	0	0	0	0	0	1	0000
0	0	0	0	0	0	0	1	0	0001
0	0	0	0	0	0	1	0	0	0010
0	0	0	0	0	1	0	0	0	0011
0	0	0	0	1	0	0	0	0	0100
0	0	0	1	0	0	0	0	0	0101
0	0	1	0	0	0	0	0	0	0110
0	1	0	0	0	0	0	0	0	0111
1	0	0	0	0	0	0	0	1	1000
1	0	0	0	0	0	0	1	0	1001
1	0	0	0	0	0	1	0	0	1010
1	0	0	0	0	1	0	0	0	1011
1	0	0	0	1	0	0	0	0	1100
1	0	0	1	0	0	0	0	0	1101
1	0	1	0	0	0	0	0	0	1110
1	1	0	0	0	0	0	0	0	1111
Toplam									
8	14	14	14	14	14	14	14	14	0
8	2	2	2	2	2	2	2	2	1

Eş. 24 ve Eş. 25'te, karar ağaçları tabanlı demodülatörlerde kullanılan X_1, X_2, X_3 ve Th ifadeleri verilmektedir. Burada, Th eşik değeri olarak adlandırılmaktadır.

Şekil 6'da, karar ağaçları tabanlı demodülatör blok diyagramları, 4-SPPM sinyaller için verilmektedir. Şekil 6a ve Şekil 6b'de sırasıyla Demodülatör-3 ve Demodülatör-4 gösterilmektedir. 4-SPPM sinyaller için, bütün yuvaların bilgi kazançlarının eşit olduğu Tablo 6'da görülmektedir. Bu

nedenle, Demodülatör-3 ve Demodülatör-4, işaret bitlerine göre oluşturulmuştur. Ayrıca, Demodülatör-3 için Max blokları, şekildeki X_i değişkenlerinin maksimum değerine göre, veri bitlerini tahmin etmektedir. Burada, Demodülatör-4 ise sadece eşik değeri yardımıyla veri bitlerini tahmin edebilmektedir.

$$X_4 = \int_{T_D}^{T_E} h(t)dt, X_5 = \int_{T_E}^{T_F} h(t)dt \quad (27)$$

Eş. 27’de, 8-SPPM sinyalleri için kullanılabilen, X_4 ve X_5 değişkenleri verilmektedir.


Şekil 7’de, 8-SPPM sinyaller için karar ağaçları tabanlı demodülatör blok diyagramları verilmiştir. Şekil 7a, Şekil 7b, Şekil 7c ve Şekil 7d’de, sırasıyla Demodülatör-5, 6, 7 ve 8 gösterilmektedir. Şekillerde, s_1 ve s_2 ayrı ayrı ana düğüm olarak belirlenmiştir. Ancak, s_2, s_3, s_4 yuvaları Şekil 7’de kendi aralarında da yer değiştirebilmektedir. Ayrıca s_5 yuvası da diğer yuvalarla yer değiştirebilir. Bu nedenle, Şekil 7.d için s_5 yuvasının kullanılmadığı görülmektedir. Bu durumda, s_5 yuvasındaki sinyal bilgileri Demodülatör-8 için kullanılmamaktadır. Bu durum sistem performansını olumsuz bir şekilde etkilemektedir. Ayrıca, s_2, s_3, s_4 ve s_5 yuvalarının bilgi kazançlarının s_1 yuvasının bilgi

kazancından daha düşük olması bu durumu açıklayabilmektedir.

3. NÜMERİK SONUÇLAR (NUMERICAL RESULTS)

Bu kısımda, önerilen demodülatörlerin performansları karşılaştırılmıştır. Önerilen sistemler için, bit hata oranı performansları, hatasız iletilen veri oranları veya doğruluk oranları incelenmiştir. Bu noktada, Şekil 8, 4-SPPM ve 8-SPPM sinyalleri için çizdirilmiştir.

