

잡음 주입 기반 심층신경망을 이용한 시변 채널 예측 기법

(Noise Injection-Based Deep Neural Network Channel Prediction for Time-Varying Channels)

이 상 근*

(Sanggeun Lee)

요약

본 논문은 모바일 생성형 인공지능 기반 미디어 서비스와 같이 신뢰성 있는 무선 전송이 요구되는 서비스 환경을 고려하여, 단일입력 단일출력 시변 채널 환경에서 잡음 주입 기반 심층신경망 채널 예측 기법을 제안한다. 제안 기법은 시험 환경의 신호대잡음비에 대응되는 잡음을 훈련 입력에 주입하여 파일럿 기반 채널 추정 오차가 존재하는 환경에서도 강건한 채널 예측이 가능하도록 한다. 모의실험 결과, 제안 기법은 기본 심층신경망 대비 낮은 정규화된 평균 제곱 오류 및 비트 오류율을 보였으며, 도플러 주파수가 증가하는 환경에서 두드러진 성능 개선 효과가 나타남을 확인하였다.

■ 중심어 : 생성형 인공지능 ; 채널 예측 ; 심층신경망 ; 잡음 주입 ; 채널상태정보

Abstract

We propose a noise injection-based deep neural network channel prediction method for single-input single-output time-varying channels, motivated by service environments that require reliable wireless transmission, such as mobile generative-AI-based media services. The proposed method injects noise corresponding to the signal-to-noise ratio of the test environment into the training input, enabling robust channel prediction even in the presence of pilot-based channel estimation errors. Simulation results demonstrate that the proposed method achieves lower normalized mean squared error and bit error rate compared with a baseline deep neural network-based channel predictor. The results also indicate that the proposed method provides more pronounced performance gains in high-Doppler environments.

■ keywords : Generative artificial intelligence ; channel prediction ; deep neural network ; noise injection ; channel state information

I. 서론

최근 생성형 인공지능 기술의 발전에 따라 텍스트, 이미지, 음성, 영상 등 다양한 형태의 미디어 콘텐츠를 사용자 요구에 따라 생성하거나 재구성하는 서비스가 확산되고 있다 [1-3]. 이러한 서비스가 모바일 단말을 통해 제공될 경우, 생성된 콘텐츠의 품질뿐만 아니라 이를 단말까지 안정적으로 전달하기 위한 무선 통신 성능도 중요

한 요소가 된다 [4]. 특히 모바일 환경에서는 사용자의 위치와 이동성, 네트워크 혼잡도 등에 따라 무선 채널과 전송 품질이 시간에 따라 변동하므로, 지연시간과 전송 신뢰성이 서비스 경험에 직접적인 영향을 미칠 수 있다. 따라서 모바일 생성형 인공지능 기반의 미디어 서비스를 안정적으로 지원하기 위해서는 무선 채널의 시간적 변동을 고려하고, 다양한 이동성 및 전송 환경에서도 안정적인 통신 품질을 유지할 수 있는 전송 기술이 필요하다.

* 정회원, 국립창원대학교 인공지능공학과

이 논문은 2025학년도 국립창원대학교 신입교원 연구 지원 사업 연구비에 의하여 연구되었음

접수일자 : 2026년 04월 30일

게재확정일 : 2026년 05월 27일

수정일자 : 2026년 05월 22일

무선 통신 시스템에서 채널상태정보(channel state information; CSI)는 데이터 복조에 필수적인 요소이다. 그러나 모바일 환경에서는 사용자 이동성과 다중경로 페이딩으로 인해 채널이 시간에 따라 빠르게 변화하며, 채널 추정 시점과 실제 데이터 전송 시점 사이의 지연으로 인해 채널상태정보 노화 문제가 발생한다. 이러한 채널상태정보의 부정확성은 적응형 무선 통신 시스템의 성능을 크게 저하시킬 수 있으며, 이를 완화하기 위한 방법으로 미래 시점의 채널상태정보를 사전에 예측하는 채널 예측 기술이 연구되어 왔다 [5-10]. 특히 도플러 주파수가 증가하는 고이동성 환경에서는 채널의 시간 상관성이 빠르게 감소하므로, 채널 예측기의 강건성이 더욱 중요해진다.

시변 채널을 예측하기 위해서 기존에는 선형 예측, 칼만 필터(Kalman filtering), 위너 필터(Wiener filtering) 등 모델 기반 기법이 활발하게 연구되어 왔다 [5]. 이러한 기법들은 채널의 시간 상관성 또는 상태공간 모델을 이용하여 미래 채널을 예측할 수 있으나, 채널 통계량, 도플러 주파수, 잡음 분산 등 모델 파라미터 설정에 따라 예측 성능이 크게 달라질 수 있다. 최근에는 이러한 기존 채널 예측 기법의 한계를 보완하기 위하여 시변 채널의 시간적 상관성과 비선형적 변동 특성을 심층신경망(deep neural network; DNN), 순환신경망(recurrent neural network; RNN), 장단기기억(long short-term memory; LSTM), 게이트순환유닛(gated recurrent unit; GRU), 합성곱신경망(convolutional neural network; CNN) 및 트랜스포머(transformer)와 같은 심층학습 기반 채널 예측 기법이 연구되고 있다 [6-10]. 순환신경망, 장단기기억, 게이트순환유닛은 채널 시퀀스의 시간적 상관성을 학습하는 데 유리하며, 트랜스포머 기반 모델은 attention 구조를 통해 장기의 의존성을 학습할 수 있다는 장점이 있다. 기존 연구들은 이러한 특성을 이용하여 빠르게 변화하

는 페이딩 채널에서 미래 채널상태정보를 효과적으로 예측할 수 있음을 보였으며, 이를 통해 채널상태정보 노화로 인한 성능 저하를 완화하고 예측 채널상태정보를 링크 적응에 활용할 수 있음을 제시하였다. 그러나 기존 연구들은 실제 운용 환경에서 발생할 수 있는 학습 데이터와 시험 데이터 간 잡음 수준, 도플러 특성, 채널 계수 분포의 불일치가 채널 예측기의 일반화 성능에 미치는 영향을 충분히 다루지 않았다.

