Faster-than-Nyquist (FTN) İşaretleme için MLP ve Kolmogorov-Arnold Network (KAN) Tabanlı Algılayıcıların Karşılaştırmalı Analizi
A Comparative Analysis of MLP and Kolmogorov-Arnold Networks (KAN) for Faster-than-Nyquist (FTN) Signaling Detection

Sude Ertan, Osman Tokluoglu, Enver Çavuş
Elektrik Elektronik Mühendisliği Bölümü, Ankara Yıldırım Beyazıt Üniversitesi, Ankara, Türkiye
E-mail: suddertan@gmail.com, otokluoglu@aybu.edu.tr, ecavus@aybu.edu.tr

***Özetçe* —Nyquistten Daha Hızlı işaretleme, Nyquist aralığını kasıtlı olarak ihlal edip kontrollü semboller arası girişim oluşturarak spektral verimliliği artırır. BCJR gibi klasik dizisel algılayıcılar optimale yakın performans sağlasa da, bunların hesaplama maliyeti kanal belleğiyle birlikte üstel biçimde artmaktadır. Bu çalışma, AWGN altında çok katmanlı algılayıcılar ile Kolmogorov Arnold Ağları kullanılarak veri güdümlü FTN BPSK algılamasını doğrudan KAN ve MLP karşılaştırması odağında incelemektedir. Yaklaşık dört milyon etiketli pencereden oluşan büyük ölçekli Monte Carlo veri kümesi sıfır nokta sekiz zaman sıkıştırma katsayısı ve yedi ile on desibel arası sinyal gürültü oranı için üretilmiştir. Genişlik taramasından elde edilen en güçlü MLP gizli katman genişliği otuz iki iken, seçilen KAN gizli katman genişliği dört ve spline ızgara boyutu beş ile kurulmuştur. On desibelde MLP bir nokta üç çarpı on üzeri eksi dört bit hata oranı üretirken KAN yedi çarpı on üzeri eksi altı değerine ulaşmakta; yani MLP gizli katman genişliğinin yalnızca sekizde birini kullanarak on sekiz nokta altı kat daha düşük bit hata oranı sağlamaktadır. Bulgular, KANın FTN karar sınırlarını modellemede MLP taban çizgisine göre daha etkili ve daha verimli bir temsil sunduğunu göstermektedir.**

Anahtar Kelimeler*—*KAN, MLP, FTN işaretleme, BPSK algılama, BCJR, sinirsel alıcı, parametre verimliliği.

***Abstract*—Faster-than-Nyquist signaling improves spectral efficiency by deliberately introducing inter-symbol interference. Classical sequence detectors such as BCJR can approach optimal performance, but their computational cost grows rapidly with channel memory. This paper investigates data-driven FTN BPSK detection under AWGN through a direct comparison between multilayer perceptrons and Kolmogorov Arnold Networks. A large-scale Monte Carlo dataset containing nearly four million labeled windows is generated for a time-packing factor of zero point eight and signal-to-noise ratio values from seven to ten decibels. The best MLP obtained from width sweeping uses hidden width thirty two, whereas the selected KAN uses hidden width four with spline grid size five. At ten decibels, the MLP produces a bit error rate of one point three times ten to the minus four, while the KAN reaches seven times ten to the minus six. This corresponds to an eighteen point six times lower bit error rate while using only one eighth of the MLP hidden width. The results show that KAN provides a more effective and more parameter-efficient neural decision model than the MLP baseline for FTN BPSK detection.**

Keywords*—*KAN, MLP, FTN signaling, BPSK detection, BCJR, neural receiver, parameter efficiency.

979-8-3195-1046-4/26/$31.00 ©2026 IEEE

I. GİRİŞ

Faster-than-Nyquist işaretleme, işgal edilen bant genişliğini artırmadan spektral verimliliği yükseltmeye yönelik klasik bir yaklaşımdır [1], [3]. Sembollerin Nyquist aralığından daha hızlı iletilmesiyle FTN, kasıtlı olarak deterministik semboller arası girişim oluşturur ve sembol-sembole algılamayı yapısal bir dizi kestirimi problemine dönüştürür. Bu spektral sıkıştırma iletim verimliliğini önemli ölçüde artırabilse de, buna bağlı algılama problemi her gözlemin birden fazla komşu sembole bağlı olması nedeniyle kayda değer ölçüde daha zorlaşmaktadır.

