

Receptor Baseado em Autoencoder para Arranjos Lineares de Antenas

Marcelo A. C. Fernandes

Resumo—Este artigo propõe um receptor neural ponta-a-ponta baseado na arquitetura autoencoder para sistemas single-carrier com arranjos adaptativos de antenas em canais com interferência intersimbólica espacialmente dispersa. Neste modelo, cada componente multipercorso chega de uma direção de chegada distinta, acoplando os domínios espacial e temporal. O receptor proposto substitui a cadeia de beamforming, equalização e demodulação por uma rede neural treinada conjuntamente com o transmissor, que aprende estratégias de recepção não-lineares. Estabelece-se um critério baseado na relação entre o número de antenas e o número de componentes multipercursos: quando os caminhos de interferência excedem os graus de liberdade do arranjo, o beamformer LCMV apresenta um piso de taxa de erro de bit irreduzível. Resultados de simulação com modulação QPSK, cinco caminhos multipercursos e arranjos de quatro, cinco e seis antenas sobre 100 realizações de canal Monte Carlo mostram que o receptor proposto alcança até três ordens de grandeza de redução na taxa de erro de bit em relação ao LCMV no regime com graus de liberdade insuficientes, mantendo desempenho comparável nos demais cenários.

Palavras-Chave—Receptor neural, autoencoder, beamforming, interferência intersimbólica, aprendizado ponta-a-ponta, arranjo adaptativo de antenas, LCMV.

Abstract—This paper proposes an end-to-end neural receiver based on the autoencoder architecture for single-carrier systems with adaptive antenna arrays operating over channels with spatially dispersed intersymbol interference. In this model, each multipath component arrives from a distinct direction of arrival, coupling the spatial and temporal domains. The proposed receiver replaces the beamforming, equalization, and demodulation chain with a neural network jointly trained with the transmitter, learning non-linear reception strategies. A criterion based on the relationship between the number of antennas and the number of multipath components is established: when the interference paths exceed the array degrees of freedom, the LCMV beamformer exhibits an irreducible bit error rate floor. Simulation results with QPSK modulation, five multipath components, and arrays of four, five, and six antennas over 100 Monte Carlo channel realizations show that the proposed receiver achieves up to three orders of magnitude bit error rate reduction over the LCMV in the degrees-of-freedom-deficient regime, while maintaining comparable performance in other scenarios.

Keywords—Neural receiver, autoencoder, beamforming, intersymbol interference, end-to-end learning, adaptive antenna array, LCMV.

I. INTRODUÇÃO

O paradigma de interpretar um sistema de comunicação como um autoencoder, onde o transmissor atua como codificador e o receptor como decodificador com o canal

como camada intermediária não treinável, foi introduzido em [1] e gerou extensa pesquisa [2], [3]. Nesta abordagem, transmissor e receptor são otimizados conjuntamente de forma ponta-a-ponta, permitindo descobrir estratégias de comunicação que podem superar projetos clássicos baseados em blocos independentes [4], [5]. Um desafio em aberto é a adaptação a canais dinâmicos com poucas amostras piloto, abordado recentemente em [6] por meio de meta-learning.

A maior parte dos trabalhos existentes concentra-se em sistemas OFDM [7], em sistemas MIMO com desvanecimento plano [8], ou em cenários onde a equalização de ISI é tratada de forma isolada por redes neurais [9]. Abordagens baseadas em autoencoder também foram aplicadas ao projeto de beamforming em arranjos de antenas [10]. A combinação de transmissão single-carrier com arranjos adaptativos de antenas sobre canais com interferência intersimbólica (ISI) e multipercursos espacialmente dispersos permanece pouco explorada na literatura. Este cenário é comum em comunicações terrestres urbanas, ambientes indoor e comunicações subaquáticas.

No projeto clássico de receptores, um arranjo com M elementos fornece $M - 1$ graus de liberdade (DOFs) espaciais para posicionar nulos no diagrama de radiação [11], [12]. Quando o número de componentes multipercursos L satisfaz $L \leq M$, um beamformer LCMV (*Linearly Constrained Minimum Variance*) pode anular todos os caminhos produtores de ISI. Em ambientes com espalhamento rico, contudo, é frequente que $L > M$, e o receptor linear apresenta ISI residual e piso de erro irreduzível.