심층신경망의 잡음 강건성을 향상시키기 위하여 denoising autoencoder, dropout, robust training, multi-SNR training 등 다양한 기법이 연구되어 왔다 [11-13]. 특히 denoising autoencoder는 손상된 입력으로부터 원 입력을 복원하도록 학습하며, dropout은 학습 과정에서 은닉 유닛 또는 연결을 확률적으로 제거함으로써 과적합을 완화한다. 또한, multi-SNR training은 여러 신호대잡음비 조건의 데이터를 함께 학습하여 다양한 잡음 환경에 대한 일반화를 목표로 한다. 그러나 이러한 기법들은 주로 일반적인 정규화, 데이터 증강 또는 표현 학습 관점에서 사용되며, 파일럿 기반 채널 추정 오차의 통계적 특성을 직접 반영하기 어렵다는 한계가 있다.

본 논문에서는 모바일 생성형 인공지능 기반 미디어 서비스와 같이 안정적인 무선 전송이 요구되는 응용 분야를 동기로 하여, 단일입력 단일출력(single-input single-output; SISO) 시스템에서 잡음에 강인한 심층신경망 기반 채널 예측 기법을 제안한다. 특히 제안 기법은 고정된 길이의 파일럿 구간 채널 추정값과 이후 데이터 심볼 구간 채널 사이의 비선형 관계를 학습할 수 있고, 장단기기억, 게이트순환유닛, 트랜스포머와 같은 시퀀스 모델에 비하여 구조가 단순한 순전파형 심층신경망을 기본 채널 예측기로 사용한다. 또한 제안 기법은 채널 추정 오차에 대한 강건성을 향상시키기 위하여 학습 과정에서 시험 환경의 신호대잡음비에 대응되는 잡음을 입력

채널에 주입한다. 본 논문에서의 잡음 주입 기법은 단순히 일반화 성능 향상을 위한 임의의 데이터 증강이 아니라, 시험 단계에서 발생하는 파일럿 기반 채널 추정 오차를 훈련 단계에서 반영하기 위하여 사용된다. 또한 신호대잡음비별로 심층신경망을 개별적으로 학습함으로써 각 잡음 환경에 특화된 채널 예측기를 구성한다. 제안 기법의 성능은 도플러 주파수 변화에 따른 채널 예측 정확도와 예측 채널상태정보 기반 비트오류율을 통해 평가한다. 모의실험 결과를 통해 제안 기법이 채널상태정보 노화와 채널 추정 오차가 존재하는 단일입력 단일출력 환경에서 기본 심층신경망 대비 향상된 채널 예측 성능을 제공할 수 있음을 보인다.

II. 본 론

1. 시스템 모델

본 논문에서는 송수신단이 각각 한 개의 안테나를 가지는 단일입력 단일출력(single-input single-output; SISO) 시스템을 고려한다. 이동성을 갖는 단말을 고려할 때, t 번째 심볼 구간에서의 수신 신호 $y(t)$ 는 다음과 같이 표현할 수 있다 [14].

$$y(t) = \sqrt{P}h(t)x(t) + n(t) \quad (1)$$

식 (1)에서 P 는 송신 파워, $h(t)$ 는 페이딩 채널, $n(t)$ 는 $\mathbb{E}[n(t)] = 0$, $\mathbb{E}[|n(t)|^2] = \sigma_n^2$ 인 부가 백색 가우시안 잡음(additive white Gaussian noise), $x(t)$ 는 $\mathbb{E}[|x(t)|^2] = 1$ 을 만족하는 송신 신호를 나타내고, $\mathbb{E}[\cdot]$ 는 평균 연산자를 의미한다. Jakes 모델을 따르는 시변 채널 $h(t)$ 는 광의의 정상성(wide sense stationary)을 가지며, $\mathbb{E}[h(t)] = 0$, $\mathbb{E}[|h(t)|^2] = 1$ 을 만족하는 복소 랜덤 변수이다. 또한, $h(t)$ 는 사용자의 속력 v 와 중심주파수 f_c , 광속 c 로 정의되는 최대 도플러 주파수 $f_D = \frac{vf_c}{c}$ 와 시간 차이 Δ 와 대하여 $J_0(2\pi f_D \Delta)$ 의 자기상관 함수를 갖는다.

