

碩士學位論文

WAVE 통신 시스템에서 PER 성능 향상을
위한 AE-LSTM-MLP 채널 추정 기법

AE-LSTM-MLP Channel Estimation Techniques for PER
Performance Enhancement in WAVE Communication Systems

韓國交通大學校 大學院

交通에너지融合學科 無線通信專攻

張 善 美

2023年 12月

WAVE 통신 시스템에서 PER 성능 향상을 위한 AE-LSTM-MLP 채널 추정 기법

張善美

碩士學位論文

WAVE 통신 시스템에서 PER 성능 향상을
위한 AE-LSTM-MLP 채널 추정 기법

AE-LSTM-MLP Channel Estimation Techniques for PER
Performance Enhancement in WAVE Communication Systems

指導教授 임 성 목

2023年 12月

韓國交通大學校 大學院

交通에너지融合學科

張 善 美

WAVE 통신 시스템에서 PER 성능 향상을
위한 AE-LSTM-MLP 채널 추정 기법

AE-LSTM-MLP Channel Estimation Techniques for PER
Performance Enhancement in WAVE Communication Systems

指導教授 임 성 목

이 論文을 工學 碩士學位論文으로 提出함

2023년 12월

韓國交通大學校 大學院

交通에너지融合學科

張 善 美

張善美의 工學 碩士學位論文을 認准함

2023년 12月

審査委員長 고 균 병 (印)

審査委員 임 성 목 (印)

審査委員 송 창 익 (印)

韓國交通大學校 大學院

요 약

제 목 : WAVE 통신 시스템에서 PER 성능 향상을 위한 AE-LSTM-MLP 채널 추정 기법

본 논문은 고속 이동 환경에서 빠르게 변화하는 채널을 정확하게 추정하여 차세대 V2X 통신을 지원하기 위해 AE 기반 LSTM-MLP 채널 추정 기법을 소개한다.

최근 도로 교통의 안전성과 이동성을 확보하여 정보를 제공하고 차량과 도로의 위험 요소를 감지하여 운전자에게 미리 알려주거나 차량을 제어함으로써 교통사고 발생을 최소화한다. 궁극적으로는 차량의 자율적인 도로의 운행이 가능하게 하는 지능형 교통체계(ITS: Intelligent Transport Systems)가 발달함에 따라 고속 이동 환경에서 빠르게 변화하는 채널을 추적하기에 어려움이 있어 안정적이고 신뢰성 있는 차량 간 통신 시스템(V2X: vehicle-to-everything)에서 고효율성과 정확성을 보장하는 채널 추정 기술이 연구되고 있다. 디매핑 된 Data Symbol을 채널 추정을 위한 가상 Pilot으로 사용하는 DPA(Data Pilot-Aided)을

기반으로 한 채널 추정 기법과 인공신경망 기반 DPA 채널 추정 기법이 제안되었다. 하지만 특정 채널 환경이나 변조 방식에서 성능 향상이 제한적이고, 주파수 영역 특성만 학습한다는 문제점이 있어 시간 영역 특성까지 학습하는 LSTM-MLP가 제안되었다. 그러나, LSTM의 units을 가변적으로 사용하기 때문에 Frame 내 앞부분에서 전송되는 OFDM Symbol의 채널 추정 시에는 LSTM units 수가 너무 작아 시간축 특성을 충분히 학습할 수 없다는 문제점이 있다. 뿐만 아니라, Frame 내 뒷부분에서 전송되는 OFDM Symbol의 채널 추정 시에는 너무 많은 LSTM units이 사용되기 때문에 성능 향상 대비 복잡도가 높아지고, 메모리 과사용의 문제점이 발생한다.

본 논문에서는 이전의 LSTM-MLP의 문제점을 해결하기 위해 초기에 AE (Autoencoder)를 활용하여 OFDM이 겪는 모든 채널을 먼저 추정한 채널 값을 활용하여 추정하고, 이를 기반으로 LSTM units의 입력 Data를 구성한다.

목 차

요 약	i
표 목 차	v
그림목차	vi
I. 서 론	1
II. WAVE 시스템 모델	9
III. DPA 기반 채널 모델	13
3.1 STA	
3.2 TRFI	
3.3 E-TRFI	
IV. 인공 신경망 기반 DPA 채널 모델	27
4.1 AE	
4.2 STA-DNN	
4.3 E-TRFI-DNN	
4.4 LSTM-MLP	

V. 제안 기법: LSTM-MLP	41
5.1 AE 훈련	
5.2 LSTM-MLP 훈련	
5.3 초기 채널 추정 기법	
5.4 LSTM-MLP 기반 학습 과정 및 최종 채널 추정값	
VI. 모의 실험	49
6.1 제안하는 채널 추정 기법 성능 및 분석	
VI. 결론	67
참고문헌	69
Abstract	72

표 목 차

<표 2-1> WAVE 시스템 파라미터	10
<표 4-1> AE 훈련 파라미터	28
<표 4-2> LSTM-MLP 훈련 파라미터 ...	38
<표 5-1> 제안하는 채널 추정 기법의 AE 훈련 파라미터	42
<표 5-2> 제안하는 채널 추정 기법의 LSTM-MLP 계층 파라미터	48
<표 6-1> 실험 환경 파라미터	49

그림 목 차

<그림 2-1> WAVE 시스템에서 프레임 구조	9
<그림 2-2> OFDM 시스템에서 송신기 및 수 신기	11
<그림 2-3> OFDM 프레임 구조의 시각화	12
<그림 3-1> STA 채널 추정 기법	13
<그림 3-2> STA 채널 추정 기법의 시각화 ...	17
<그림 3-3> TRFI 채널 추정 기법	18
<그림 3-4> TRFI 신뢰도 테스트 과정 ...	22
<그림 3-5> E-TRFI 채널 추정 기법	22
<그림 4-1> AE 채널 추정 기법	27
<그림 4-2> STA-DNN 채널 추정 기법 ...	31
<그림 4-3> E-TRFI-DNN 채널 추정 기법 ...	33
<그림 4-4> LSTM-MLP 채널 추정 기법 ...	35
<그림 4-5> LSTM-MLP 계층	38
<그림 5-1> 제안하는 채널 추정 기법 과정 ...	41
<그림 5-2> 학습 Data 전처리 과정 및 LSTM units	43
<그림 5-3> 제안하는 채널 추정 기법의 LSTM-MLP 계층	44
<그림 5-4> 제안하는 채널 추정 기법의 채널 예측 시 각화	48

<그림 6-1> Rural, QPSK, 1/2 PER	51
<그림 6-2> Rural, QPSK, 1/2 BER	51
<그림 6-3> Rural, 16QAM, 1/2 PER	...	52
<그림 6-4> Rural, 16QAM, 1/2 BER	...	52
<그림 6-5> Urban, QPSK, 1/2 PER	54
<그림 6-6> Urban, QPSK, 1/2 BER	54
<그림 6-7> Urban, 16QAM, 1/2 PER	...	55
<그림 6-8> Urban, 16QAM, 1/2 BER	...	55
<그림 6-9> Crossing, QPSK, 1/2 PER	...	57
<그림 6-10> Crossing, QPSK, 1/2 BER	...	57
<그림 6-11> Crossing, 16QAM, 1/2 PER	...	59
<그림 6-12> Crossing, 16QAM, 1/2 BER	...	59
<그림 6-13> Highway LOS, QPSK, 1/2 PER	...	61
<그림 6-14> Highway LOS, QPSK, 1/2 BER	...	61
<그림 6-15> Highway LOS, 16QAM, 1/2 PER	...	62
<그림 6-16> Highway LOS, 16QAM, 1/2 BER	...	62
<그림 6-17> Highway NLOS, QPSK, 1/2 PER	...	64
<그림 6-18> Highway NLOS, QPSK, 1/2 BER	...	64
<그림 6-19> Highway NLOS, 16QAM, 1/2 PER	...	65
<그림 6-20> Highway NLOS, 16QAM, 1/2 BER	...	65