Şekil 8’de önerilen demodülatörlerin bit hata oranı performansları gösterilmektedir. Burada, Demodülatör-1, 3 ve 4, 4-SPPM sinyallerini çözebilmektedir. Ayrıca, Demodülatör-2, 5, 6, 7 ve 8, 8-SPPM sinyallerini çözebilmektedir. Şekilde KNN tabanlı Demodülatör-1 ve karar ağaçları tabanlı Demodülatör-3’ün bit hata oranı performanslarının eşit olduğu görülmektedir. 4-SPPM sinyallerde, bütün yuvaların bilgi kazançlarının eşit olmasına rağmen, Demodülatör-1 ve Demodülatör-3’ün bit hata oranı performanslarının, Demodülatör-4’ün bit hata oranı performansından daha iyi olduğu şekilde görülmektedir. Bu nedenle, $L > 2$ için $G(s_i)$ önermesi yapılabilmektedir. $L = 2$ için, işaret bitleri birinci yuvalara kodlanmaktadır. Bu nedenle, s_1 ana düğümlü demodülatör, s_2 veya s_3 ana



Şekil 7. M=8 için, karar ağaçları tabanlı demodülatörler (Decision tree based demodulators for M=8)

düğümlü demodülatörlerden daha iyi bir bit hata oranı performansı sergilemektedir. 8-SPPM sinyaller için, KNN tabanlı Demodülatör-2 ve karar ağaçları tabanlı Demodülatör-5'in bit hata oranı performanslarının eşit çıktığı şekilde görülmektedir. Demodülatör-5'in, s_1 ana düğümüne sahip olması ve gereksiz dallanma bulundurmaması nedeniyle; Demodülatör-5'in bit hata oranı performansı, Demodülatör-6, 7 ve 8'in bit hata oranı performanslarından daha iyi olmaktadır. Demodülatör-5, 6 ve 7 için, dallanma sayısı arttıkça, önerilen sistemlerin bit hata oranı performanslarının kötüleştiği Şekil 8'de görülebilmektedir. Ayrıca, s_1 ana düğümlü demodülatörlerin bit hata oranı performanslarının, s_2 ana düğümlü Demodülatör-8'in bit hata oranı performansından daha iyi olduğu şekilde görülmektedir. Bu durum, Şekil 9 ve Tablo 7 tarafından açıklanabilmektedir.

Şekil 9'da, bütün demodülatörler için, doğruluk oranları gösterilmektedir. Önerilen sistemler için, doğruluk veya hata olmadan iletilen veri oranı, 1-BER ifadesi yardımıyla bulunabilmektedir. Şekilde, 4-SPPM sinyalleri çözebilen demodülatörlerin, 8-SPPM sinyalleri çözebilen


demodülatörlerden doğruluk oranı açısından daha iyi olduğu görülmektedir. Ayrıca, KNN tabanlı Demodülatör-1 ve karar ağaçları tabanlı Demodülatör-3'ün doğruluklarının diğer demodülatörlerden daha iyi olduğu şekilde görülmektedir. $SNR \geq 12$ dB için, bütün demodülatörlerde doğruluk oranları hemen hemen 1'e eşit olmaktadır. Yani $SNR \geq 12$ dB için, veriler %99 ve %100 aralığında doğru bir şekilde iletilmektedir. Bu durum, Eş. 28- Eş. 30 tarafından açıklanabilmektedir.

$$BER = \frac{FP + FN}{TP + TN + FP + FN} \quad (28)$$


$$AR = \frac{TP + TN}{TP + TN + FP + FN} \quad (29)$$

$$BER + AR = 1 \quad (30)$$

Eş. 28- Eş. 30'da, BER ve doğruluk oranı arasındaki ilişkiyi gösteren ifadeler verilmiştir. Burada, FP ve FN, sırasıyla



Şekil 8. Önerilen demodülatörler için bit hata oranı performansları (Bit error rate performances for proposed demodulators)



Şekil 9. Önerilen sistemler için doğruluk oranları (Accuracy rates for the proposed systems)

yanlış pozitif ve yanlış negatif değerleri göstermektedir. TP ve TN ifadeleri ise, sırasıyla doğru pozitif ve doğru negatif değerleri göstermektedir [11-14]. Ayrıca, Eş. 28 ve Eş. 29'un taraf tarafa toplanması sonucunda Eş. 30'un elde edilebildiği görülebilmektedir.