수신 신호를 복조하기 위하여 수신단은 채널상태정보를 필요로 하고, 이를 위하여 송신단은 t_{pilot} 번째 심볼 구간에서 파일럿 신호를 전송한다. 최소자승법(least square; LS) 알고리즘을 기반으로 채널을 추정할 경우, 수신단은 $h(t_{\text{pilot}})$ 에 대응되는 추정 채널 $\hat{h}(t_{\text{pilot}})$ 을 다음과 같이 획득한다.

$$\begin{aligned} \hat{h}(t_{\text{pilot}}) &= \frac{1}{\sqrt{P}x(t_{\text{pilot}})}y(t_{\text{pilot}}) \\ &= h(t_{\text{pilot}}) + \frac{n(t_{\text{pilot}})}{\sqrt{P}x(t_{\text{pilot}})} \end{aligned} \quad (2)$$

이때 $x(t_{\text{pilot}})$ 은 송수신단이 상호 간 알고 있는 파일럿 신호이며, 본 논문에서는 단위 전력 파일럿 심볼, 즉 $|x(t_{\text{pilot}})|^2 = 1$ 을 가정한다. 또한 잡음이 평균이 0이고 분산이 σ_n^2 인 복소 가우시안 분포를 따르므로, 추정 오차 $\tilde{n}(t_{\text{pilot}}) = n(t_{\text{pilot}})/\sqrt{P}x(t_{\text{pilot}})$ 의 분산은 $\tilde{\sigma}_n^2 = \sigma_n^2/P$ 와 같이 주어진다. 신호대잡음비(signal-to-noise ratio)를 $\gamma = P/\sigma_n^2$ 와 같이 정의하면 추정 오차의 분산은 $\tilde{\sigma}_n^2 = 1/\gamma$ 와 같이 나타낼 수 있다.

한편, $t_{\text{data}} > t_{\text{pilot}}$ 번째 심볼 구간에서 수신되는 데이터 심볼을 복조하기 위하여 수신단은 $\hat{h}(t_{\text{pilot}})$ 을 기반으로 $h(t_{\text{data}})$ 에 대응되는 예측 채널 $\tilde{h}(t_{\text{data}})$ 를 획득한다. 또한, 예측된 채널의 성능 평가를 위하여, 본 논문에서는 다음과 같은 정규화된 평균 제곱 오류(normalized mean squared error; NMSE)를 사용한다.

$$\epsilon = \frac{\mathbb{E}[|\tilde{h}(t_{\text{data}}) - h(t_{\text{data}})|^2]}{\mathbb{E}[|h(t_{\text{data}})|^2]} \quad (3)$$

2. 심층신경망 기반 채널 예측기

본 절에서는 과거 파일럿 구간에서 추정된 채널상태정보를 이용하여 미래 데이터 전송 구간의 채널을 예측하기 위한 심층신경망 기반 채널 예측기를 설명한다 [15]. 본 논문에서는 그림 1과 같이 L 개의 연속된 파일럿 심볼 구간에서 획득

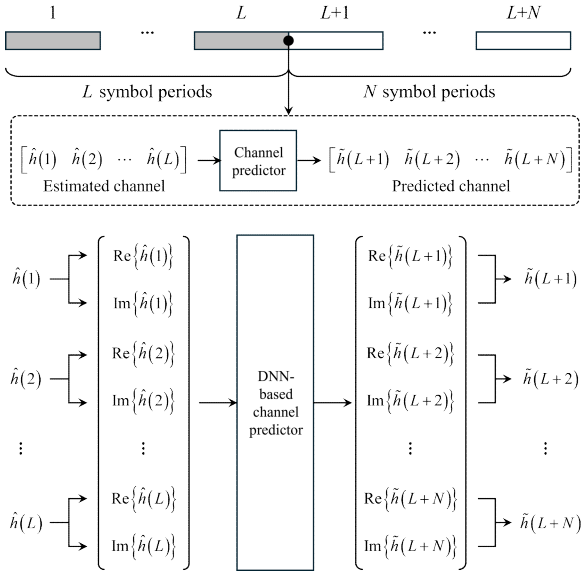


그림 1. 파일럿 심볼 구간의 추정 채널을 이용하여 데이터 심볼 구간의 채널을 예측하는 심층신경망 기반 채널 예측기의 입출력 구조

한 추정 채널을 기반으로, 그 이후 N 개의 연속된 데이터 심볼 구간에 대응되는 채널을 예측하는 시스템을 고려한다. 구체적으로, 파일럿 구간은 $t_{\text{pilot}} = 1, 2, \dots, L$ 로 정의되고, 해당 구간에서 수신단은 식 (2)를 이용하여 추정 채널 $\hat{h}(1), \hat{h}(2), \dots, \hat{h}(L)$ 을 획득한다. 채널 예측기는 L 개의 추정 채널을 기반으로 데이터 구간 $t_{\text{data}} = L+1, L+2, \dots, L+N$ 에 해당하는 미래 채널 $\tilde{h}(L+1), \tilde{h}(L+2), \dots, \tilde{h}(L+N)$ 을 예측하는 것이다. 즉, 본 논문에서의 채널 예측은 길이 L 의 과거 채널 시계열로부터 길이 N 의 미래 채널 시계열을 추정하는 다중 출력 회귀(multi-output regression) 문제로 정의될 수 있다. 이를 수식으로 나타내면, 학습 가능한 파라미터 집합 θ 를 갖는 심층신경망 기반 채널 예측기를 함수 $f_{\theta}(\cdot)$ 를 이용하여 표현할 수 있다.

$$\begin{aligned} & [\tilde{h}(L+1), \tilde{h}(L+2), \dots, \tilde{h}(L+N)] \\ & = f_{\theta}(\hat{h}(1), \hat{h}(2), \dots, \hat{h}(L)) \end{aligned} \quad (4)$$