I. 서론

최근 운전자의 안전성과 편의성 제고를 위해 다양한 교통 서비스를 제공함으로써 교통사고 발생을 최소화할 수 있는 지능형 교통 시스템 (ITS: Intelligent Transport Systems)에 관한 연구가 활발히 진행되고 있다[1]. 특히 고도화된 지능형 교통 시스템에서는 차량 간 혹은 차량과 인프라 간 다양한 교통 정보 및 인포테인먼트 정보를 안정적으로 송수신함으로써 운전자에게 최상의 교통 서비스를 제공할 수 있어야 한다. IEEE 802.11p 기반의 차량 환경을 위한 무선 액세스 (WAVE: Wireless Access for Vehicle Environment) 통신 시스템이 대표적인 차량 간 통신 시스템 (V2X: Vehicle-to-Everything)으로 주목받고 있다[2][3].

WAVE 통신 시스템의 표준인 IEEE 802.11p는 무선랜 표준인 IEEE 802.11a를 기반으로 제정되었는데, 표준에 따르면 채널 추정을 위한 Pilot 정보가 프레임 내 프리앰블에만 포함되어 있다. 따라서, 이 Pilot 정보를 이용하여 추정된 채널 값을 프레임 내 전송된 모든 Data Symbol을 복원하는 데 사용해야 하는 구조적인 한계로 인해 고속 이동환경에서 빠르게 변화하는 채널을 추정하는 데 정확도가 떨어진다는 문제점이 발생한다[4]. 따라서, V2X 통신 시스템에서 사용자에게 제공되는 교통안전 서비스를 안정적이고, 빠르게 송수신하기 위해서 고효율성과 정확성을 보장하는 고정밀 채널 추정 기법이 요구되고 있다[5].

이러한 표준에서 제정된 프레임 구조의 자체적인 문제를 해결하고, 채널 추정 정확도를 향상시키기 위해서 디맵핑된 Data Symbol을 Data Pilot으로 활용하여 현재 채널 값을 업데이트하는 DPA (Data Pilot-Aided) 기반 채널 추정 기법들이 개발되었으며, 대표적으로 STA (Spectrum Temporal Averaging)[6], CDP (Constructed Data Pilot)[7], TRFI (Time domain Reliability test Frequency domain Interpolation)[8], E-TRFI (Enhanced-Time domain Reliability test Frequency domain Interpolation)[9] 기법이 있다.

STA 기법은 DPA 기반으로 채널 값을 추정한 후 시간 영역 및 주파수 영역에서 추정된 채널의 평균화 과정을 수행한다. 이러한 평균화 과정은 채널 추정 과정에서 발생하는 잡음의 효과를 완화 시킴으로써 채널 추정 성능을 향상시킬 수 있다. 그러나, 근본적으로 채널의 시간 영역 및 주파수 영역에 따른 변화로 인해 발생하는 채널 추정 오차를 완화 시키지 못하기 때문에 채널 변화가 극심한 환경에서는 높은 SNR (Signal-to-Noise Ratio) 영역에서도 error floor 현상이 발생한다. 이를 개선하기 위해 CDP 기법이 제안되었다. CDP 기법에서는 프레임 내 인접한 두 Symbol 간 채널은 거의 유사하다는 가정 하에 DPA 기반으로 채널을 추정한 후 이전 Symbol을 등화 함으로써 추정된 채널 값의 신뢰도를 테스트한다.

만약 신뢰성 테스트를 통과하지 못할 경우, 이전 채널 값을 그대로 사용하는데, 이로 인해 STA 기법 대비 높은 SNR 영역에서 채널 추정 성능을 향상 시킬 수 있다. 그러나, 차량의 이동 속도가 빨라질수록 채널 간 correlation이 낮아질 수 있는데 이 경우 채널 추정 에러가 지속해서 발생하는 error propagation 문제가 발생하여 성능을 열화시키는 요인이 된다. 이를 극복하기 위해 TRFI 기법이 제안되었다. TRFI 기법의 알고리즘은 기본적으로 CDP와 동일한 방식으로 채널 추정 후 신뢰도 테스트까지 수행한다. 이후 신뢰도 테스트를 통과하지 못한 채널 값은 동일 Symbol 내에서 interpolation 기법을 통해 채널 값을 업데이트하며, 이로 인해 CDP 대비 채널 추정 정확도를 더욱 향상 시킬 수 있다. 그러나, 변조 지수 및 차량의 이동 속도가 높아질수록 전반적인 채널 추정 정확도가 떨어지고, PER (Packet Error Rate) 성능이 열화되는 문제점을 보인다.

한편, CDP 및 TRFI는 경판정 (Hard Decision) 기반의 신뢰도 테스트로 인해 채널 추정 오차가 커지는 문제점을 가지고 있는데, 이를 해결하기 위해 E-TRFI 기법이 제안되었다. E-TRFI는 채널 추정 오차를 최소화하기 위하여 가상 부반송파의 채널까지 추정하여 interpolation을 수행한다. 뿐만 아니라, 수신 신호와 송신 신호의 성상도 간 Euclidean 거리를 기반으로 신뢰도 테스트를 진행함으

로써 경관정 기반의 신뢰도 테스트 기법이 가지는 채널 추정 오차를 완화 시킬 수 있다. 결과적으로 기존 DPA 기반 채널 추정 기법 대비 가장 좋은 PER 성능을 보여 준다. 그러나, 변조 지수가 높아질수록, 채널 변화가 극심할수록 채널 추정 성능이 열화되는 근본적인 문제점을 해결하지 못하였다.

특정 채널 환경이나 변조 방식에서 채널 추정 정확도가 떨어지는 문제점을 해결하기 위해 기존 DPA 기반 채널 추정 기법에 심층신경망 (DNN:Deep Neural Network)을 결합한 AE (Autoencoder)[10], STA - DNN (Spectrum Temporal Averaging - Deep Neural Network)[11], E-TRFI - DNN (Enhanced - Time domain Reliability test Frequency domain Interpolation - Deep Neural Network)[12]이 제안되었다. DNN 기반의 채널 추정 기법은 공통적으로 학습 단계와 채널 추정 단계로 나눌 수 있다. 학습 단계에서는 채널의 1차 추정된 값을 DNN 기반 심층신경망의 입력값으로 사용하고, 이에 대한 출력값을 실제 채널 값과 비교하여 MSE (Mean Square Error)를 최소화하는 방향으로 각 hidden layer의 weight matrix와 bias vector를 최적화한다. 이후 채널 추정 단계에서는 최적화된 weight matrix와 bias vector를 기반으로 인공 신경망을 구축한 이후 채널 추정을 수행한다.

AE 기반 채널 추정 기법은 LS (Least Square) 기반으로 초기 채널을 추정한 후에 이를 AE의 입력값으로 사용하여 채널 특성을 학습시킨 후 이를 기반으로 구성된 인공신경망을 사용하여 채널을 추정한다. 학습 단계에서 채널의 주파수 영역 특성을 학습하기 때문에 별도의 DPA 기반 채널 추정 과정 없이도 전통적인 채널 추정 기법 대비 PER 성능을 비약적으로 향상시킬 수 있다.