Tablo 7'de, önerilen demodülatörlerin farklı SNR değerleri için doğruluk değerleri (%) verilmiştir. Burada, Demodülatör-1,2 için sırasıyla 4 ve 8 seviyeli KNN demodülatörler ve Demodülatör-3, 4 için 4 seviyeli karar ağaçları demodülatörler gösterilirken, Demodülatör-5, 6, 7, 8 için 8 seviyeli karar ağaçları demodülatörleri verilmektedir. Bu demodülatör numaraları Şekil 4-Şekil 7'den de görülebilmektedir. Tablo, Eş. 28- Eş. 30 yardımıyla elde edilmiştir. Burada, verilen tablonun, Şekil 9'da ki sonuçlarla tamamen aynı olduğu görülmektedir. Ayrıca, SNR değeri arttıkça, bütün önerilen demodülatörler için sistem performansları da artmaktadır. Demodülatör 1 ve 3'ün sistem performanslarının tamamen aynı olduğu tablodan yorumlanabilmektedir. Burada, bu demodülatörlerin sistem performanslarının, diğer demodülatörün sistem performanslarından daha iyi olduğu görülmektedir. Önerilen KNN tabanlı demodülatörlerin ve doğru bir şekilde tasarlanmış olan karar ağaçları tabanlı demodülatörlerin en iyi performansı sergilediği tabloda görülebilmektedir. Ayrıca, SNR değeri 16 dB'ye eşit olduğunda, bütün demodülatörlerin verileri tamamen doğru çözebildiği gözlemlenmiştir.

Tablo 8'de tasarlanmış olan her demodülatör için çalışma süreleri iletilen bit sayılarına göre saniye cinsinden

verilmektedir. Tablo incelendiğinde, karar ağaçları tabanlı demodülatörlerin KNN tabanlı demodülatörlerden bit sayısı arttıkça da zaman açısından daha avantajlı olduğu görülmektedir. Bir diğer taraftan aynı demodülatörler, Manhattan ve Minkowski mesafeleri ifadeleriyle de tasarlanabilmektedir. Bu nedenle, Eş. 31 ve Eş. 32 aşağıdaki gibi yazılabilir.

$$Y_i = \left| \sum_j^{j_{\text{Max}}-1} \left(\int_j^{j^+} h(t) dt - V_M \cdot T_{j,j^+} \cdot \theta_{j,j^+}(t) \right) \right| \quad (31)$$

$$Y_i = \sqrt[R]{ \left| \sum_j^{j_{\text{Max}}-1} \left(\int_j^{j^+} h(t) dt - V_M \cdot T_{j,j^+} \cdot \theta_{j,j^+}(t) \right) \right|^R } \quad (32)$$

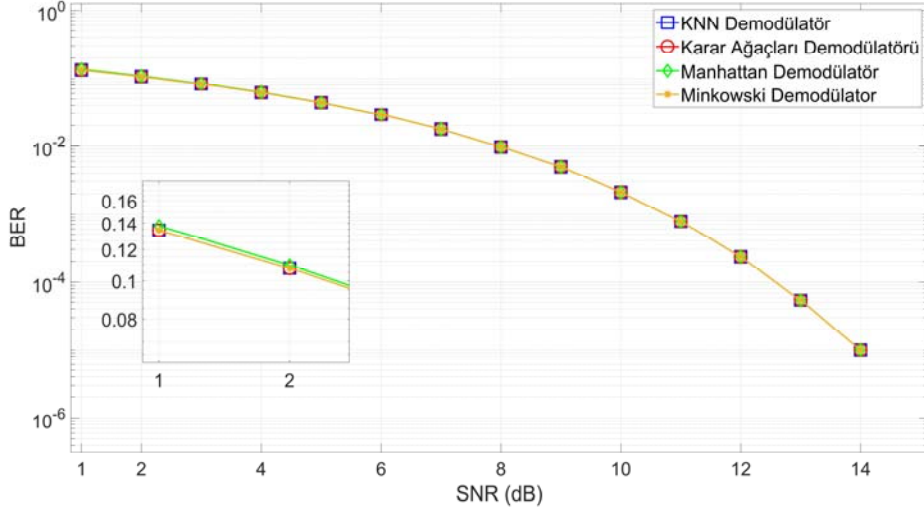
Eş. 31 ve Eş. 32'de sırasıyla, Manhattan ve Minkowski mesafelerini hesaplayan ifadeler verilmiştir [15, 16]. Önerilen KNN tabanlı ve karar ağaçları tabanlı demodülatörlere ek olarak, Manhattan ve Minkowski mesafeleri yardımıyla da sinyaller demodüle edilebilmektedir ($R \geq 1$, $R \in \mathbb{R}^+$). Eş. 13, Eş. 20'de de olduğu gibi, Eş. 31, Eş. 32 için Y_i değerleri bulunmaktadır. Her demodülatör için, elde edilen Y_i değerleri arasında minimum Y_i değeri belirlenir. Burada, minimum Y_i değerine göre, veri bitleri tahmin edilmektedir. Ayrıca, önerilen demodülatörlerin geleneksel sistem olarak da kullanılabileceği bu ifadeler yardımıyla açıklanabilmektedir. Bu durum, Şekil 10-Şekil 11'de gösterilmektedir.