일반적으로 심층신경망의 파라미터 θ 는 실수 범위에서 정의되므로, 본 논문에서 심층신경망의 입력 및 출력은 복소 채널 계수의 실수부와 허수부로 분리하여 구성한다. 이에 따라 입력 벡터

\mathbf{z}_{in} 은 L 개의 추정 채널에 대한 실수부와 허수부를 순차적으로 배열하여 다음과 같이 정의한다.

$$\mathbf{z}_{\text{in}} = [\text{Re}\{\hat{h}(1)\}, \text{Im}\{\hat{h}(1)\}, \dots, \text{Re}\{\hat{h}(L)\}, \text{Im}\{\hat{h}(L)\}] \quad (5)$$

마찬가지로 심층신경망의 출력 벡터 \mathbf{z}_{out} 은 N 개의 미래 데이터 심볼 구간에 대한 예측 채널의 실수부와 허수부로 구성되며, 다음과 같이 표현된다.

$$\mathbf{z}_{\text{out}} = [\text{Re}\{\tilde{h}(L+1)\}, \text{Im}\{\tilde{h}(L+1)\}, \dots, \text{Re}\{\tilde{h}(L+N)\}, \text{Im}\{\tilde{h}(L+N)\}] \quad (6)$$

따라서 본 논문의 채널 시계열 예측 문제는 다음과 같이 쓸 수 있다.

$$\mathbf{z}_{\text{out}} = f_{\theta}(\mathbf{z}_{\text{in}}) \quad (7)$$

한편, 본 논문에서 사용하는 심층신경망은 M 개의 은닉층(hidden layer)을 갖는 완전연결 신경망 구조로 구성되고, 각 은닉층의 노드 수는 d_1, d_2, \dots, d_M 이며, d_0, d_{M+1} 은 각각 입력층과 출력층의 노드수를 나타낸다. 앞서 정의한 입력 벡터 \mathbf{z}_{in} 와 출력 벡터 \mathbf{z}_{out} 의 차원을 고려하면 $d_0 = 2L$, $d_{M+1} = 2N$ 이다. 또한, $m = 0, 1, \dots, M$ 에 대해 m 번째 계층과 $m+1$ 번째 계층을 연결하는 가중치 행렬과 바이어스 벡터를 각각 $\mathbf{W}_m \in \mathbb{R}^{d_{m+1} \times d_m}$, $\mathbf{b}_m \in \mathbb{R}^{d_{m+1}}$ 로 정의한다. 심층신경망의 입력에 $\mathbf{x}_0 = \mathbf{z}_{\text{in}}$ 에 대하여, m 번째 은닉층의 출력 \mathbf{x}_m 은 다음과 같이 표현된다.

$$\mathbf{x}_m = \Phi(\mathbf{W}_{m-1}\mathbf{x}_{m-1} + \mathbf{b}_{m-1}), m = 1, 2, \dots, M \quad (8)$$

이때 $\Phi(\cdot)$ 는 비선형 활성화함수(activation function)를 의미하며, 본 논문에서는 정류선형 유닛(rectified linear unit; ReLU)을 사용한다. 출력층에서는 다음과 같이 선형 출력을 사용한다.

$$f_{\theta}(\mathbf{z}_{\text{in}}) = \mathbf{W}_M \mathbf{x}_M + \mathbf{b}_M \quad (9)$$

한편, 심층신경망의 파라미터 집합 $\theta = \{\mathbf{W}_m, \mathbf{b}_m\}_{m=0}^M$ 을 학습시키기 위하여 N_{training} 번의 독립적인 채널 실현으로부터 훈련데이터

쌍을 구현한다. i 번째 채널 실현 $h^{(i)}(1), h^{(i)}(2), \dots, h^{(i)}(L+N)$ 으로부터 구성된 훈련 샘플의 입력 벡터를 $\mathbf{z}_{\text{in}}^{(i)}$, 정답 벡터를 $\mathbf{z}_{\text{tar}}^{(i)}$ 라고 하면, 정답 벡터는 실제 미래 채널을 이용하여 다음과 같이 정의된다.

$$\mathbf{z}_{\text{tar}}^{(i)} = [\text{Re}\{h^{(i)}(L+1)\}, \text{Im}\{h^{(i)}(L+1)\}, \dots, \text{Re}\{h^{(i)}(L+N)\}, \text{Im}\{h^{(i)}(L+N)\}] \quad (10)$$

이때 $i = 1, 2, \dots, N_{\text{training}}$ 이다. 심층신경망은 예측 출력 $f_{\theta}(\mathbf{z}_{\text{in}}^{(i)})$ 이 정답 벡터 $\mathbf{z}_{\text{tar}}^{(i)}$ 와 가까워지도록 학습되며, 이를 위한 구체적인 학습 방법은 다음 절에서 설명한다.

3. 잡음 주입 기반 강건 채널 예측 기법

본 절에서는 심층신경망 기반 채널 예측기의 강건성을 향상시키기 위한 훈련 방법을 설명한다. 앞 절에서 설명한 것처럼 심층신경망 기반 채널 예측기는 L 개의 과거 채널 계수를 이용하여 N 개의 미래 채널 계수를 예측한다. 그러나 실제 시험 환경에서 수신단이 사용하는 채널상태 정보는 파일럿 기반 채널 추정 과정을 통하여 획득되므로, 수신 잡음에 의한 추정 오차를 포함한다. 따라서 잡음이 포함되지 않은 기준 채널 계수만으로 심층신경망을 학습할 경우, 시험 단계에서 입력 채널상태정보의 불확실성으로 인해 예측 성능이 저하될 수 있다.