Klasik dizi algılayıcısı BCJR, FTN için optimale yakın performans elde edebilmektedir [2]. Ancak bu tür çözümlerin pratik kullanımı, etkin kanal belleğiyle elverişsiz biçimde ölçeklenen hesaplama karmaşıklığı nedeniyle sınırlıdır. Gerçek zamanlı alıcılar veya donanım açısından kısıtlı platformlar için bu durum, doğrusal olmayan FTN karar bölgelerini daha düşük karmaşıklıkla yaklaşıklayabilen öğrenilmiş algılayıcıları motive etmektedir. Yakın tarihli çalışmalar, GRU gibi yinelemeli sinir ağı mimarilerinin FTN dizilerindeki zamansal yapıyı kullanarak belirli rejimlerde BCJR'a yakın BER performansı elde edebildiğini göstermiştir [6].

Bu çalışma ise MLP ile KAN'ın FTN-BPSK algılamasındaki doğrudan karşılaştırmasını merkeze almaktadır. MLP'ler basit gerçekleştirimleri nedeniyle cazip taban çizgileri oluşturmakla birlikte, ISI'nin oluşturduğu ince ayrıntılı doğrusal olmayan sınırları temsil edebilmek için çoğunlukla geniş gizli katmanlara ihtiyaç duymaktadır. Kolmogorov-Arnold Ağları

farklı bir tümevarımsal önyargı sunar: doğrusalsızlığı düğümlerde değil kenarlarda konumlandırarak her bağlantıya öğrenilebilir bir spline fonksiyonu atar [4]. Bu kenar tabanlı parametreleştirme, haberleşme kanallarındaki yapısal yerel etkileşimler için özellikle çekicidir.

Literatürde FTN algılama çoğu zaman ya klasik algılayıcılarla ya da tek bir sinir ağı ailesiyle ele alınmaktadır. Buna karşılık bu çalışma, aynı veri kümesi, aynı pencere gösterimi ve aynı değerlendirme koşulları altında KAN ile MLP arasında doğrudan ve sistematik bir karşılaştırma sunmaktadır. Bu yönüyle çalışma yalnızca bir sinir ağı alıcısı önermekten öte, FTN karar sınırlarını hangi temsilin daha verimli modellediği sorusuna cevap aramaktadır.

Bu çalışmanın katkıları şunlardır: i) $\tau = 0.8$ ve 7–10 dB SNR aralığında büyük ölçekli FTN-BPSK veri kümesinin oluşturulması, ii) 65 örnekli alınan pencere üzerinde sistematik KAN–MLP karşılaştırması, iii) BER performansının FTN sert-karar taban çizgisi ve BCJR referansına karşı değerlendirilmesi ve iv) KAN'ın çok daha küçük gizli gösterimle MLP'ye kıyasla belirgin BER avantajı sağladığının gösterilmesi.

II. Sistem Modeli

BPSK için iletilen sembol dizisi

$$x_k \in \{-1, +1\} \tag{1}$$

şeklindedir. FTN işaretlemede sembol aralığı

$$T_{\mathrm{FTN}} = \tau T, \qquad 0 < \tau < 1 \tag{2}$$

olarak sıkıştırılır; burada T Nyquist sembol aralığıdır ve bu çalışmada $\tau = 0.8$ seçilmiştir. Bunun sonucunda işaretleme hızı $1/\tau = 1.25$ katsayısı kadar artmakta, yani Nyquist işaretlemeye göre sembol hızında yüzde 25 kazanım elde edilmektedir.