AE 기반 채널 추정 기법보다 더 좋은 성능을 구현하기 위해 STA-DNN 및 E-TRFI-DNN 기법이 제안되었다. AE 기반 채널 추정 기법에서는 LS 기반의 채널 추정 기법을 통해 심층신경망의 입력값을 생성하는 반면, STA-DNN 및 E-TRFI-DNN에서는 DPA 기반 채널 추정 기법 중 하나인 STA 기법과 E-TRFI 기법을 사용하여 추정된 채널값을 심층 신경망의 입력값으로 사용한다. 실제 시스템의 채널 추정 과정을 통해 DNN의 입력값을 생성하기 때문에 채널 추정 오차까지 고려하여 채널의 주파수축 특성을 학습할 수 있다는 장점을 가지고 있으며 이로 인해 AE 기반 채널 추정 기법 대비 더 좋은 PER 성능을 나타낸다. 그러나, DNN 기반 채널 추정 기법들은 모두 채널의 주파수 영역 특성만을 학습하기 때문에 차량의 고속 이동에 따른 채널의 시변 특성을 반영하지 못한다는 단점을 가지고 있다.

채널의 주파수 영역 특성 뿐만 아니라 시간 영역 특성까지 학습함으로써 채널 추정 정확도를 더욱 향상시키기 위해 순환신경망 (RNN:Recurrent Neural Network) 중 하나인 장단기 메모리 (LSTM:Long short-term memory) 와 다층 퍼셉트론 (MLP:Multi-Layer Perceptron)를 결합한 LSTM-MLP[13] 기법이 제안되었다. 제안 기법은 LSTM을 통해 채널의 시간 영역 특성을 학습한 후 MLP 과정을 통해 채널의 주파수 영역 특성까지 학습하며, 이로 인해 DNN 기반 채널 추정 기법 대비 PER 성능을 좀 더 향상시킬 수 있다. 그러나, 전송되는 Frame 내 직교 주파수 분할 (OFDM:Orthogonal Frequency Division Multiplexing) Symbol의 순서에 따라 LSTM의 units을 가변적으로 사용하기 때문에 Frame 내 앞부분에서 전송되는 OFDM Symbol의 채널 추정 시에는 LSTM units 수가 너무 작아 시간 영역 특성을 충분히 학습할 수 없다는 문제점이 있다. 뿐만 아니라, Frame 내 뒷부분에서 전송되는 OFDM Symbol의 채널 추정 시에는 너무 많은 LSTM units이 사용되기 때문에 성능 향상 대비 복잡도가 높아지고, 메모리 과사용의 문제점이 발생한다.

본 논문에서는 LSTM-MLP 기법의 문제점을 보완하고, 채널 추정 성능을 더욱 향상시킬 수 있는 AE-LSTM-MLP 기법을 제안한다. 제안 기법은 AE를 활용하여 Frame 내 OFDM이 겪는 모든 채널을 먼저 추

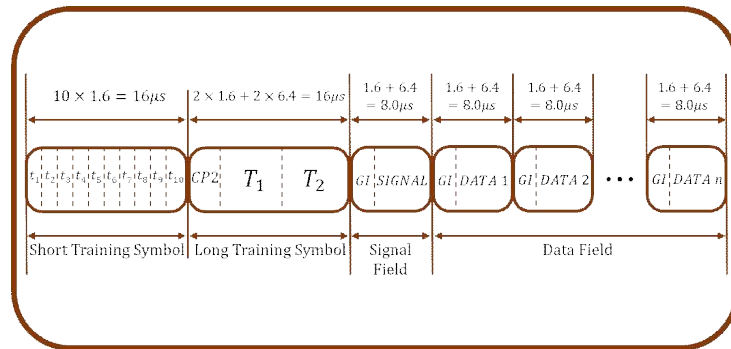
정하여 LSTM-MLP에 인가한다. 이후, Frame 내 OFDM Symbol의 위치와 상관없이 고정된 LSTM units 수를 사용하여 채널의 시간축 특성을 학습하고, 이후 MLP를 통해 채널의 주파수축 특성까지 학습한다. LSTM units의 수를 충분히 크게 설정함으로써 Frame 내 OFDM Symbol의 위치에 상관없이 채널의 시간축 특성을 완벽하게 학습할 수 있고, 이를 통해 채널 추정 정확도를 향상시킬 수 있다. 그러나, LSTM units의 수가 커질수록 시계열 상 초기 시점의 채널 추정을 위한 입력 Data 구성이 어렵다는 문제점이 발생한다. 이를 해결하기 위하여 초기에 AE를 활용하여 OFDM이 겪는 모든 채널을 먼저 추정한 채널 값을 활용하여 추정하고, 이를 기반으로 LSTM units의 입력 Data를 구성한다.

제안 기법 또한 기존 딥러닝 기반 채널 추정 기법과 동일하게 학습 단계와 채널 추정 단계로 나눌 수 있다. 학습 단계에서는 M개의 time step을 가지는 LSTM과 MLP로 인공신경망을 구성한다. 한 Frame을 구성하는 OFDM Symbol 수를 N이라 할 때, AE로 추정한 Frame 내 모든 OFDM에서 M개의 채널값을 입력 Data set으로 구성하여 LSTM units에 인가한다. LSTM units output을 MLP의 입력값으로 재인가한 후 출력값을 (M+1)번째 실제 채널과 비교하여 MSE를 최소화하도록 학습을 시킨다. 이후 LSTM의 입력 Data set을 AE로 추정된 2번째-(M+1)번

제 실제 채널과 비교하여 MSE를 최소화하도록 학습을 시킨다. 이후 LSTM의 입력 Data set을 AE로 추정된 2번째-(M+1)번째 채널값을 LSTM units에 인가하고, 이후 절차를 동일하게 처리한다. 위 과정을 반복함으로써 채널의 시간 영역 및 주파수 영역의 특성을 학습하게 되고, 이를 통해 LSTM 및 MLP의 각 파라미터를 최적화할 수 있다. 채널 추정 단계에서는 최적화된 파라미터를 기반으로 한 Frame에서 (N-1)개의 OFDM Symbol에서 AE로 추정한 채널을 AE-LSTM-MLP 인공신경망에 인가하면, 모든 채널을 추정할 수 있게 된다.

제안하는 AE-LSTM-MLP 기법은 LSTM units의 수를 고정적으로 사용함으로써 채널의 시간 영역 특성을 안정적으로 학습할 수 있다. 뿐만 아니라, AE를 사용하여 실제 채널과 유사한 Data set을 LSTM units의 입력으로 인가함으로써 실제 채널과 오차가 최소화된 시계열 채널값의 시간 영역 특성을 학습하기 때문에 인공신경망의 성능을 더욱 향상시킬 수 있다. 제안기법의 성능을 검증하기 위해 다양한 채널 환경에서 모의 실험을 진행하였으며, 전반적으로 기존 기법 대비 성능이 향상되는 것을 관찰하였다. 특히, Highway NLOS 채널 환경에서 16QAM 변조 방식을 사용하였을 경우 제안 기법의 PER 성능은 기존 기법 대비 대략 2dB 정도의 성능 향상을 나타낸다.