Neste artigo, propõe-se um receptor neural ponta-a-ponta que contorna esta limitação. As contribuições do trabalho são: (i) propõe-se uma arquitetura baseada em autoencoder (AE) para sistemas single-carrier com arranjos de M elementos sobre canais com ISI espacialmente dispersa, incorporando informação de estado do canal (CSI) e treinamento com realizações de canal variáveis; (ii) estabelece-se o critério $M - 1$ vs. $L - 1$ como fronteira que delimita o regime onde o receptor proposto se torna vantajoso em relação ao LCMV; (iii) por meio de simulação Monte Carlo com 100 realizações de canal, demonstra-se que o AE alcança até três ordens de grandeza de redução na BER quando $L > M$; (iv) introduz-se o conceito de *sensibilidade angular neural* como análogo não-linear do diagrama de radiação clássico, permitindo interpretar como o decoder processa a informação espacial.

II. MODELO DO SISTEMA

Considera-se um sistema single-carrier onde um transmissor com uma antena envia símbolos $x[n] \in \mathcal{S}$ através de um canal multipercursos para um arranjo linear uniforme (ULA) com M elementos. Cada uma das L componentes multipercursos possui ganho complexo α_ℓ e ângulo de chegada

Marcelo A. C. Fernandes, InovAI Lab, nPITI/IMD, Universidade Federal do Rio Grande do Norte (UFRN); Leading Advanced Technologies Center of Excellence (LANCE), nPITI/IMD, UFRN; Departamento de Engenharia de Computação e Automação (DCA), UFRN, Natal-RN, e-mail: mfernandes@dca.ufrn.br. Este trabalho foi parcialmente financiado por CNPq e CAPES.

(DOA, *Direction of Arrival*) θ_ℓ distinto. O sinal recebido no arranjo é expresso por

$$\mathbf{y}[n] = \sum_{\ell=0}^{L-1} \alpha_\ell x[n-\ell] \mathbf{a}(\theta_\ell) + \mathbf{n}[n] \quad (1)$$

onde $\mathbf{a}(\theta_\ell) = [1, e^{j\pi \sin \theta_\ell}, \dots, e^{j(M-1)\pi \sin \theta_\ell}]^T$ é o vetor de direção e $\mathbf{n}[n] \sim \mathcal{CN}(\mathbf{0}, \sigma_n^2 \mathbf{I}_M)$ é ruído AWGN. Neste modelo, cada tap ISI chega de uma direção diferente, acoplando os domínios espacial e temporal.

O receptor de referência considerado é o beamformer LCMV [11], que obtém o vetor de pesos $\mathbf{w}$ minimizando a potência de saída sujeito a restrições lineares:

$$\min_{\mathbf{w}} \mathbf{w}^H \mathbf{R}_{yy} \mathbf{w} \quad \text{s.a.} \quad \mathbf{C}^H \mathbf{w} = \mathbf{f} \quad (2)$$

onde $\mathbf{R}_{yy} = \mathbb{E}[\mathbf{y}\mathbf{y}^H]$ é a matriz de covariância, $\mathbf{C} = [\mathbf{a}(\theta_0), \dots, \mathbf{a}(\theta_{L-1})]$ contém os vetores de direção, e $\mathbf{f} = [1, 0, \dots, 0]^T$ especifica ganho unitário para o caminho direto e nulos para os caminhos ISI. A solução em forma fechada é:

$$\mathbf{w}_{\text{LCMV}} = \mathbf{R}_{yy}^{-1} \mathbf{C} (\mathbf{C}^H \mathbf{R}_{yy}^{-1} \mathbf{C})^{-1} \mathbf{f}. \quad (3)$$