이를 고려하여 본 논문에서는 시험 환경의 신호대잡음비에 대응되는 심층신경망을 개별적으로 학습하는 방법을 사용한다. 구체적으로, II-1 절에서 설명한 것과 같이 최소자승법 알고리즘으로 추정된 채널에는 신호대잡음비 γ 에 의해 결정되는 채널 추정 오차가 포함되므로, 시험 환경에서 고려하는 신호대잡음비 $\gamma_g, g = 1, 2, \dots, G$ 에 대하여 서로 다른 잡음 수준을 갖는 훈련 입력을 구성하고, 이에 대응되는 심층신경망 파라미터 $\theta(\gamma_g)$ 를 각각 학습한다. 따라서 γ_g 에 대해 학습된 채널 예측기 $f_{\theta(\gamma_g)}(\cdot)$ 는 해당 신호대잡

음비 환경에서 발생할 수 있는 채널 추정 오차 특성을 반영한 예측기로 동작한다. 특정 시험 신호대잡음비 γ_g 에 대하여, 훈련 과정에서는 다수의 독립적인 채널 실현으로부터 기준 입력 벡터와 정답 벡터를 구성한 뒤, 기준 입력 벡터에 γ_g 에 대응되는 잡음을 주입한다. 마지막으로 잡음이 주입된 입력으로부터 실제 미래 채널을 예측하도록 심층신경망 $f_{\theta(\gamma_g)}(\cdot)$ 을 학습한다. 반면 시험 과정에서는 실제 파일럿 심볼 구간에서 추정된 채널상태정보를 이용하여 입력 벡터를 구성하고, 시험 환경의 신호대잡음비 γ_g 에 대응하여 학습된 심층신경망 $f_{\theta(\gamma_g)}(\cdot)$ 을 사용하여 미래 채널을 예측한다.

먼저 훈련 환경에서 i 번째 채널 실현에 대한 기준 입력 벡터 $\mathbf{z}_{\text{in}}^{(i)}$ 와 정답 벡터 $\mathbf{z}_{\text{tar}}^{(i)}$ 는 다음과 같이 정의된다.

$$\mathbf{z}_{\text{in}}^{(i)} = [\text{Re}\{h^{(i)}(1)\}, \text{Im}\{h^{(i)}(1)\}, \dots, \text{Re}\{h^{(i)}(L)\}, \text{Im}\{h^{(i)}(L)\}] \quad (11)$$

$$\mathbf{z}_{\text{tar}}^{(i)} = [\text{Re}\{h^{(i)}(L+1)\}, \text{Im}\{h^{(i)}(L+1)\}, \dots, \text{Re}\{h^{(i)}(L+N)\}, \text{Im}\{h^{(i)}(L+N)\}] \quad (12)$$

이때 식 (11)과 (12)의 기준 입력 벡터 $\mathbf{z}_{\text{in}}^{(i)}$ 와 정답 벡터 $\mathbf{z}_{\text{tar}}^{(i)}$ 는 매우 높은 신호대잡음비를 갖는 훈련 단계 환경에서 획득된 채널 정보로부터 구성된 것으로 가정할 수 있다. 그러나 시험 단계에서 수신단이 사용하는 채널상태정보는 파일럿 기반 채널 추정 과정에서 잡음의 영향을 받는다. 따라서 본 논문에서는 훈련 과정에서 입력 벡터에 인위적인 잡음을 주입하여 시험 환경에서 발생할 수 있는 채널 추정 오차를 반영한다. 구체적으로, i 번째 채널 실현에 대한 잡음 주입 입력 벡터는 다음과 같이 정의한다.

$$\hat{\mathbf{z}}_{\text{in}}^{(i)}(\gamma_g) = \mathbf{z}_{\text{in}}^{(i)} + \mathbf{w}_{\gamma_g}^{(i)} \quad (13)$$

여기에서 $\mathbf{w}_{\gamma_g}^{(i)} \in \mathbb{R}^{2L}$ 은 입력 벡터에 주입되는 부가 백색 가우시안 잡음으로, $\mathbf{w}_{\gamma_g}^{(i)}$ 의 각 성분은

평균이 0이고 분산이 $1/(2\gamma_g)$ 인 가우시안 분포를 따르는 독립적인 랜덤 변수이다. 결과적으로, 식 (13)은 시험 환경에서 $1/\gamma$ 의 분산을 갖는 채널 추정 오차를 훈련 입력에 반영하는 역할을 한다.

기본 심층신경망은 일반적으로 예측 출력과 정답 벡터 사이의 손실함수를 최소화하도록 학습되며, 채널 예측기와 같이 다중 출력 회귀 문제에 대해서는 다음과 같은 평균제곱오차(mean squared error; MSE) 기반 손실함수가 널리 사용된다.

$$L(\theta) = \frac{1}{N_{\text{training}}} \sum_{i=1}^{N_{\text{training}}} \| \mathbf{z}_{\text{tar}}^{(i)} - f_{\theta}(\mathbf{z}_{\text{in}}^{(i)}) \|^2_F \quad (14)$$