II. WAVE 시스템 모델



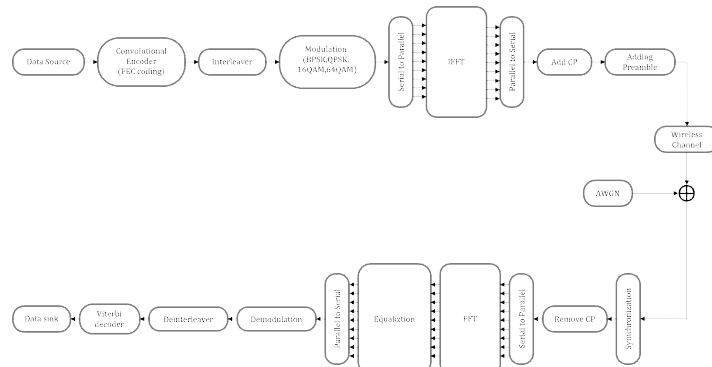
<그림 2-1> WAVE 시스템에서 프레임 구조

IEEE 802.11p는 차량 간 통신 시스템 (V2X:Vehicle-to-Everything)을 위해 사용되는 표준이다. <그림 2-1>은 WAVE 시스템에서 프레임 구조를 나타내는데, 프리앰블 (Preamble), Signal Field 및 Data Field로 구성된다. 이 중 Preamble은 다시, Short Training Symbol과 Long Training Symbol로 나뉜다. Short Training Symbol은 16μs 길이의 시퀀스 10개로 구성되며, 전체 Frame의 시간 동기를 추정할 때 사용되고, Long Training Symbol은 Short Training Symbol과 같은 16μs 길이로 구성되어 있으며, 초기 채널 추정에 사용된다. Signal Field는 BPSK, QPSK, 16QAM, 64QAM 등 변조지수와 코드율, 등 프레임 구조에 관한 정보를 가지고 있다. Data Field는 Signal Field와 같이 총 8.0μs 길이로 구성되며, V2X

<표 2-1> WAVE 시스템 파라미터

Parameter	Values
FFT size	64
FFT period	6.4 μ s
Symbol duration	8.0 μ s
GI duration	1.6 μ s
Total subcarriers	52
Pilot subcarriers	4
Data subcarriers	48
Code rate	1/2,2/3,3/4
Modulation Schemes	BPSK,QPSK, 16QAM,64QAM
Bit Rate	3,4,5,6,9,12,18,24,27
Frequency spacing of subcarriers	156KHz
Error correction coding	K=7 convolution code
CBandwidth	10MHz

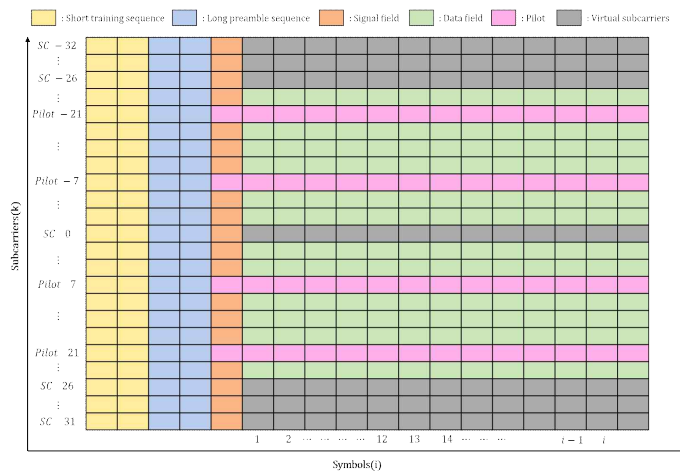
통신 시스템을 통해 전송하고자 하는 교환되는 실제 정보를 포함한다. Data Field를 구성하는 각 OFDM Symbol은 48개의 Data 부반송파, 4개의 Pilot 부반송파, 1개의 DC, 11개의 Virtual 부반송파를 가지고 있다. 4개의 Pilot 부반송파는 -21번째, -7번째, 7번째, 21번째 부반송파를 통해 전송되며, 위상 동기 오차 및 채널 추정에 사용된다. 표준에 따르면 Data Field를 구성하는 직교 주파수 분할 (OFDM:Orthogonal Frequency Division Multiplexing) Symbol 수는 가변적으로 설정이 가능하며, 일반적으로



<그림 2-2> OFDM 시스템에서 송신기 및 수신기

50개 혹은 100개의 OFDM Symbol로 한 프레임을 구성한다. 본 논문에서는 Data Field는 100개의 OFDM Symbol로 구성된다고 가정한다. 또한 <표 2-1>은 IEEE802.11p에서 정의된 각 파라미터의 값을 나타낸다.

<그림 2-2>는 OFDM 시스템의 송신기 및 수신기를 나타낸다. 송신기에서는 순방향 에러 정정을 위한 컨볼루션 인코더를 기반으로 Data 소스를 채널 코딩한 후 burst error 감소를 위해 인터리버 (interleaver)를 통해 Data를 재배열한다. 이후 변조 방식에 따라 신호를 변조하고, 역고속 푸리에 변환 (IFFT:Inverse Fast Fourier Transform)을 적용 후 보호 구간 (GI:Guard Interval)을 삽입하여 프레임 단위로 신호를 전송한다. 수신기에서는 Short Training Symbol로 프레임의 채널 초기 시간 동기 추정 및 Long Training




<그림 2-3> OFDM 프레임 구조의 시각화

Symbol을 사용하여 초기 채널 추정을 수행한다. 이를 기반으로 수신 Data Symbol의 GI 제거 및 푸리에 변환(FFT:Fast Fourier Transform)을 통해 변환된 주파수 영역 신호를 등화, 복조 및 디코딩하여 Data 비트를 복원한다

<그림 2-3>은 한 개의 OFDM에서 Data field의 -31 번째부터 -26번째, 0번째, 26번째부터 31번째는 Virtual 부분송파, -21번째, -7번째, 7번째, 21번째는 Pilot 부분송파, 나머지는 Data를 가지고 있는 것을 WAVE 시스템에서 시간 영역과 주파수 영역으로 나타낸 것이다.

Ⅲ. DPA 기반 채널 모델

WAVE (Wireless Access for Vehicle Environment) 시스템에서 Pilot의 채널 변화 추적의 어려움을 해결하기 위해 디매핑된 Data Symbol을 채널 추정을 위한 Virtual Pilot으로 사용하는 DPA (Data Pilot-Aided) 채널 추정을 기반으로 한 알고리즘 중 STA (Spectrum Temporal Averaging), TRFI (Time domain Reliability test Frequency domain Interpolation), E-TRFI (Enhanced-Time domain Reliability test Frequency domain Interpolation)를 소개한다.



<그림 3-1> STA 채널 추정 기법

3.1 STA

STA는 고속 주행 환경에서 시변 채널 특성을 반영한 채널 추정 기법으로서 특정 i 번째 Data Symbol의 추정값을 이용하여 지속해서 채널 추정값을 업데이트하는 Data 기반 추정 기법이다. <그림 3-1>은 STA의 채널 추정 및 업데이트 과정이다.

3.1.1 LS(Least Square) 채널 추정 기법

먼저 IEEE 802.11p 프레임 구조의 Long Training Symbol 부분에 전송되는 Symbol에 송수신단이 모두 알

고 있는 Pilot Symbol 이다. 시간 영역에서 같은 Pilot sequence가 두 번 반복되는 구조이므로 이를 이용하여 다음과 같은 과정을 수행한다. Long Training Symbol의 GI를 제거 후에 시간 영역 신호를 각각 T_1, T_2 라고 한다. 이를 FFT 변환하여 나온 주파수 영역 신호는 각각 Y_1, Y_2 이고, k번째 부반송파가 겪은 채널은 동일하다는 가정하에 k번째 부반송파에서 LS 채널 추정값은 다음과 같다.

$$H_{t-1}(k) = \left(\frac{Y_1(k)}{X(k)} + \frac{Y_2(k)}{X(k)} \right) \times \frac{1}{2} = \frac{Y_1(k) + Y_2(k)}{2X(k)} \quad (3.1)$$

이 때 $Y_1(k), Y_2(k)$ 는 k번째 부반송파에서 수신한 long preamble 신호이고, $X(k)$ 는 k번째 부반송파에서 전송된 Pilot Symbol이다. $X(k)$ 가 두 번 반복되는 특성을 이용하여 각 LS 기법으로 채널 추정 후 평균을 취한다. 추정된 채널 값 $H_{t-1}(k)$ 으로 Data Field에서 전송되는 모든 OFDM Symbol의 k번째 부반송파 정보를 등화하고 이는 다음과 같다.

$$\hat{T}_t(k) = \frac{Y_t(k)}{H_{t-1}(k)}, t = 1, 2, \dots, I \quad (3.2)$$

여기서 $Y_t(k)$ 는 주파수 영역에서 k번째 부반송파의 수신 신호이고, $\hat{T}_t(k)$ 는 k번째 부반송파에서 추정된 채널값

으로 등화 과정을 수행한 k번째 부반송파에서의 Symbol이다. 또한, i는 한 프레임에 포함되는 OFDM Symbol 개수이다.