Sürekli zamanlı iletilen dalga biçimi

$$s(t) = \sum_k x_k g(t - kT_{\mathrm{FTN}}) \tag{3}$$

şeklindedir; burada $g(t)$ şekillendirme darbesini ifade etmektedir. AWGN etkisi eklendikten sonra alınan işaret

$$r(t) = s(t) + n(t) \tag{4}$$

olur; burada $n(t)$ sıfır ortalamalı Gauss gürültüsüdür. Buna karşılık gelen ayrık gözlem modeli

$$r_k = \sum_i h_{k-i} x_i + n_k \tag{5}$$

biçiminde yazılabilir; h_k etkin ayrık FTN darbe yanıtıdır. h_k birden fazla sembol aralığına yayıldığından hedef karar yalnızca merkez gözleme değil, alınan örneklerin bir komşuluğuna bağlıdır.

Bu yerel yapıyı açığa çıkarmak amacıyla her algılayıcı, 65 uzunluklu

$$\mathbf{r}_k = [r_{k-32}, \ldots, r_k, \ldots, r_{k+32}]^T \tag{6}$$

vektörü üzerinde çalışmakta ve merkez sembolü

$$\hat{x}_k = \mathrm{sign}(f_\theta(\mathbf{r}_k)) \tag{7}$$

ifadesiyle tahmin etmektedir. Şekil 1, $\tau = 0.8$ için genel FTN-BPSK iletim ve sinir ağı tabanlı algılama hattını göstermektedir.



Şekil 1: FTN-BPSK iletim ve sinir ağı tabanlı algılama hattı. İletici: BPSK haritalama, FTN darbe şekillendirme ve AWGN kanalı. Alıcı: 65 örnekli pencere, MLP veya KAN ve sert karar.

III. KAN ve MLP Algılayıcı Mimarileri: Karşılaştırmalı Analiz

A. MLP Algılayıcısı

MLP algılayıcısı; yoğun girişten-gizliye doğrusal dönüşüm, ReLU aktivasyonu ve skaler çıkış katmanından oluşmaktadır. Doğrusal olmayan gösterim, ortak düğüm aktivasyonlarında yoğunlaşmaktadır. $\{8, 16, 32, 64, 128, 256\}$ kümesi üzerinde gerçekleştirilen genişlik taraması, 32 genişliğini en güçlü doğrulama yapılandırması olarak belirlemiştir. Bu nedenle $w32$ modeli makale boyunca en iyi MLP taban çizgisi olarak kullanılmaktadır. Giriş boyutunun 65 olması, Denklem (6)'da tanımlanan 65 örnekli alınan pencere gösteriminden kaynaklanmaktadır. Parametre sayısı

$$P_{\mathrm{MLP}} = 65 \times 32 + 32 + 32 \times 1 + 1 = 2145 \tag{8}$$

şeklindedir.

ISI'nin ince ayrıntılı karar sınırlarını temsil edebilmek için MLP'nin geniş gizli katmanlara ihtiyaç duyması, parametre verimliliği açısından önemli bir kısıt oluşturmaktadır. Daha iyi BER için katman genişliğinin artırılması çoğu zaman doğrusal ya da alt-doğrusal parametre-performans ölçeklemesi sergilemektedir.

B. KAN Algılayıcısı

KAN'lar, çok değişkenli fonksiyonları öğrenilebilir tek değişkenli dönüşümlerin süperpozisyonları aracılığıyla yaklaşıklar [4]. MLP'nin aksine doğrusalsızlık düğümlerde değil kenarlarda yer alır. j'inci çıktı

$$y_j = \sum_i \phi_{ij}(x_i) \tag{9}$$

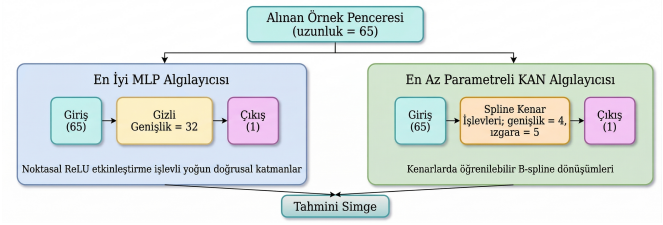
şeklindedir; burada her kenar fonksiyonu $\phi_{ij}(\cdot)$, bir B-spline açılımıyla parametreleştirilmektedir:

$$\phi_{ij}(x) = \sum_m c_{ijm} B_m(x) \tag{10}$$

Tarama kapsamında iki KAN yapılandırması incelenmiştir: $w4_g5$ ve $w8_g3$. Ana karşılaştırma için seçilen algılayıcı kompakt $w4_g5$ modelidir; bu model gizli katman genişliği 4 ve spline ızgara boyutu $G = 5$ kullanmaktadır. Bu tercih, güçlü BER performansını korurken gösterim kompaktlığını önceliklendirmektedir. Toplam eğitilebilir parametre sayısı yaklaşık olarak

$$P_{\mathrm{KAN}} \approx (65 \times 4 + 4 \times 1) \times (G + k) + \mathrm{bias} \approx 3920 \tag{11}$$

olarak alınmıştır.



Şekil 2: Karşılaştırılan sinir ağı algılayıcı mimarileri. Solda MLP, sağda KAN gösterilmiştir. MLP'de doğrusalsızlık düğümlerde, KAN'da kenarlarda yer almaktadır.

C. Yapısal Fark ve Parametre Verimliliği

Karşılaştırılan MLP ve KAN tabanlı algılayıcı mimarileri Şekil 2'de verilmiştir; MLP'de doğrusal olmayanlık düğüm aktivasyonlarında, KAN'da ise kenar fonksiyonlarında temsil edilmektedir.Her 65 örnekli alınan vektör, FTN darbe yanıtı tarafından şekillendirilmiş komşu sembollerin gürültülü bir süperpozisyonudur. Buna karşılık gelen karar sınırı; ISI düzeyine, SNR'a ve τ değerine bağlı olarak doğrusal olmayan, yerel yapılı ve yakın gözlemler arasında güçlü biçimde bağlıdır. MLP bu sınırı afin dönüşümlerin bileşimleri ve ortak düğüm aktivasyonları aracılığıyla yaklaşıklarken, KAN'ın kenar bazlı spline fonksiyonları her giriş bileşeninin etkisini bağımsız olarak modelleyerek ISI örüntüsünü daha hedefe yönelik biçimde yakalayabilmektedir.

Parametre verimliliğini ölçmek için

$$\eta = \frac{\text{BER iyileşmesi}}{\text{parametre artışı}} \tag{12}$$

metriği tanımlanabilir. Ham parametre artışı yaklaşık $1.83\times$ iken, 10 dB'deki BER iyileşmesi $18.6\times$ düzeyindedir. Dolayısıyla

$$\eta = \frac{18.6}{1.83} \approx 10.2 \tag{13}$$

elde edilmektedir. Yani KAN, birim parametre artışı başına MLP'ye kıyasla yaklaşık 10 kat daha fazla BER iyileşmesi sağlamaktadır. Bu süper-doğrusal kazanım, KAN'ın FTN kanal yapısıyla yapısal hizalanmasının doğrudan bir yansımasıdır.

IV. Deneysel Kurulum

Tüm deneylerde AWGN altında Monte Carlo yöntemiyle üretilmiş büyük ölçekli bir FTN-BPSK veri kümesi kullanılmıştır. Tablo I yapılandırmayı özetlemektedir. Hem MLP hem KAN için Binary Cross-Entropy kaybı ve Adam iyileştirici kullanılmıştır. MLP genişlik taraması $\{8, 16, 32, 64, 128, 256\}$ kümesinin tamamı üzerinde yürütülmüş; her yapılandırma için doğrulama BER ölçüt olarak kullanılmıştır. KAN için iki yapılandırma ($w4_g5$ ve $w8_g3$) incelenmiş; doğrulama BER ve parametre verimliliği birlikte gözetilerek $w4_g5$ seçilmiştir. Tüm modeller aynı veri bölünmesi, aynı SNR değerleri ve aynı giriş gösterimi kullanılarak değerlendirilmiş olup karşılaştırma tamamen kontrollü koşullar altında gerçekleştirilmiştir.