식 (14)은 잡음이 포함되지 않은 기준 입력 벡터 $\mathbf{z}_{\text{in}}^{(i)}$ 에 대한 예측 출력이 실제 미래 채널로부터 구성된 정답 벡터 $\mathbf{z}_{\text{tar}}^{(i)}$ 에 가까워지도록 심층신경망을 학습시키는 손실함수이다. 그러나 앞에서 서술한 것과 같이 시험 단계에서 수신단이 사용하는 채널상태정보는 채널 추정 오차를 포함하므로, 식 (14)만으로 학습된 심층신경망은 잡음에 대한 충분한 강건성을 확보하기 어렵다. 이를 고려하여 본 논문에서는 잡음 주입 입력 벡터 $\hat{\mathbf{z}}_{\text{in}}^{(i)}$ 를 이용하는 손실함수를 제안한다. 신호대잡음비 γ_g 에 대응되는 제안 손실함수는 다음과 같이 정의된다.

$$\hat{L}(\theta, \gamma_g) = \frac{1}{N_{\text{training}}} \sum_{i=1}^{N_{\text{training}}} \| \mathbf{z}_{\text{tar}}^{(i)} - f_{\theta(\gamma_g)}(\hat{\mathbf{z}}_{\text{in}}^{(i)}(\gamma_g)) \|^2_F \quad (15)$$

식 (15)는 잡음이 주입된 입력 벡터가 주어졌을 때에도 실제 미래 채널을 정확히 예측하도록 심층신경망을 학습시키는 손실함수이다. 즉, 제안 기법은 훈련 과정에서 시험 환경의 신호대잡음비에 대응되는 입력 불확실성을 명시적으로 반영하고, 해당 잡음 조건에서 미래 채널을 예측하도록 파라미터 $\theta(\gamma_g)$ 를 최적화한다. 따라서 심층신경망은 입력 잡음의 세부적인 변화에 과도하게 의존하기보다, 파일럿 심볼 구간에서의 채널

표 1. 시스템 파라미터 및 심층신경망 하이퍼파라미터

System Parameters	Value
Antenna configuration	SISO
Center frequency [GHz]	2
Symbol duration [sec]	6.67×10^{-5}
Modulation scheme	QAM
Modulation order	4
DNN Hyperparameters	Value
Number of hidden layers, M	2
Number of nodes per hidden layer, d_1, d_2, \dots, d_M	512
Batch size	64
Optimizer	Adam
Learning rate	0.001
Number of epochs	200

계수의 시간적 상관성을 기반으로 미래 채널을 예측하도록 학습된다.

4. 실험 결과

본 절에서는 제안하는 잡음 주입 기반 심층신경망 기반 채널 예측기의 성능을 모의실험을 통해 검증한다. 모의실험에 사용된 주요 시스템 파라미터와 심층신경망 하이퍼파라미터는 표 1에 정리하였다. 특히 제안하는 심층신경망을 학습시키기 위하여 $N_{\text{training}} = 100,000$ 개의 서로 독립적으로 생성된 레일리 페이딩 채널을 사용하였고, 학습된 심층신경망의 성능을 검증하기 위하여 $N_{\text{test}} = 100,000$ 개의 서로 독립적으로 생성된 레일리 페이딩 채널을 사용하였다. 별도의 검증 데이터는 사용하지 않았으며, 고정적으로 200번의 epoch를 사용하였다. 또한 N_{training} 개의 채널에 신호대잡음비 γ 가 0, 5, 10, 15, 20, 25, 30dB에 해당하는 잡음을 주입하여 심층신경망을 학습시켰다. 제안하는 기법의 훈련 과정은 오프라인으로 이루어지며, 고려하는 신호대잡음비의 후보군에 따라 저장해야 하는 심층신경망 모델 수와 오프라인 학습 비용이 증가하는 특성을 갖는다. 시험 단계에서는 데이터 심볼 구간에서의 신호대잡음비에 해당되는 심층신경망을 선택한 뒤, 해당 모델의 순전파를 통하여 채널 예측을 수행하였다. 시험 단계에서는 훈련 단계에서 학습된 심층신경망을 사용하므로, 제안하는 심층신경망

표 2. 10^{-2} NMSE 달성 기준 기본 심층신경망 대비 제안 기법의 신호대잡음비 이득

	$L = 30$	$L = 50$
$f_D = 30\text{Hz}$	10.87dB	7.83dB
$f_D = 100\text{Hz}$	12.10dB	8.25dB

의 복잡도는 기본 심층신경망의 복잡도와 동일하다.

채널 예측이 필요한 데이터 심볼 구간의 길이 $N=20$ 에 대하여, 심층신경망의 입력 길이에 따른 성능 변화를 확인하기 위하여 파일럿 심볼 구간의 길이 $L=30$ 및 $L=50$ 을 고려하였다. 각 경우에 대하여 제안하는 심층신경망은 $L=30$ 인 경우 314,408개, $L=50$ 인 경우 334,888개의 심층신경망 파라미터를 가진다. 이는 32-bit floating point 형식으로 저장할 경우 단일 모델의 저장 비용은 각각 약 1.26MB, 1.34MB이며, 7개의 신호대잡음비 모델을 모두 저장할 경우 각각 약 8.80MB 및 9.38MB의 저장공간을 요구한다 [16]. 또한 도플러 주파수에 따른 채널 시변성의 영향을 분석하기 위하여 $f_D = 30\text{Hz}$ 및 $f_D = 100\text{Hz}$ 환경에서 실험을 수행하였다. 성능 비교를 위하여 데이터 심볼 구간의 채널을 별도로 예측하지 않고 과거 파일럿 심볼 구간에서 추정된 채널을 그대로 사용하는 outdated 채널 기반 방법을 고려하였다. 또한 제안하는 기법의 성능을 검증하기 위한 평균 NMSE $\bar{\epsilon}$ 은 수식 (3)을 이용하여 얻을 수 있는 n_{test} 번째 시험 채널에 대한 $\epsilon(n_{\text{test}})$ 에 대하여 다음과 같이 계산하였다.