Um arranjo com M antenas dispõe de $M - 1$ graus de liberdade (DOFs) espaciais para posicionar nulos no diagrama de radiação. A condição para anular todos os $L - 1$ caminhos ISI é

$$M - 1 \geq L - 1 \iff M \geq L. \quad (4)$$

Quando esta condição é satisfeita, a saída do LCMV reduz-se a $z[n] = \mathbf{w}^H \mathbf{y}[n] \approx \alpha_0 x[n] + \tilde{n}[n]$, livre de ISI, onde $\tilde{n}[n] = \mathbf{w}^H \mathbf{n}[n]$ é o ruído filtrado pelo beamformer, com variância $\sigma_n^2 \|\mathbf{w}\|^2$. Quando $M < L$, a matriz $\mathbf{C}$ torna-se subdeterminada e o beamformer recai para o MVDR (*Minimum Variance Distortionless Response*), apontando apenas para o caminho direto. Neste caso, $L - M$ caminhos ISI permanecem sem anulação, gerando um piso de BER que não diminui com o aumento da SNR.

III. RECEPTOR NEURAL PROPOSTO

A. Arquitetura AE Ponta-a-Ponta

A cadeia de comunicação é modelada como um auto-encoder. O encoder (transmissor) mapeia cada índice de mensagem $s \in \{1, \dots, K\}$, representado como vetor one-hot, isto é, um vetor binário de dimensão K com valor unitário na posição correspondente a s e nulo nas demais, a um símbolo 2D expresso como

$$\mathbf{x} = f_{\text{enc}}(\text{one-hot}(s); \phi) \in \mathbb{R}^2 \quad (5)$$

onde ϕ denota o conjunto de pesos e vieses do encoder, e com normalização de potência $\tilde{\mathbf{x}} = \mathbf{x} / \sqrt{\mathbb{E}[\|\mathbf{x}\|^2]}$. O encoder é composto por duas camadas totalmente conectadas (*Fully Connected* - FC) com ativação ReLU ($K \rightarrow 128 \rightarrow 2$).

Após propagação pelo canal (1), o decoder (receptor) recebe como entrada a concatenação do sinal recebido com uma estimativa do canal, e produz probabilidades a posteriori para cada símbolo

$$\hat{p}(s|\mathbf{y}, \hat{\mathbf{H}}) = f_{\text{dec}}([\mathbf{y}_{\text{ri}}^T, \hat{\mathbf{H}}_{\text{vec}}^T]^T; \psi) \quad (6)$$

onde ψ denota os parâmetros treináveis do decoder e $\mathbf{y}_{\text{ri}} = [\text{Re}(\mathbf{y})^T, \text{Im}(\mathbf{y})^T]^T \in \mathbb{R}^{2M}$ é o vetor recebido com partes real e imaginária concatenadas. O vetor $\hat{\mathbf{H}}_{\text{vec}} \in \mathbb{R}^{2ML}$ é a estimativa vetorizada do canal, obtida por mínimos quadrados (LS) a partir de N_p símbolos piloto. Para cada tap ℓ e cada antena m , a estimativa LS do coeficiente do canal $h_{\ell,m} = \alpha_\ell [\mathbf{a}(\theta_\ell)]_m$ é dada por:

$$\hat{h}_{\ell,m} = \frac{\sum_n x^*[n-\ell] y_m[n]}{\sum_n |x[n-\ell]|^2} \quad (7)$$

onde as somas percorrem os N_p símbolos piloto. O vetor $\hat{\mathbf{H}}_{\text{vec}} \in \mathbb{R}^{2ML}$ é formado empilhando-se, para $\ell = 0, \dots, L - 1$ e, internamente, $m = 0, \dots, M - 1$, as partes real e imaginária de $\hat{h}_{\ell,m}$, isto é, $\hat{\mathbf{H}}_{\text{vec}} = [\text{Re}(\hat{\mathbf{h}})^T, \text{Im}(\hat{\mathbf{h}})^T]^T$ com $\hat{\mathbf{h}} = [\hat{h}_{0,0}, \dots, \hat{h}_{0,M-1}, \dots, \hat{h}_{L-1,M-1}]^T$. Esta informação de estado do canal (CSI) permite ao decoder condicionar seu processamento à realização de canal corrente.