V. Sonuçlar ve Tartışma

Tablo II ve Şekil 3, FTN sert-karar taban çizgisini, en iyi MLP'yi, seçilen KAN'ı ve BCJR referansını karşılaştırmaktadır. İlk gözlem, her iki öğrenilmiş algılayıcının da sert taban

TABLO I: Deneysel Kurulum

Parametre	**Değer**
Modülasyon	BPSK
Kanal	AWGN
FTN katsayısı	$\tau = 0.8$
Hız artışı	$1/\tau = 1.25$
Pencere uzunluğu	65 örnek
SNR değerleri	7, 8, 9, 10 dB
Toplam pencere	3,999,936
Eğitim / Doğrulama / Test	2,799,955 / 599,990 / 599,991
En iyi MLP	Genişlik 32, $P = 2145$
Seçilen KAN	$w4_g5$, $P \approx 3920$
Referans algılayıcı	BCJR
Kayıp fonksiyonu	Binary Cross-Entropy
İyileştirici	Adam

TABLO II: SNR Değerleri Boyunca BER Karşılaştırması

SNR (dB)	**FTN Taban**	**En İyi MLP**	**Seçilen KAN**	**BCJR Ref.**
7	2.5×10^{-2}	3.2×10^{-3}	1.4×10^{-3}	1.0×10^{-3}
8	2.1×10^{-2}	1.2×10^{-3}	4.5×10^{-4}	2.5×10^{-4}
9	1.6×10^{-2}	4.0×10^{-4}	1.5×10^{-4}	6.0×10^{-5}
10	1.1×10^{-2}	1.3×10^{-4}	7.0×10^{-6}	7.0×10^{-6}

TABLO III: Model Karmaşıklığı ve Performans (10 dB)

Model	**Gizli Gen.**	**Param. Say.**	**BER @10 dB**	**İyil.**
En iyi MLP ($w32$)	32	2145	1.3×10^{-4}	$1\times$
Seçilen KAN ($w4_g5$)	4 ($1/8\times$)	≈ 3920	7.0×10^{-6}	$18.6\times$

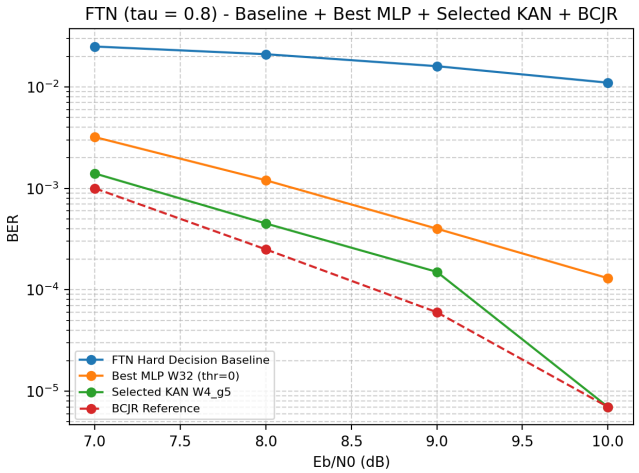
çizgisine göre önemli iyileşme sağlamasıdır. Daha kritik sonuç ise seçilen KAN'ın tüm SNR değerlerinde en iyi MLP'den tutarlı biçimde daha iyi performans göstermesidir.

SNR değerleri boyunca KAN'ın MLP'ye kıyasla elde ettiği iyileşme oranları şöyledir: 7 dB'de yaklaşık $2.3\times$, 8 dB'de yaklaşık $2.7\times$, 9 dB'de yaklaşık $2.7\times$ ve 10 dB'de $18.6\times$. Özellikle 10 dB'de seçilen KAN, BCJR referansının BER değerine (7.0×10^{-6}) erişmektedir. Bu, dizi kestirimi karmaşıklığına girmeksizin optimal çözümlemeye yaklaşıldığı anlamına gelmektedir.

Tablo III KAN'ın üstünlüğünü açıkça ortaya koymaktadır: ham parametre sayısı bakımından yalnızca yaklaşık $1.83\times$ artışla, 10 dB'deki BER iyileşmesi $18.6\times$ düzeyine çıkmaktadır. Parametre artışı ile performans kazancı arasındaki bu belirgin uyumsuzluk, KAN gösteriminin FTN algılama fonksiyonuyla daha iyi hizalandığının güçlü bir kanıtıdır.