3.1.2 변조 Symbol 추정

LS 채널 추정 기법으로 k번째 부반송파의 추정 채널값으로 등화 과정을 수행한 k번째 부반송파에서의 Symbol $\hat{T}_t(k)$ 를 다음과 같이 디매핑하여 변조 Symbol $\hat{X}_t(k)$ 를 추정할 수 있다.

$$\hat{T}_t(k) = \frac{Y_t(k)}{H_{t-1}(k)} \xrightarrow{\text{Demapping}} \hat{X}_t(k) \quad (3.3)$$

3.1.3 i번째 Symbol에 대한 채널 값 업데이트

i번째 추정된 변조 Symbol $\hat{X}_t(k)$ 과 i번째 수신된 신호 $Y_t(k)$ 를 사용하여 i번째 Symbol에 대한 채널 값 $\hat{H}_t(k)$ 를 다음과 같이 업데이트한다.

$$\hat{H}_t(k) = \frac{Y_t(k)}{\hat{X}_t(k)} \quad (3.4)$$

채널 추정값을 업데이트함으로써 시변 채널 환경에서 채널 추정 오차를 줄일 수 있다. 하지만 변조 Symbol $\hat{X}_t(k)$ 를 추정하는 과정에서 채널 추정 오차와 잡음에 의

한 디매핑 오차(Demapping Error)가 발생하여 채널 추정 오차가 발생한다. 따라서 디매핑 오차에 의한 채널 추정 오차를 완화하기 위해 다음과 같은 평균화 과정을 추가한다.

3.1.4 주파수 영역과 시간 영역에서 평균화 과정


주파수 영역에서 인접한 부반송파의 채널 추정값과 평균을 취하고 이는 다음과 같다.

$$\tilde{H}_t(k) = \sum_{\lambda=-\beta}^{\beta} \omega_{\lambda} \hat{H}_t(k+\lambda) \quad (3.5)$$

여기서 β 는 k번째 부반송파를 중심으로 인접 부반송파의 개수를 의미하고, ω_{λ} 는 단위 합이 가중치 계수를 의미한다. 일반적으로는 $\beta = 2$, $\omega_{\lambda} = \frac{1}{5}$ 값으로 고려하고, 5개의 채널 추정값에 대한 평균과 각 채널 추정값에 동일한 가중치를 부여하는 것을 의미한다. 또한, LS 기법으로 추정된 채널 값 $H_{t-1}(k)$ 와 주파수 영역에서 평균화 과정을 한 채널 값 $\tilde{H}_t(k)$ 를 사용하여 시간 영역에서 다음과 같이 평균을 취한다.

$$\hat{H}_t(k) = \left(1 - \frac{1}{\alpha}\right) H_{t-1}(k) + \frac{1}{\alpha} \tilde{H}_t(k) \quad (3.6)$$


여기서 α 는 시간 영역의 평균 매개변수를 의미하고, 일반적으로 $\alpha = 2$ 값으로 고려한다.



<그림 3-2> STA 채널 추정 기법의 시각화

각 영역에서 채널 추정값의 평균화 과정을 통해 채널 추정의 오차를 감소시킨다. 또한, 모든 OFDM Data Symbol을 복원할 때 적용하여 반복 수행함으로써 채널 추정값을 업데이트한다.

<그림 3-2>는 (3.1.1)-(3.1.4)의 과정을 간략하게 표현한 것이다. STA는 주파수 영역과 시간 영역에서 평균화하는 과정을 겪어서 낮은 SNR 영역에서 채널 추정의 성능이 우수하다. 하지만 고속 이동환경에서 채널의 시간 영역에서 특성이 빠르게 변하는 경우와 잡음에 의한 채널 추정 오차가 발생하고, 평균화 과정을 겪더라도 채널 추정 오차를 줄이기 어렵다.



<그림 3-3> TRFI 채널 추정 기법

3.2 TRFI

TRFI 채널 추정 기법은 CDP 채널 추정 기법과 신뢰도 테스트가 기반이다. 신뢰도가 없다고 판단되는 경우 신뢰도가 있는 부반송파의 채널로 interpolation을 사용하여 특정 부반송파에서 비워진 채널을 추정하는 기법이다. <그림 3-3>은 TRFI의 채널 추정 및 interpolation 과정이고, 다음과 같다.

3.2.1 LS(Least Square) 채널 추정 기법

먼저 IEEE 802.11p 프레임 구조의 Long Training Symbol 부분에 전송되는 Symbol에 송수신단이 모두 알고 있는 Pilot Symbol 이다. 시간 영역에서 같은 Pilot sequence가 두 번 반복되는 구조이므로 이를 이용하여 다음과 같은 과정을 수행한다.

Long Training Symbol의 GI를 제거 후에 시간 영역 신

호를 각각 T_1, T_2 라고 한다. 이를 FFT 변환하여 나온 주파수 영역 신호는 각각 Y_1, Y_2 이고, k번째 부반송파가 겪은 채널은 동일하다는 가정하에 k번째 부반송파에서 LS 채널 추정값은 식(3.1)과 같다. 이후 등화 과정은 식(3.2)과 같다.

3.2.2 변조 Symbol 추정

LS 채널 추정 기법으로 k번째 부반송파의 추정 채널값으로 등화된 k번째 부반송파의 Symbol $\hat{T}_i(k)$ 를 디매핑하여 변조 Symbol $\hat{X}_i(k)$ 를 추정하는 과정은 식(3.3)과 같다.

3.2.3 i번째 Symbol에 대한 채널 값 업데이트

i번째 추정된 변조Symbol $\hat{X}_i(k)$ 과 i번째 수신된 신호 $Y_i(k)$ 를 사용하여 i번째 Symbol에 대한 채널 값 $\hat{H}_i(k)$ 를 업데이트하는 과정은 식(3.4)과 같다. 채널 추정값을 업데이트함으로써 시변 채널 환경에서 채널 추정 오차를 줄일 수 있다. 하지만 변조 Symbol $\hat{X}_i(k)$ 를 추정하는 과정에서 채널 추정 오차와 잡음에 의한 디매핑 오차(Demapping Error)가 발생하여 채널 추정 오차가 발생한다.