$$\bar{\epsilon} = \frac{1}{N_{\text{test}}} \sum_{n_{\text{test}}=1}^{N_{\text{test}}} \epsilon(n_{\text{test}}) \quad (16)$$

그림 2는 $N=20$ 에 대하여 도플러 주파수에 따른 예측 채널의 NMSE 성능을 나타낸다. 그림 2(a)는 $f_D = 30\text{Hz}$, 그림 2(b)는 $f_D = 100\text{Hz}$ 환경에서의 결과이며, 각 그림에서는 $L=30$ 및 $L=50$ 에 대한 성능을 함께 나타내었다. 또한 제안 기법의 잡음 주입의 효과를 정량적으로 보기 위하여, 10^{-2} 수준의 NMSE 달성 기준의 신호대잡음비 이득을 표 2에 정리하였다. 기존

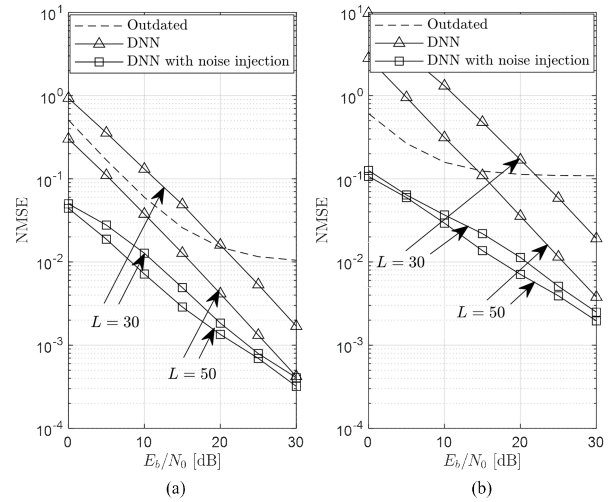


그림 2. 도플러 주파수에 따른 예측 채널의 NMSE 성능 ($L=30, L=50$), (a) $f_D = 30\text{Hz}$, (b) $f_D = 100\text{Hz}$




그림 3. 도플러 주파수에 따른 예측 채널 기반 BER 성능 ($L=50$), (a) $f_D = 30\text{Hz}$, (b) $f_D = 100\text{Hz}$

outdated 방법은 데이터 심볼 구간의 채널 변화를 고려하지 않고 과거 채널상태정보를 그대로 사용하므로, 신호대잡음비가 증가하더라도 채널 노화에 의한 오차가 남아 오류 마루(error floor) 현상이 나타난다. 반면 심층신경망 기반 채널 예측기는 과거 채널 시계열에 포함된 시간적 상관성을 이용하여 미래 채널을 예측하므로, 신호대잡음비가 증가할수록 NMSE 성능이 감소하는 경향을 갖는다. 또한 훈련 과정에서 활용하는 채널 시계열의 길이가 증가할수록 심층신경망 기반 채널 예측기의 성능이 향상되는 경향을 보인

다. 이는 $f_D=30\text{Hz}$ 환경 및 $f_D=100\text{Hz}$ 환경 모두에서 $L=50$ 인 경우가 $L=30$ 인 경우보다 낮은 NMSE 성능을 달성하는 결과를 통해 확인할 수 있다. 또한 $L=30$ 인 경우 $L=50$ 인 경우보다 더 큰 신호대잡음비 이득이 관찰되었는데, 이는 훈련을 위하여 활용 가능한 채널상태정보가 상대적으로 제한된 경우 잡음 주입에 의한 강건성 개선 효과가 더 크게 나타남을 의미한다.

제안하는 잡음 주입 기반 심층신경망을 사용한 채널 예측기는 기본 심층신경망을 이용한 채널 예측기보다 우수한 NMSE 성능을 보인다. 이는 훈련 과정에서 입력 채널상태정보의 잡음 영향을 반영함으로써, 파일럿 심볼 구간의 채널 추정 오차의 영향을 완화한 결과로 해석할 수 있다. 두 채널 예측기의 성능 차이는 높은 신호대잡음비 영역에서 작아지는데, 이는 파일럿 기반 채널 추정 오차가 작아지므로 잡음 주입에 의한 성능 개선 효과가 줄어들기 때문이다.

그림 3은 $L=50$ 인 경우의 BER 성능을 나타내며, 제안된 기법의 성능을 검증하기 위하여 데이터 심볼 구간의 채널을 수신단이 완벽하게 알고 있는 perfect CSI 경우를 비교군으로 함께 나타내었다. 그림 3(a)의 $f_D=30\text{Hz}$ 환경에서는 채널 변화가 비교적 완만하므로, 제안하는 잡음 주입 기반 심층신경망 채널 예측기를 사용할 경우 outdated 방법보다 향상된 BER 성능을 보이며, 이는 NMSE 성능 개선이 실제 데이터 복조 성능 향상으로 이어짐을 의미한다. 또한 그림 3(b)의 $f_D=100\text{Hz}$ 환경에서는 이러한 제안 기법의 우수성이 크게 두드러지는 것을 확인 가능하다.