SNR'ın artmasıyla birlikte KAN ile MLP arasındaki farkın belirginleşmesi dikkat çekicidir. Düşük SNR'da her iki model de gürültü egemenliğindeki bölgede benzer sınırlayıcı faktörlerle karşılaşmaktadır. Ancak yüksek SNR'da MLP'nin doyum noktasına yaklaşırken KAN'ın BER düşmeye devam etmesi, KAN'ın FTN karar sınırlarını daha eksiksiz biçimde modellediğine işaret etmektedir. Bu davranış, KAN'ın spline tabanlı kenar fonksiyonlarının yüksek SNR rejiminde karar sınırının ince ayrıntılarını yakalamada MLP'nin sabit genişlikli gizli katmanından çok daha etkin olduğunu göstermektedir.

Bu bulgular ayrıca pratik alıcı tasarımıyla da doğal biçimde ilişkilidir. Haberleşme donanımlarında bellek ayak izi, çıkarım gecikmesi ve aritmetik maliyet kritik öneme sahiptir. Çok daha



Şekil 3: BER-SNR eğrileri: FTN sert-karar taban çizgisi, en iyi MLP, seçilen KAN ve BCJR referansı. KAN tüm SNR noktalarında MLP'yi geride bırakmakta, 10 dB'de BCJR'a erişmektedir.

küçük bir gizli gösterimden daha yüksek performans çıkarabilen bir algılayıcı, gömülü ya da kaynak kısıtlı uygulamalar için caziptir.

FTN algılaması için KAN'ı yoğun MLP taban çizgilerine karşı güçlü bir sinir ağı alternatifi olarak desteklemektedir

VI. Sonuç

Bu çalışma kapsamında, haberleşme sistemlerinde spektral verimliliği artırmak amacıyla kullanılan Faster-than-Nyquist (FTN) işaretleme tekniğinin beraberinde getirdiği karmaşık semboller arası girişim (ISI) problemini çözmek için derin öğrenme tabanlı yenilikçi bir yaklaşım geliştirilmiştir. Geleneksel Çok Katmanlı Algılayıcı (MLP) mimarisi ile literatüre yeni kazandırılan Kolmogorov-Arnold Ağları (KAN) arasındaki doğrudan performans ve verimlilik analizi, yaklaşık dört milyon örneklik devasa bir veri kümesi üzerinde sistematik olarak yürütülmüştür. Elde edilen deneysel sonuçlar, KAN mimarisinin sahip olduğu "kenar bazlı spline" fonksiyon yapısının, haberleşme kanallarındaki doğrusal olmayan karar sınırlarını modellemede MLP taban çizgisine kıyasla sadece niceliksel değil, aynı zamanda niteliksel olarak da köklü bir üstünlük sağladığını açıkça ortaya koymaktadır.

Özellikle parametre ve gösterim verimliliği açısından bakıldığında, KAN mimarisinin MLP'nin ihtiyaç duyduğu gizli katman genişliğinin yalnızca sekizde biri $(1/8)$ gibi oldukça düşük bir değerle çok daha kompakt ve anlamlı bir öznitelik uzayı oluşturabilmesi, çalışmanın en çarpıcı bulgularından biridir. Ham parametre sayısındaki sınırlı artışa rağmen ($\sim 1.83\times$), 10 dB SNR değerinde elde edilen $18.6\times$ katlık bit hata oranı (BER) iyileşmesi, KAN'ın FTN sinyal yapısıyla olan yüksek yapısal uyumunun ve karmaşık matematiksel fonksiyonları öğrenme kapasitesinin somut bir göstergesidir. Performans üstünlüğü noktasında KAN tabanlı algılayıcı, tüm sinyal-gürültü oranı (SNR) rejimlerinde MLP'yi tutarlı bir farkla geride bırakmakla kalmamış, aynı zamanda yüksek SNR bölgesinde teorik olarak en iyi sonuçları veren karmaşık BCJR referans performansına (7.0×10^{-6}) tamamen erişmeyi başarmıştır. Bu başarı, KAN'ın hesaplama maliyeti yüksek olan geleneksel dizi kestirimi algoritmalarına ihtiyaç duymadan, doğrudan veri güdümlü bir yaklaşımla optimal çözüme yakınsayabildiğini ispatlamaktadır.