3.2.4 신뢰도 테스트

인접한 채널 간 correlation이 높고 수신 단에서 알고 있는 4개의 pilot에 대한 채널 추정값은 별도의 신뢰도 테스트 없이 정확하다는 가정하에 신뢰도 테스트를 진행한다. 이전에 수신된 신호 $Y_{t-1}(k)$ 를 i번째 OFDM Symbol에 대한 업데이트된 채널 값 $\hat{H}_t(k)$ 로 나눠 등화하는 과정을 거쳐 i-1 번째 OFDM 전송 Symbol을 다음과 같이 디매핑한다.

$$\hat{T}_{t-1}(k) = \frac{Y_{t-1}(k)}{\hat{H}_t(k)} \xrightarrow{\text{Demapping}} \hat{X}'_{t-1}(k) \quad (3.7)$$

또한, t-1 번째 OFDM Symbol에서 업데이트된 채널 추정값 $\hat{H}_{t-1}(k)$ 를 사용하여 이전에 수신된 신호 $Y_{t-1}(k)$ 를 등화하고 t-1 번째 OFDM 전송 Symbol을 다음과 같이 디매핑한다.


$$\hat{T}'_{t-1}(k) = \frac{Y_{t-1}(k)}{\hat{H}_{t-1}(k)} \xrightarrow{\text{Demapping}} \hat{X}''_{t-1}(k) \quad (3.8)$$

이전에 수신된 신호를 $\hat{H}_t(k)$ 와 $\hat{H}_{t-1}(k)$ 로 등화와 디매핑 과정을 통해 $\hat{X}'_{t-1}(k)$ 와 $\hat{X}''_{t-1}(k)$ 를 비교한다. 두 인접한 채널 간 correlation이 높다고 가정했으므로


$\widehat{X}'_{t-1}(k)$ 와 $\widehat{X}''_{t-1}(k)$ 가 같은 경우 $\widehat{H}_t(k)$ 를 t번째 Symbol의 k번째 부반송파의 채널 추정값으로 업데이트한다. 또한 신뢰성이 없다고 판단된 채널 추정값은 제거하고, 대신 인접한 신뢰성 높은 채널 추정값들을 이용하여 주파수 영역에서 interpolation 기법을 통해 채널 추정값을 업데이트한다. 결과적으로 식(3.9)과 같은 비교과정을 거친다.

$$H_t(k) = \begin{cases} \widehat{H}_t(k) & , \widehat{X}'_{t-1}(k) = \widehat{X}''_{t-1}(k) \\ interpolation, \widehat{X}'_{t-1}(k) \neq \widehat{X}''_{t-1}(k) & \end{cases} \quad (3.9)$$

일반적으로는 비선형적 interpolation 기법을 많이 사용하고, TRFI에서 사용된 신뢰도 테스트 과정은 <그림 3-4>와 같다. interpolation 기법을 사용함으로써 CDP의 문제점이었던 Error propagation이 발생하지 않아 CDP보다 성능이 향상된다. 그러나 변조 지수 및 차량의 이동 속도가 높아질수록 전반적인 채널 추정 정확도가 떨어지고, PER 성능이 열화되는 문제점을 보인다.



<그림 3-4> TRFI 신뢰도 테스트 과정



<그림 3-5> E-TRFI 채널 추정 기법

3.3 E-TRFI

E-TRFI는 TRFI와 다르게 가상 부반송파의 채널까지 추정하여 interpolation을 수행함으로써 낮은 SNR 영역에서 성능 열화와 신뢰도 평가의 부정확성을 개선하기 위해 제안되었다. E-TRFI는 수신 신호와 정상도 지점 사이의 Euclidean 거리를 기반으로 잘못된 Data Pilot의 발생률을 줄이기 위해 엄격하게 신뢰성을 판단하고, DFT(Discrete Fourier Transform) 기반 채널 추정 기법을 사용하여 잡음에 의한 영향을 최소화하는 E-TRFI가 제안되었다. <그림 3-5>는 E-TRFI의 채널 추정 및 업데이트 과정이고 다음과 같다.

3.3.1 DFT기반 채널 추정 기법과 TDLS 채널 추정 기법
먼저 IEEE 802.11p 프레임 구조의 Long Training Symbol 부분에 전송되는 Symbol에 송수신단 모두 알고 있는 Pilot Symbol 이다. 시간 영역에서 같은 Pilot sequence가 두 번 반복되는 구조이므로 이를 이용하여 다음과 같은 과정을 수행한다.

Long Training Symbol의 GI를 제거 후에 시간 영역 신호를 각각 T_1, T_2 라고 한다. 이를 FFT 변환하여 나온 주파수 영역 신호는 각각 Y_1, Y_2 이고, k번째 부반송파가 겪은 채널은 동일하다는 가정하에 k번째 부반송파에서

LS 채널 추정값은 식(3.1)과 같다. 이후 추정된 채널 값 $H_{i-1}(k)$ 로 64×64 를 $64 \times (CP-1)$ DFT기반 행렬 \mathbf{F}_{64} 로 변환한다. \mathbf{F}_{64} 에서 WAVE 시스템의 Virtual 부반송파에 해당하는 부분을 제외하고 주파수 영역에서 Data Symbol로 구성된 $52 \times (CP-1)$, \mathbf{F}_{52} 로 정의한다. \mathbf{F}_{64} 와 \mathbf{F}_{52} 를 사용하여 Long Training Symbol의 Virtual 부반송파의 채널을 포함한 주파수 영역에서 64-point로 추정된 full-size CFR 벡터 $\hat{\mathbf{h}}_{0,full}$ 는 다음과 같다.

$$\hat{\mathbf{h}}_{0,full} = \mathbf{F}_{64} (\mathbf{F}_{52}^H \mathbf{F}_{52})^{-1} \mathbf{F}_{52}^H \tilde{\mathbf{h}}_0 = \mathbf{Q}_0 \tilde{\mathbf{h}}_0 \quad (3.10)$$

3.3.2 Euclidean 거리 기반 신뢰도 테스트

$i-1$ 번째 OFDM Symbol에서 얻은 k 번째 부반송파의 CFR $\hat{H}_{t-1}(k)$ 로 수신 신호 $Y_t(k)$ 를 나눠 등화 과정을 거친다. pilot 부반송파를 제외한 48개의 부반송파 S_D 에서 등화 한 신호 $\hat{T}_t(k)$ 는 식(3.2)과 같다. 또한, pilot 부반송파를 제외한 48개의 부반송파 S_D 에서 $\hat{T}_t(k)$ 를 가까운 성상도에 매핑하여 Data Pilot을 구성하고, 매핑된 추정 신호는 식(3.3)과 같다. 이후 등화 과정을 수행한 신호와 수신된 신호 사이의 거리를 다음과 같이 측정하여 엄격한 신뢰성 테스트를 제안한다.

$$\hat{d}_k^{(m)} = |\hat{T}_t(k) - X_t^{(m)}(k)|^2, \text{ for } m = 1, 2, 3, \dots, M \quad (3.11)$$

여기서 M 은 변조 차수를 나타내고, $\{\hat{d}_k^{(1)}, \hat{d}_k^{(2)}, \dots, \hat{d}_k^{(M)}\}$ 은 일반성의 손실 없이 오름차순으로 배열된다고 가정한다. 이러한 가정을 함으로써 최소거리와 두 번째 최소거리 사이의 비율을 다음과 같다.

$$\Gamma_k = \frac{\hat{d}_k^{(1)}}{\hat{d}_k^{(2)}}, \text{ for } k \in S_D \quad (3.12)$$

여기서 Γ_k 는 0보다 크고 1과 같거나 작다고 정의하고, 식(3.3)에서 매핑된 추정 신호는 송신 신호 $X_t(k)$ 와 동일할 가능성이 높아지므로 신뢰성이 높아진다. 반면 Γ_k 가 1에 가까워질수록 Data Pilot을 신뢰할 수 없다고 판단한다. 또한, 신뢰성 테스트를 위한 임계값 C_{th} 를 정의한다. 최소 거리가 두 번째 최소거리보다 절반 정도 작으면 신뢰도 테스트를 통과하도록 C_{th} 를 0.5로 정의한다.