Tablo 7. Önerilen sistemler için doğruluk (%) (Accuracy (%) for the proposed systems)


	Doğruluk (%)							
	Demodülatör-1	Demodülatör-2	Demodülatör-3	Demodülatör-4	Demodülatör-5	Demodülatör-6	Demodülatör-7	Demodülatör-8
SNR=4	93,8	87,45	93,8	90,69	87,45	84,5	82,22	81,25
SNR=6	95,66	92,96	95,66	93,11	92,96	90,43	87,35	87,46
SNR=8	99,03	96,95	99,03	98,2	96,95	95,24	93,82	93,18
SNR=10	99,78	99,07	99,78	99,57	99,07	98,27	97,59	97,29
SNR=14	99,99	99,98	99,99	99,99	99,98	99,95	99,93	99,92
SNR=18	100	100	100	100	100	100	100	100

Tablo 8. Önerilen demodülatörler için çalışma süreleri (Running times for the proposed demodulators)

Bit sayısı	Demodülatör-1, saniye	Demodülatör-2, saniye	Demodülatör-3, saniye	Demodülatör-4, saniye	Demodülatör-5, saniye	Demodülatör-6, saniye	Demodülatör-7, saniye	Demodülatör-8, saniye
1	0,007751	0,009229	0,000243	0,000186	0,000246	0,000309	0,000282	0,000186
1500	0,0114	0,0528	0,0044	0,0028	0,0067	0,0077	0,0055	0,0028
15000	0,1170	0,3930	0,0435	0,0330	0,0810	0,0855	0,0705	0,0525
150000	1,185	4,62	0,495	0,39	1,35	1,38	2,22	1,89



Şekil 10. Önerilen sistemler için bit hata oranı performansları (Bit error rate performances for the proposed systems)



Şekil 11. Önerilen sistemler için doğruluk oranları (Accuracy rates for the proposed systems)

Şekil 10 ve Şekil 11’de sırasıyla önerilen demodülatörler için bit hata oranı performansları ve doğruluk oranları gösterilmektedir. Şekillerde, önerilen KNN ve karar ağaçları tabanlı demodülatörler ve Minkowski demodülatörünün tamamen aynı bit hata oranı ve doğruluk oranı performanslarına sahip oldukları görülmektedir. İlâveten, $10^{-1,754}$ ve daha küçük bit hata oranı performansları için bütün demodülatörlerin aynı bit hata oranı ve doğruluk oranı performanslarına sahip olduğu görülmektedir. Böylece, önerilen her bir demodülatörün, geleneksel sistemler için de kullanılabilceği anlaşılabilmektedir.

Şekil 8-Şekil 11 ve Tablo 7 birlikte incelendiğinde, önerilen KNN ve karar ağaçları tabanlı demodülatörlerin birçok modülasyon tekniği için geleneksel yapı olarak kullanılabilceği çıkarımı yapılabilmektedir. Burada, bit hata oranı ve doğruluk oranı performansları hemen hemen paralel sonuçları göstermektedir. Bu noktada, önerilen KNN tabanlı demodülatörlerin doğrudan geleneksel yapı olarak

kullanılabileceği görülmektedir. Ancak, kullanıcı tarafından tasarlanması gereken karar ağaçları tabanlı demodülatörlerin en uygun şekilde tasarlanması gerekmektedir. Bu bilgilerle birlikte, KNN ve en uygun şekilde tasarlanan karar ağaçları tabanlı demodülatörlerin geleneksel yapıya uygun sonuçlar verdiği gözlemlenmiştir.