III. 결 론

본 논문에서는 모바일 생성형 인공지능 기반 미디어 서비스와 같이 신뢰성 있는 무선 전송이 요구되는 환경을 고려하여, 단일입력 단일출력 시변 채널 환경에서 파일럿 기반 채널 추정 오차를 고려한 잡음 주입 기반 심층신경망 채널 예측

기법을 제안하였다. 제안 기법은 파일럿 기반 채널 추정 오차가 존재하는 환경에서도 강건한 채널 예측을 위하여, 시험 환경의 신호대잡음비에 대응되는 잡음을 훈련 입력에 주입하여 심층신경망을 훈련한다. 모의실험 결과, 제안하는 잡음 주입 기반 학습은 outdated 채널상태정보 기반 방법뿐 아니라 기본 심층신경망 대비 향상된 NMSE 및 BER 성능을 달성함을 확인하였다. 다만 본 논문에서의 검증은 단일입력 단일출력 환경에 한정되므로, 향후 다중입력 다중출력 (multiple-input multiple output; MIMO) 시스템, 직교 주파수 분할 다중(orthogonal frequency division multiplexing; OFDM) 등 다양한 환경에서의 성능 검증이 필요하다.

REFERENCES

- [1] 김소연, 서호건, “생성형 AI와 프롬프트 엔지니어링 기반 아동 문해력 향상을 위한 애플리케이션,” *스마트미디어저널*, 제13권, 제8호, 26-38쪽, 2024년
- [2] 황민지, 김병욱, 한지애, “그래픽 디자인에서 이미지 생성형 AI 툴의 활용 우위도 분석,” *스마트미디어저널*, 제14권, 제2호, 9-18쪽, 2025년
- [3] 장우성, 서채연, 전병국, 김영철, “대인 관계 유형이 적용된 프롬프트 엔지니어링을 통한 게임 내 사용자와 NPC 간 상호작용 개선 연구,” *스마트미디어저널*, 제14권, 제8호, 110-116쪽, 2025년
- [4] Y.-J. Liu, H. Du, X. Xu, R. Zhang, G. Feng, B. Cao, D. Niyato, D. I. Kim, A. Jamalipour, K. B. Letaief, and R. Tafazolli, “A survey of integrating generative artificial intelligence and 6G mobile services: architectures, solutions, technologies and outlooks,” *IEEE Trans. Cognit. Commun. Netw.*, vol. 11, no. 3, pp. 1334-1356, Jun. 2025.
- [5] H. Kim, S. Kim, H. Lee, C. Jang, Y. Choi, and J. Choi, “Massive MIMO channel prediction: Kalman filtering vs. machine learning,” *IEEE Trans. Commun.*, vol. 69, no. 1, pp. 518-528, Jan. 2021.
- [6] W. Jiang and H. D. Schotten, “Deep learning for fading channel prediction,” *IEEE Open J. Commun. Soc.*, vol. 1, pp. 320-332, 2020.
- [7] W. Jiang and H. D. Schotten, “Neural network-based fading channel prediction: A comprehensive overview,” *IEEE Access*, vol. 7, pp. 118112-118124, 2019.
- [8] C. Luo, J. Ji, Q. Wang, X. Chen, and P. Li,

- “Channel state information prediction for 5G wireless communications: A deep learning approach,” *IEEE Trans. Netw. Sci. Eng.*, vol. 7, no. 1, pp. 227-236, Jan. 2020.
- [9] L. Liu, H. Feng, T. Yang, and B. Hu, “MIMO-OFDM wireless channel prediction by exploiting spatial-temporal correlation,” *IEEE Trans. Wireless Commun.*, vol. 13, no. 1, pp. 310-319, Jan. 2014.
- [10] T. Zhou, X. Liu, Z. Xiang, H. Zhang, B. Ai, and L. Liu, “Transformer network based channel prediction for CSI feedback enhancement in AI-native air interface,” *IEEE Trans. Wireless Commun.*, vol. 23, no. 9, pp. 11154-11167, Sep. 2024.
- [11] C. M. Bishop, “Training with noise is equivalent to Tikhonov regularization,” *Neural Comput.*, vol. 7, no. 1, pp. 108-116, Jan. 1995.
- [12] P. Vincent, H. Larochelle, Y. Bengio, and P.-A. Manzagol, “Extracting and composing robust features with denoising autoencoders,” in *Proc. 25th Int. Conf. Mach. Learn.*, New York, NY, USA, 2008, pp. 1096-1103.
- [13] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: A simple way to prevent neural networks from overfitting,” *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929-1958, 2014.
- [14] Y. Li, and X. Huang, “The simulation of independent Rayleigh faders,” *IEEE Trans. Commun.*, vol. 50, no. 9, pp. 1503-1514, Sep. 2002.
- [15] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, The MIT Press, 2016.
- [16] V. Sze, Y.-H. Chen, T.-J. Yang, and J. S. Emer, “Efficient processing of deep neural networks: A tutorial and survey,” *Proc. IEEE*, vol. 105, no. 12, pp. 2295-2329, Dec. 2017.

 저 자 소 개


이상근(정회원)

2013년 연세대학교 전기전자공학과
학사 졸업

2019년 연세대학교 전기전자공학과
박사 졸업

2019년-2025년 삼성전자 MX사업부
책임연구원

2025년-현재 국립창원대학교 조교수

<주관심분야 : 무선통신, 다중안테나시스템, 인공지능>