3.3.3 주파수 영역에서 interpolation 기법

신뢰성 테스트 단계가 완료되면 주파수 영역에서 interpolation 기법을 수행하여 Data Pilot이 신뢰성 테스트에서 통과하지 못한 CFR을 추정한다. 기존의 TRFI와 달리 정확

도를 향상시키기 위해 이전 OFDM Symbol에서 추정된 Virtual CFR을 사용한다. 신뢰도 테스트를 통과한 추정된 CFR, Pilot 부반송파에서 추정된 CFR, Virtual 부반송파의 추정된 CFR은 다음과 같다.


$$\hat{H}_t(k) = \begin{cases} \frac{Y_t(k)}{\widehat{X}_t(k)} & , \text{ for } k \in S_R \\ \frac{Y_t(k)}{X_t(k)} & , \text{ for } k \in S_P \\ \hat{H}_{t-1}(k) & , \text{ for } k \in S_V \\ \text{interpolation} & , \text{ for } \Gamma_k > \beta \end{cases} \quad (3.13)$$

E-TRFI는 앞서 언급한 기존 DPA 기반 채널 추정 기법 대비 가장 좋은 PER 성능을 보여준다. 그러나 변조 지수가 높아질수록, 채널 변화가 극심할수록 채널 추정 성능이 열화되는 근본적인 문제점을 해결하지 못했다.

이러한 문제점을 해결하기 위해 인공 신경망 기반 DPA 채널 추정 기법이 제안되었다.

IV. 인공신경망 기반 DPA 채널 모델

본 절에서는 DPA 기반 채널 추정 기법의 성능 한계를 극복하고, 채널 추정 정밀도를 더욱 향상시키기 위한 목적으로 제안된 기존 인공신경망 기반의 채널 추정 기법들을 소개한다.



<그림 4-1> AE 기반 채널 추정 기법

4.1 AE 기반 채널 추정 기법

기존 DPA기반 채널 추정 기법은 채널의 시간 영역 및 주파수 영역의 변화가 커질수록, 변조 지수가 높아질수록 채널 추정 정확도 및 PER 성능이 열화되는 문제점을 보인다. 이를 극복하기 위해 채널 추정 기법에 심층신경망을 결합한 AE 기반 채널 추정 기법이 제안되었다. AE 기반 채널 추정 기법은 DPA 채널 추정을 수행한 후, DPA 추정 오류를 보상하기 위해 설계된 AE에 입력으로 들어간다. 또한, 입력에 가깝게 출력을 재구성하도록 훈련된 신경 네트워크이며, <그림 4-1>은 AE 기반 채널 추정 기법이고 다음과 같다.

<표 4-1> AE 훈련 파라미터

Parameter	Values
Input size	104
Output size	104
Hidden layer	40-20-40
Activation function	ReLU
Epoch	400
Loss function	MSE
Optimizer	Adam

4.1.1 AE 훈련

AE 훈련 Data는 오프라인에서 컴퓨터 시뮬레이션으로 생성된 V2X 채널을 사용하여 생성한다. 시간 영역에서 CIR을 무작위로 생성한 후 FFT 연산을 통해 주파수 영역의 CFR로 변환한다. 일반적으로 기저대역 채널은 복소수 값으로 표현되어 입력 벡터 $\mathbf{x}^{(n)}$ 을 다음과 같이 구성한다. 또한 <표 4-1>의 파라미터로 설정하여 인공신경망의 입력과 출력이 같아지도록 훈련한다. AE가 훈련하는 과정은 다음과 같다.

$$\mathbf{x}^{(n)} = [\text{Re}([\mathbf{H}^{(n)}]), \text{Im}([\mathbf{H}^{(n)}])]^T \quad (4.1)$$

먼저 입력 벡터 $\mathbf{x}^{(n)}$ 이 은닉 계층에 입력으로 들어갈 때, t 번째 은닉 계층의 차원을 d_t 로 정의한다. 이때 은닉 계

층의 weight matrix $\mathbf{W}_t \in \mathbb{R}^{d_t \times d_{t-1}}$, bias vector $\mathbf{b}_t \in \mathbb{R}^{d_t \times 1}$ 로 정의된다. 이후 은닉 계층의 Hidden state 연산을 위해 활성화 함수는 $t \neq L$ 일 경우 ReLU 또는 $t = L$ 일 경우 Linear를 사용한다.

$$\begin{aligned} \mathbf{h}_t &= \Phi_t(\mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t) \\ &= \begin{cases} \max(\mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t, 0), & \text{for } t \neq L \\ \mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t, & \text{for } t = L \end{cases} \quad (4.2) \end{aligned}$$

인공신경망에서 Loss function을 가지고 입력과 출력 간의 예측값과 실제값 사이의 차이를 측정한다. Loss function을 최소화하기 위해 최적화 함수 중 하나인 Adam을 사용하여 weight matrix과 bias vector를 업데이트한다. Epoch마다 Adam을 사용하여 weight matrix과 bias vector를 업데이트하면서, 신경망은 Loss function을 최소화하는 방향으로 학습을 수행한다. 반복적인 과정을 통해 모델은 입력 Data로부터 올바른 출력을 예측하기 위한 최적의 파라미터를 조정한다.

4.1.2 초기 채널 추정

인공신경망의 훈련이 끝난 후에 식(3.1)-(3.4)의 과정을 수행하여 t번째 수신 신호의 초기 채널 값 $\hat{H}_t(k)$ 을 추정한다.

4.1.3 Data set

LS 채널 추정 기법으로 t번째 수신 신호의 초기 채널 추정 값 $\hat{H}_t(k)$ 를 실수부와 허수부로 분리하여 식(4.3)과 같이 구성한다. 여기서 k는 Data 부반송파와 Pilot 부반송파를 나타낸다.

$$\mathbf{x}_{set}^{(n)} = [Re([\tilde{H}_t(k)]), Im([\tilde{H}_t(k)])]^T \quad (4.3)$$

4.1.4 DNN 학습 과정 및 최종 채널 추정값

이후 4.1.1 훈련과정을 통해 얻은 weight matrix과 bias vector를 식(4.2)와 같은 연산을 통해 학습에 사용한다.

이후 \mathbf{y}_t^r 을 실수부와 허수부로 나눠 최종 채널을 추정한다. 이는 다음 식(4.8)과 같다.

$$\hat{H}_t(k) = [Re([\mathbf{y}_t^r(k)]), Im([\mathbf{y}_t^r(k)])]^T \quad (4.4)$$



<그림 4-2> STA-DNN 채널 추정 기법

4.2 STA-DNN

STA-DNN 기법은 STA에 DNN을 결합한 채널 추정 기법으로 인공지능망에 입력하는 Data의 잡음 영향을 줄이기 위해 제안된 기법이다. <그림 4-2>는 STA-DNN의 채널 추정 및 학습 과정이고 다음과 같다.

4.2.1 STA-DNN 훈련

STA-DNN 훈련Data는 SNR 영역이 30dB인 환경에서 DPA 채널 기반 모델의 STA 채널 추정 기법과 같이, 식 (3.1)-(3.6) 과정을 통해 채널을 추정한다. 이후 추정된 채널을 식(4.5)과 같이 실수부와 허수부로 나눠 행렬로 변환한다.

$$\mathbf{x}_t(k) = [Re\{\tilde{H}_t(k)\}, Im\{\tilde{H}_t(k)\}]^T \quad (4.5)$$

<표 4-1>의 파라미터와 같이 설정하여 인공지능망의 입력과 출력이 같아질 수 있도록 훈련한다. STA-DNN이 훈련하는 과정은 AE 훈련 방식과 같다.

4.2.2 초기 채널 추정

인공신경망의 훈련이 끝난 후에 식(3.1)-(3.6) 과정을 수행하여 t번째 수신 신호의 초기 채널 값 $\tilde{H}_t(k)$ 을 추정한다.