Uma decisão suave mapeia as probabilidades de volta ao plano I/Q:

$$\hat{\mathbf{x}}_{\text{soft}} = \sum_{k=1}^K p(s=k|\mathbf{y}) \cdot \mathbf{c}_k \quad (8)$$

onde $\mathbf{c}_k$ são os pontos da constelação aprendida pelo encoder.

B. Estratégia de Treinamento

O protocolo de treinamento é projetado para promover generalização entre realizações de canal. A cada *época*, uma nova realização de canal é sorteada com ganhos e fases aleatórios, mantendo os DOAs fixos. Dentro de cada época, cada *iteração* emprega uma SNR sorteada uniformemente no intervalo $[\text{SNR}_{\min}, \text{SNR}_{\max}]$. Esta estrutura expõe a rede a uma variedade de condições de canal e de relação sinal-ruído durante o treinamento.

No início de cada época, a CSI é estimada via mínimos quadrados conforme (7) utilizando N_p símbolos piloto, e fornecida ao decoder como entrada adicional. Com isso, o decoder condiciona seu processamento à realização de canal corrente, sem necessidade de re-treinamento.

O sistema é treinado ponta-a-ponta minimizando a entropia cruzada categórica caracterizada como

$$\mathcal{L}_{\text{AE}} = -\frac{1}{B} \sum_{i=1}^B \sum_{k=1}^K s_k^{(i)} \log p(s=k|\mathbf{y}^{(i)}) \quad (9)$$

onde B é o tamanho do mini-batch. Como o canal (1) é linear em $x[n]$ e diferenciável, os gradientes propagam-se por todos os L taps via diferenciação automática.

C. Sensibilidade Angular Neural

Para interpretar o comportamento espacial do decoder, define-se a sensibilidade angular como

$$P_{\text{neural}}(\theta) = \|\mathbf{z}(\theta)\|^2, \quad \mathbf{z}(\theta) = f_{\text{dec}}(\mathbf{a}(\theta)) \quad (10)$$

onde $\mathbf{a}(\theta)$ é o vetor de direção correspondente a uma fonte de amplitude unitária no ângulo θ . A grandeza é obtida varrendo-se θ e aplicando $\mathbf{a}(\theta)$ à porção da entrada do decoder correspondente ao sinal recebido, mantendo-se a entrada de CSI fixa na realização de canal sob análise. Esta

grandeza é o análogo não-linear do diagrama de radiação do LCMV, $|\mathbf{w}^H \mathbf{a}(\theta)|^2$, e indica como o decoder responde a sinais provenientes de diferentes direções.

IV. RESULTADOS DE SIMULAÇÃO

A. Configuração

As simulações consideram modulação QPSK ($K = 4$) com $L = 5$ componentes multipercurso e três configurações de arranjo: $M \in \{4, 5, 6\}$, correspondendo aos regimes $L > M$ (DOFs insuficientes), $L = M$ (limiar) e $L < M$ (DOFs suficientes).

O canal segue o modelo (1) com perfil de potência exponencial $|\alpha_\ell| \propto e^{-0,3\ell}$ e fases uniformes em $[0, 2\pi)$. Os DOAs θ_ℓ são sorteados uniformemente em $[-\pi/2, \pi/2]$ e permanecem fixos entre as realizações de teste, enquanto os ganhos e fases variam com dispersão de $\pm 30\%$ em torno do perfil nominal. Este modelo representa desvanecimento em bloco com geometria fixa de espalhadores.

O AE é treinado por 200 épocas com 30 iterações por época. A cada época, uma nova realização de canal é sorteada, e a cada iteração a SNR é amostrada uniformemente no intervalo $[4, 20]$ dB. O encoder possui duas camadas FC com ativação ReLU ($K \rightarrow 128 \rightarrow 2$) e o decoder três camadas FC ($d_{\text{in}} \rightarrow 384 \rightarrow 384 \rightarrow 384 \rightarrow K$) com softmax na saída. O tamanho do mini-batch é 4096 e o otimizador é o Adam com taxa de aprendizado 3×10^{-3} . A CSI é estimada via mínimos quadrados (7) com $N_p = 128$ símbolos piloto no início de cada época e fornecida como entrada adicional ao decoder.