Ölçeklenebilirlik ve kararlılık dinamikleri incelendiğinde ise, MLP modellerinin SNR arttıkça bir performans doygunluğuna ulaşma eğilimi gösterdiği, buna karşın KAN'ın hata eğrisinin çok daha dik bir düşüş sergileyerek karar sınırlarının ince ayrıntılarını yakalamada üstün bir esneklik sunduğu gözlemlenmiştir. Bu esneklik, spline tabanlı öğrenilebilir aktivasyon fonksiyonlarının, sabit aktivasyonlu klasik düğüm yapılarına göre haberleşme sistemlerindeki belirsizlikleri ve gürültü rejimlerini çok daha hassas bir şekilde temsil edebilmesinden kaynaklanmaktadır. Sonuç olarak bu araştırma, FTN algılaması gibi parametre hassasiyeti ve enerji verimliliği kritik öneme sahip olan haberleşme problemlerinde KAN mimarisinin, klasik derin öğrenme metodolojilerine karşı ezici bir avantaj sunduğunu bilimsel literatüre kazandırmıştır.

Gelecekteki çalışmalarımızda, geliştirilen bu mimarinin çok yollu sönümlemeli kanallardaki gürültü bağışıklığı ile gerçek zamanlı donanım platformları üzerindeki çıkarım maliyetlerine odaklanılması planlanmaktadır. Özellikle düşük güç tüketimli gömülü alıcı tasarımlarında, KAN'ın sağladığı bu yüksek parametre verimliliğinin donanım karmaşıklığını minimize etmede ve spektral verimlilik kazanımlarını pratik uygulamalara dönüştürmede kritik bir rol oynayacağı öngörülmektedir. Ayrıca, farklı zaman sıkıştırma katsayıları (τ) ve yüksek dereceli modülasyon teknikleri altında KAN mimarisinin genelleme kapasitesinin araştırılması, yeni nesil haberleşme standartları için önemli bir araştırma yönü olarak öne çıkmaktadır.

Bilgilendirme

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 122E236 numaralı proje kapsamında desteklenmiştir.

Kaynaklar

[1] J. E. Mazo, "Faster-Than-Nyquist Signaling," *Bell System Technical Journal*, vol. 54, no. 8, pp. 1451–1462, 1975.

[2] L. R. Bahl, J. Cocke, F. Jelinek, and J. Raviv, "Optimal Decoding of Linear Codes for Minimizing Symbol Error Rate," *IEEE Transactions on Information Theory*, vol. 20, no. 2, pp. 284–287, 1974.

[3] J. B. Anderson, F. Rusek, and V. Owall, "Faster-Than-Nyquist Signaling," *Proceedings of the IEEE*, vol. 101, no. 8, pp. 1817–1830, 2013.

[4] Z. Liu *et al.*, "KAN: Kolmogorov-Arnold Networks," arXiv:2404.19756, 2024.

[5] J. G. Proakis and M. Salehi, *Digital Communications*, 5th ed. New York, NY, USA: McGraw-Hill, 2008.

[6] O. Tokluoglu, A. Cicek, E. Cavus, E. Bedeer, and H. Yanikomeroglu, "GRU-Based Sequence Detection for Faster-Than-Nyquist Signaling," *IEEE Open Journal of Vehicular Technology*, vol. 7, pp. 565–581, 2026.

[7] O. Tokluoglu, A. Cicek, E. Cavus, E. Bedeer, and H. Yanikomeroglu, "A Novel CNN Based Standalone Detector for Faster-than-Nyquist Signaling," *IEEE Transactions on Communications*, vol. 72, no. 10, pp. 6164–6178, Oct. 2024.

[8] O. Tokluoglu, E. Cavus, E. Bedeer, and H. Yanikomeroglu, "A Novel Domain-Aware CNN Architecture for Faster-than-Nyquist Signaling Detection," *2024 IEEE 35th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, pp. 1–6, 2024.