4. SONUÇLAR (CONCLUSIONS)

Bu çalışmada KNN ve karar ağaçları tabanlı M-SPPM demodülatörleri tasarlanmıştır. 4-SPPM ve 8-SPPM sinyaller için, eğitim kümesinde kullanılan veri sayısı sırasıyla 4 ve 8’e eşittir. Burada, gürültülü sinyaller, test kümesini oluşturmaktadır. Önerilen sistemlerin daha iyi anlaşılabilmesi açısından, M-SPPM sinyallerin modülatör blok diyagramı ve matematiksel teorik altyapısı oluşturulmuştur. KNN ($K=1, \forall M$) tabanlı önerilen demodülatör, gürültülü sinyallerin gürültüsüz sinyallere olan uzaklıklarını tespit etmektedir. Elde edilen en küçük değer

incelenerek, KNN tabanlı demodülatörler için veri bitleri tahmin edilmektedir. Bir diğer taraftan aynı sinyaller karar ağaçları tabanlı demodülatörler ile de çözülebilmektedir. Burada, karar ağaçlarının en uygun şekilde tasarlanması gerekmektedir. Yapılan çalışmada, öncelikle M seviyeli bir SPPM sinyal için entropi değerinin L'ye eşit olduğu gösterilmektedir. Bu durum, diğer modülasyon teknikleri içinde açıklanabilmektedir. Entropi değerleri sayesinde her bir yuva için bilgi kazançları bulunabilir. Eğer ana düğüm düşük kazançlı yuva seçilirse, karar ağaçları tabanlı önerilen demodülatörlerin sistem performansları da azalmaktadır. Bu nedenle, en uygun karar ağaçları tabanlı demodülatör belirlenmelidir. Ayrıca, KNN ve karar ağaçları tabanlı önerilen demodülatörler senkron modülasyon tekniklerine uygulanabilirler. Çoğu teknikte (PPM, MPPM, VPPM [17], OPPM, SPPM vb.) karar ağaçları tabanlı demodülatörler başarılı bir şekilde çalışmaktadır. Ancak, yeni önerilecek bir teknik için KNN ve karar ağaçları tabanlı demodülatörlerin farklı sonuç vermesi durumunda, KNN tabanlı demodülatörlerin referans olarak alınması daha doğru olmaktadır. Sonuçlarda, KNN tabanlı önerilen sistemlerin ve en uygun şekilde tasarlanmış olan karar ağaçları tabanlı önerilen sistemlerin M-SPPM sinyaller için tamamen aynı sistem performanslarına sahip olduğu görülmektedir. Bu noktada, önerilen sistemler geleneksel sistem olarak da kullanılabilir (özellikle KNN doğrudan bütün senkron tekniklere uygulanabilir). Bu durum, Manhattan ve Minkowski mesafelerine göre sinyalleri çözebilen demodülatörler sayesinde de açıklanabilmektedir. Önerilen sistemlerin doğruluk ve bit hata oranları performansları incelendiğinde, düşük SNR'ler için doğruluğun çoğu sistemde yakın olduğu görülmektedir. Önerilen sistemlerin performansları istatistiksel olarak incelendiğinde, SNR=14 dB için bütün demodülatörlerin doğruluk oranları %99,9'un üzerindedir. Bu nedenle, Şekil 8 ve Şekil 9 birlikte incelenebilmektedir. SNR=18 dB için, bütün demodülatörlerin veriyi tamamen doğru bir şekilde tahmin edebildiği görülmektedir.

İlaveten, ilerideki yapılacak olan çalışmalarda önerilen sistemlerin gerçek zamanlı uygulamalarının yapılması hedeflenmektedir. Bununla birlikte, böyle demodülatörlerin destek vektör makineleri [18, 19], yapay sinir ağları ve derin öğrenme [20-22] gibi yöntemlerle de tasarlanıp tasarlanamayacağı incelenmesi hedeflenmektedir. Yapılan çalışmada da görüldüğü gibi, KNN tabanlı sistemler doğrudan matematiksel yöntemlerle geleneksel sistem olarak kullanılabilir. Ancak karar ağaçları tabanlı sistemlerin kullanıcı tarafından en uygun şekilde tasarlanması gerekmektedir. Bu nedenle, karar ağaçları tabanlı sistemler için en uygun sistemin kendi kendisine tasarlandığı bir yapı geliştirilebilir ve böyle yöntemler makine öğrenmesi teknikleri içerisinde de bulunmaktadır. Ayrıca, önerilen KNN tabanlı yöntem zaman açısından karar ağaçları tabanlı yöntemden daha kötüdür. Bu nedenle, KNN tabanlı yöntemin bu açığı kapatılması için farklı metodolojiler geliştirilebilir. Burada, önerilen sistemlerin hem mevcut hem de yeni tasarlanacak bir tekniğin sistem

performanslarının incelenmesi açısından, avantaj ve kolaylık sağladığı görülmektedir.