O LCMV utiliza $N_p = 2000$ símbolos piloto para estimação da matriz de covariância $\mathbf{R}_{yy}$ e assume conhecimento dos DOAs para construção da matriz de restrições $\mathbf{C}$.

Todas as curvas de BER são obtidas sobre 100 realizações de canal Monte Carlo independentes. Reporta-se a mediana e o intervalo de confiança (IC) de 95%, calculado pelos percentis 2,5% e 97,5% das realizações. Os símbolos de teste totalizam 10 000 por realização.

B. Desempenho BER

A Fig. 1 apresenta a BER em função de E_b/N_0 para as três configurações de arranjo. Para $M = 4$ ($L > M$), o LCMV apresenta um piso de BER em torno de 8×10^{-2} , uma vez que dispõe de apenas 3 DOFs para anular 4 caminhos ISI. O AE alcança BER inferior a 10^{-4} a 18 dB, o que corresponde a uma redução de aproximadamente três ordens de grandeza. O IC do LCMV é mais largo nesta configuração, indicando maior variabilidade entre realizações de canal.

Para $M = 5$ ($L = M$), o piso do LCMV reduz-se para aproximadamente 3×10^{-2} , enquanto o AE alcança 10^{-4} a 16 dB, mantendo vantagem de mais de duas ordens de grandeza. No caso de $M = 6$ ($L < M$), o LCMV passa a dispor de DOFs suficientes para anular todos os caminhos ISI e sua BER decresce com o aumento da SNR. Ainda assim, o AE mantém vantagem de aproximadamente 10 dB ao longo de toda a faixa avaliada, indicando que o processamento não-linear extrai ganho adicional mesmo no regime $M \geq L$.




Fig. 1. BER vs. E_b/N_0 para QPSK, $L = 5$ caminhos e $M \in \{4, 5, 6\}$ antenas. Linhas sólidas: mediana sobre 100 realizações Monte Carlo. Áreas sombreadas: intervalos de confiança de 95%.

C. Análise de Constelações

A Fig. 2 mostra a constelação na saída do beamformer LCMV a $E_b/N_0 = 14$ dB para $M = 4, 5$ e 6. Os círculos vermelhos representam os pontos da constelação QPSK transmitida e os pontos azuis representam a saída do beamformer $z[n] = \mathbf{w}^H \mathbf{y}[n]$. Para $M = 4$, os pontos de saída ocupam todo o plano I/Q sem formação de agrupamentos, o que confirma a presença de ISI residual. Para $M = 5$, os agrupamentos começam a se formar, porém com dispersão. Para $M = 6$, os quatro agrupamentos tornam-se visíveis ao redor dos pontos da constelação.

A Fig. 3 mostra a constelação na saída do receptor AE nas mesmas condições. Os círculos vermelhos representam os pontos da constelação aprendida pelo encoder e os pontos azuis representam a decisão suave (8). Para $M = 4$, os




Fig. 2. Constelação na saída do LCMV a $E_b/N_0 = 14$ dB. Círculos vermelhos: constelação QPSK transmitida. Pontos azuis: saída do beamformer.

pontos de saída já se concentram ao redor dos centros da constelação aprendida, indicando que o decoder consegue resolver a ISI mesmo com DOFs insuficientes. Para $M = 5$ e $M = 6$, os agrupamentos tornam-se progressivamente mais compactos.

O encoder aprende uma constelação que difere da QPSK padrão. A geometria da constelação aprendida é otimizada para a estrutura do canal, buscando maximizar a separação no espaço de decisão do decoder.

D. Diagrama de Radiação e Sensibilidade Angular

A Fig. 4 apresenta o diagrama de radiação do LCMV, $|\mathbf{w}^H \mathbf{a}(\theta)|^2$, em coordenadas polares para as três configurações de arranjo. A linha verde indica o DOA do sinal desejado e as linhas vermelhas tracejadas indicam os DOAs dos caminhos ISI. Para $M = 4$, os nulos posicionados nas direções ISI são rasos, pois o arranjo não dispõe de DOFs suficientes para cancelamento de todos os caminhos. À medida que M aumenta, os nulos tornam-se mais profundos, atingindo cancelamento efetivo para $M = 6$.