KAYNAKLAR (REFERENCES)

1. Farahneh H., Hussian F., Fernando X., De-Noising Scheme for VLC-Based V2V Systems; A Machine Learning Approach, *Procedia Comput. Sci.*, 171 (2019), 2167–2176, 2020.
2. Tran H. Q., Ha C., High Precision Weighted Optimum K-Nearest Neighbors Algorithm for Indoor Visible Light Positioning Applications, *IEEE Access*, 8, 114597–114607, 2020.
3. Xu S., Chen C.C., Wu Y., Wang X., Wei F., Adaptive residual weighted k-nearest neighbor fingerprint positioning algorithm based on visible light communication, *Sensors (Switzerland)*, 20 (16), 1–24, 2020.
4. Valieva I., Bjorkman M., Akerberg J., Ekstrom M., Voitenko I., Multiple Machine Learning Algorithms Comparison for Modulation Type Classification for Efficient Cognitive Radio, *Proc. - IEEE Mil. Commun. Conf. MILCOM*, November, 318–323, 2019.
5. Hussain A., Ghauri S.A., Sohail M.F., Khan S.A., Qureshi I. M., Knn based classification of digital modulated signals, *IJUM Eng. J.*, 17 (2), 71–82, 2016.
6. Ma S., Dai J., Lu S., Li H., Zhang H., Du C., Li A.S. Signal Demodulation with Machine Learning Methods for Physical Layer Visible Light Communications: Prototype Platform, Open Dataset, and Algorithms, *IEEE Access*, 7, 30588–30598, 2019.
7. Ray I., Analysis of Offset Pulse Position Modulation, Doctoral dissertation, University of Huddersfield, United Kingdom, 2015.
8. Cryan R.A., Spectral characterisation of shortened pulse position modulation format, *Electron. Lett.*, 46 (5), 355–356, 2010.
9. Hagem R.M., FPGA Based Implementation of Pulse Position Modulation for Underwater Optical Wireless Communication, *Int. J. Eng. Innov. Technol.*, 6 (5), 47–50, 2016.
10. Bulut F., Different Mathematical Models for Entropy in Information Theory, *Bilge International Journal of Science and Technology Research*, 1 (2), 167–174, 2017.
11. Trajdos P., Kurzynski M., Weighting scheme for a pairwise multi-label classifier based on the fuzzy confusion matrix, *Pattern Recognit. Lett.*, 103, 60–67, 2018.
12. Ferri C., Hernández-Orallo J., ve Modroiu R., An experimental comparison of performance measures for classification, *Pattern Recognit. Lett.*, 30 (1), 27–38, 2009.
13. Cuadros-Rodríguez L., Pérez-Castaño E., Ruiz-Samblás C., Quality performance metrics in multivariate classification methods for qualitative analysis, *TrAC - Trends Anal. Chem.*, 80, 612–624, 2016.
14. Zhang Y., Lu S., Zhou X., Yang M., Wu L., Liu B., Phillips P., Wang S. Comparison of machine learning

- methods for stationary wavelet entropy-based multiple sclerosis detection: Decision tree, k -nearest neighbors, and support vector machine, *Simulation*, 92 (9), 861–871, 2016.
15. Kantardzic M., *Data mining: concepts, models, methods, and algorithms*. John Wiley & Sons, 2011.
 16. Günay M., Alkan A., EMG İşaretlerinin K-Ortalama Algoritması Kullanılarak Öbekleştirilmesi, *KSÜ Mühendislik Bilimleri Dergisi*, 12 (2), 25–29, 2010.
 17. Sünnetci K.M., Sonmez M., Görünür Işık Haberleşme Sistemleri İçin Karartma Kontrol Biti Kullanılarak Geliştirilmiş Bir İletim Yönteminin Analizi, *Journal of Polytechnic*, 2020.
 18. Alkan A., Analysis of knee osteoarthritis by using fuzzy c-means clustering and SVM classification, *Scientific Research and Essays*, 6 (20), 4213–4219, 2011.
 19. Akben S.B., Alkan A., Density-Based Feature Extraction To Improve The Classification Performance In The Datasets Having Low Correlation Between Attributes, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 30 (4), 597-603, 2015.
 20. Karaali İ., Eminağaoğlu M., A convolutional neural network model for marble quality classification, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (1), 347-358, 2020.
 21. Yılmaz A., Diagnosing COVID-19 from X-Ray images with using multi-channel CNN architecture, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (4), 1761-1774, 2021.
 22. Elmas B., Identifying species of trees through bark images by convolutional neural networks with transfer learning method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (3), 1253-1270, 2021.