A Fig. 5 apresenta a sensibilidade angular neural do AE (10) nas mesmas condições. O padrão obtido difere do diagrama de radiação do LCMV: ao invés de nulos pontuais, o decoder exibe uma resposta angular com múltiplos lóbulos e vales distribuídos ao longo do espaço angular. Este comportamento reflete o processamento não-linear realizado pelo decoder, que não se limita ao direcionamento de nulos e opera conjuntamente nos domínios espacial e temporal.

E. Caracterização do Canal

A Fig. 6 apresenta a distribuição dos parâmetros do canal ao longo das 100 realizações Monte Carlo. As amplitudes dos taps seguem o perfil de decaimento exponencial com




Fig. 3. Constelação na saída do AE a $E_b/N_0 = 14$ dB. Círculos vermelhos: constelação aprendida. Pontos azuis: decisão suave.




Fig. 4. Diagrama de radiação polar do LCMV para $M \in \{4, 5, 6\}$. Verde: DOA do sinal desejado. Vermelho tracejado: DOAs da ISI.

dispersão de $\pm 30\%$ em torno do valor nominal, conforme indicado pelos box plots na Fig. 6(a). As fases distribuem-se uniformemente em $[-180^\circ, 180^\circ]$, como observado na Fig. 6(b). Os DOAs permanecem fixos entre realizações, de modo que a estrutura espacial do canal é preservada enquanto os ganhos e fases variam a cada realização.

V. DISCUSSÃO

Os resultados obtidos confirmam o critério de DOFs (4) e permitem identificar os mecanismos que explicam o desempenho do receptor AE em relação ao LCMV.

O LCMV realiza filtragem espacial *linear*, formando uma combinação ponderada dos M sinais das antenas. Quando $L > M$, não existe combinação linear capaz de simultaneamente preservar o sinal desejado e rejeitar todos os caminhos ISI. O decoder do AE, por sua vez, opera como aproximador de funções não-lineares no espaço $2M$ -dimensional do sinal recebido, aprendendo fronteiras de decisão que exploram a estrutura espaço-temporal da ISI. Em consequência, o decoder realiza conjuntamente as funções de beamforming, equalização e demodulação.

A incorporação da CSI como entrada do decoder é determinante para a capacidade de generalização do receptor.




Fig. 5. Sensibilidade angular neural do AE para $M \in \{4, 5, 6\}$. Verde: DOA do sinal desejado. Vermelho tracejado: DOAs da ISI.




Fig. 6. Estatísticas dos ganhos do canal em 100 realizações. Box plots indicam mediana, quartis e bigodes. Pontos representam realizações individuais. A linha tracejada em (a) corresponde ao decaimento exponencial de referência $e^{-0.3\ell}$.

Sem esta informação, o decoder aprende um mapeamento fixo, válido para uma única realização de canal. Com a CSI estimada, o decoder condiciona seu processamento ao estado do canal corrente, adaptando-se a novas realizações em tempo de teste sem necessidade de re-treinamento.

Os resultados de constelação mostram que o encoder aprende uma geometria que difere da QPSK padrão. Os pontos da constelação aprendida são posicionados de forma a maximizar a separação no espaço de decisão do decoder, e não no plano I/Q convencional.

A análise da sensibilidade angular (10) revela que o decoder AE não opera por meio de nulos pontuais como o LCMV. O padrão angular obtido apresenta múltiplos lóbulos e vales distribuídos ao longo do espaço angular, indicando que o decoder processa conjuntamente a informação proveniente de todas as direções. Este comportamento é consistente com o processamento não-linear que permite

ao AE operar no regime $L > M$.

Quanto às limitações, a abordagem considera DOAs conhecidos para o LCMV e CSI estimada via LS para o AE. O treinamento requer um modelo de canal diferenciável, e o custo computacional do decoder neural em tempo de inferência é superior ao do LCMV.

VI. CONCLUSÃO

Neste trabalho, propôs-se um receptor neural ponta-a-ponta baseado na arquitetura autoencoder para sistemas single-carrier com arranjos adaptativos de antenas operando em canais com ISI espacialmente dispersa. O receptor substitui a cadeia de beamforming, equalização e demodulação por uma rede neural que aprende estratégias de recepção não-lineares no espaço $2M$ -dimensional do sinal recebido. Resultados de simulação com modulação QPSK, $L = 5$ caminhos e $M \in \{4, 5, 6\}$ antenas sobre 100 realizações Monte Carlo mostraram reduções de BER de até três ordens de grandeza em relação ao LCMV quando $L > M$, e vantagem de aproximadamente 10 dB mesmo no regime $M \geq L$. O critério $M - 1$ vs. $L - 1$ fornece uma diretriz para identificar quando o receptor neural se torna vantajoso. Introduziu-se também o conceito de sensibilidade angular neural como ferramenta de análise complementar ao diagrama de radiação do beamformer. Como extensões, identificam-se a avaliação com modulações de ordem superior, a adaptação a canais variantes no tempo por meio de fine-tuning online, e a validação em plataformas de hardware.

REFERÊNCIAS

- [1] T. O'shea and J. Hoydis, "An introduction to deep learning for the physical layer," *IEEE Transactions on Cognitive Communications and Networking*, vol. 3, no. 4, pp. 563–575, 2017.
- [2] O. Alnaseri, L. Alzubaidi, Y. Himeur, M. A. Ala'anzy, J. Timmermann, M. S. Gismalla, S. Atalla, and W. Mansoor, "A review on deep learning autoencoder in the design of next-generation communication systems," *IEEE Open Journal of the Communications Society*, 2026.
- [3] A. Christopoulou, D. Kosmanos, A. Xenakis, and C. Chaikalis, "Ai-enabled autoencoder-based physical layer design for 6G communication systems," *Electronics*, vol. 15, no. 3, p. 538, 2026.
- [4] S. Dörner, S. Cammerer, J. Hoydis, and S. Ten Brink, "Deep learning based communication over the air," *IEEE Journal of Selected Topics in Signal Processing*, vol. 12, no. 1, pp. 132–143, 2017.
- [5] F. Ait Aoudia and J. Hoydis, "Model-free training of end-to-end communication systems," *IEEE Journal on Selected Areas in Communications*, vol. 37, no. 11, pp. 2503–2516, 2019.
- [6] A. Owfi, J. Ashdown, K. Turck, and F. Afghah, "Online meta-learning channel autoencoder for dynamic end-to-end physical layer optimization," in *2025 IEEE Wireless Communications and Networking Conference (WCNC)*. IEEE, 2025, pp. 1–6.
- [7] A. Felix, S. Cammerer, S. Dörner, J. Hoydis, and S. Ten Brink, "Ofdm-autoencoder for end-to-end learning of communications systems," in *2018 IEEE 19th international workshop on signal processing advances in wireless communications (SPAWC)*. IEEE, 2018, pp. 1–5.
- [8] T. J. O'Shea, T. Erpek, and T. C. Clancy, "Deep learning based MIMO communications," *arXiv preprint arXiv:1707.07980*, 2017.
- [9] C. Farhati, S. Feki, H. Shaiek, A. Dziri, A. A. El Bey, and F. Abdelkefi, "Deep-learning for generic blind-joint channel equalization and power amplifier post-distortion," *IEEE Access*, vol. 11, pp. 104 754–104 762, 2023.
- [10] S. P. Shojaei, H. Soleimani, and M. Soleimani, "Supervised autoencoder-based beamforming approach for satellite mmwave communication," *International Journal of Antennas and Propagation*, vol. 2024, no. 1, p. 6750409, 2024.
- [11] H. L. Van Trees, *Optimum array processing: Part IV of detection, estimation, and modulation theory*. John Wiley & Sons, 2002.
- [12] S. S. Haykin, *Adaptive filter theory*. Pearson Education India, 2008.