4.2.3 Data set

STA 채널 추정 기법으로 t번째 수신 신호의 초기 채널 추정 값 $\tilde{H}_t(k)$ 를 실수부와 허수부로 분리하여 식(4.3)과 같이 구성한다.

4.1.4 DNN 학습 과정 및 최종 채널 추정값

이후 4.1.1 훈련과정을 통해 얻은 weight matrix과 bias vector를 식(4.2)와 같은 연산을 통해 학습에 사용한다.

이후 \mathbf{y}_t^r 을 실수부와 허수부로 나눠 최종 채널을 추정한다. 이는 다음 식(4.6)과 같다.

$$\hat{H}_t(k) = [Re([\mathbf{y}_t^r(k)]), Im([\mathbf{y}_t^r(k)])]^T \quad (4.6)$$



<그림 4-3> E-TRFI-DNN 채널 추정 기법

4.3 E-TRFI-DNN

E-TRFI-DNN 기법은 E-TRFI에 DNN을 결합한 채널 추정 기법으로 인공지능망에 입력하는 Data의 잡음 영향을 줄이기 위해 제안된 기법이다.

<그림 4-3>은 E-TRFI-DNN의 채널 추정 및 학습 과정이고 다음과 같다.

4.3.1 E-TRFI-DNN 훈련

E-TRFI-DNN 훈련Data는 SNR 영역이 30dB인 환경에서 DPA 채널 기반 모델의 E-TRFI 채널 추정 기법과 같이, 식(3.10)-(3.13) 과정을 통해 채널을 추정한다. 이후 추정된 채널을 식(4.5)과 같이 실수부와 허수부로 나뉘어 행렬로 변환한다. 이후 <표 4-1>의 파라미터와 같이 설정하여 인공지능망의 입력과 출력이 같아질 수 있도록 훈련한다. E-TRFI-DNN이 훈련하는 과정은 AE 훈련 방식과 같다.

4.3.2 초기 채널 추정

인공신경망의 훈련이 끝난 후에 식(3.10)-(3.13) 과정을 수행하여 t번째 수신 신호의 초기 채널 값 $\widetilde{H}_t(k)$ 을 추정한다.

4.3.3 Data set

E-TRFI 채널 추정 기법으로 t번째 수신 신호의 초기 채널 추정 값 $\widetilde{H}_t(k)$ 를 실수부와 허수부로 분리하여 식(4.3)과 같이 구성한다.

4.3.4 DNN 학습 과정 및 최종 채널 추정값

이후 4.1.1 훈련과정을 통해 얻은 weight matrix과 bias vector를 식(4.2)와 같은 연산을 통해 학습에 사용한다.

이후 \mathbf{y}_t^r 을 실수부와 허수부로 나눠 최종 채널을 추정한다. 이는 다음 식(4.7)과 같다.

$$\widehat{H}_t(k) = [Re([\mathbf{y}_t^r(k)]), Im([\mathbf{y}_t^r(k)])]^T \quad (4.7)$$

AE와 기존 DPA에 DNN을 결합한 기법들은 기존 DPA 대비 성능이 향상된다. 하지만 높은 SNR 영역에서 STA-DNN과 E-TRFI-DNN의 성능이 열화 되고, 딥러닝 기반 채널 추정 기법은 채널의 주파수 영역에서 특성만 고려하여 시간 영역에서 특성을 고려하지 않는다는 문제점이 있다.



<그림 4-4> LSTM-MLP 채널 추정 기법

4.4 LSTM-MLP

LSTM-MLP는 이전의 기존 DPA에 DNN을 결합한 기법에서의 문제점을 해결하고자 LSTM 계층을 추가하여 주파수 영역 뿐만 아니라 시간 영역에서의 특성도 고려한다. <그림 4-4>는 LSTM-MLP의 채널 추정 및 학습 과정이고 다음과 같다.

4.4.1 LSTM-MLP 훈련

LSTM-MLP 훈련Data는 LS 채널 추정 기법과 같이 식 (3.1)-(3.4) 과정을 통해 채널을 추정한다. 이후 채널 추정값에서 k_1 이 Data 부반송파와 Pilot 부반송파일 경우 이전 채널 추정값을 사용한다. 또한, LS 채널 추정값에서 k_2 가 Pilot 부반송파일 경우 현재 채널 추정값을 사용한다. 구한 채널 추정값을 실수부와 허수부로 나누어 LSTM-MLP 계층의 학습 Data \mathbf{x}_t 를 구성한다. 이 과정은 식(4.16)과 같다.

$$\mathbf{x}_t = [Re([\hat{H}_{t-1}(k_1)]), Re([\hat{H}_t(k_2)]), Im([\hat{H}_{t-1}(k_1)]), Im([\hat{H}_t(k_2)])]^T \quad (4.8)$$

이후 LSTM-MLP 계층의 입력으로 들어간다.

LSTM은 순환 신경망 기법의 하나로, Cell state와 Forgetgate, Input gate, Output gate를 추가하여 기존 순환 신경망에서 입력값과 출력값 사이의 시점이 멀어질 수록 이전 Data의 소멸로 발생하는 기울기 소멸 문제를 해결한다. LSTM units에는 Forget gate, Input gate, Candidate cell, Output gate, Hidden state, Cell state로 구성된다. 먼저 Forget gate는 과거 메모리를 잊기 위한 gate이다. Cell state로부터 어떤 정보를 잊을 것인지 정하는 단계로 시그모이드 함수에 의해 결정한다. 시그모이드 함수는 0 또는 1의 값을 보내 얼마나 정보를 전달해야 하는지에 대한 척도를 나타낸다. 0을 보내면 모든 정보를 잊고, 1을 보내면 모든 정보를 보존하게 된다. 다음은 Input gate로, 시그모이드 함수가 앞으로 들어오는 새로운 정보 중 어떤 값을 Cell state에 저장할 것인지 정하여 업데이트한다. 이 과정에서 현재 단기 기억 상황일 경우 장기 기억을 얼마나 추가하는지 결정한다. Input gate에서 나온 값은 하이퍼볼릭 탄젠트 함수를 사용한 Candidate cell과 만나 과거의 Data를 얼마나 잊고 얼마나 기억하는지 조절하는 역할을 한다. 이 과정에서 과거의 정보와 현재 결과를 더해 현재 Cell state가 출력된다. 다음은 Output gate로 현재의 단기 기억 상황에 장기 기억을 추가한 후 이를 현재 예측에 얼마나 이

용하는지를 결정한다. 이 과정에서 하이퍼볼릭 탄젠트 함수를 사용해 다음 현재 Hidden state가 출력된다.

다음은 각 gate와 state에서 수행하는 과정을 수식으로 나타낸 것이다.

$$\mathbf{f}_t = \sigma(\mathbf{W}_f \mathbf{x}_t + \mathbf{U}_f \mathbf{h}_{t-1} + \mathbf{b}_f) \quad (4.9)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i \mathbf{x}_t + \mathbf{U}_i \mathbf{h}_{t-1} + \mathbf{b}_i) \quad (4.10)$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c \mathbf{x}_t + \mathbf{U}_c \mathbf{h}_{t-1} + \mathbf{b}_c) \quad (4.11)$$


$$\mathbf{o}_t = \sigma(\mathbf{W}_o \mathbf{x}_t + \mathbf{U}_o \mathbf{h}_{t-1} + \mathbf{b}_o) \quad (4.12)$$

$$\mathbf{c}_t = \mathbf{f}_t \circ \mathbf{c}_{t-1} + \mathbf{i}_t \circ \tilde{\mathbf{c}}_t \quad (4.13)$$

$$\mathbf{h}_t = \mathbf{o}_t \circ \tanh(\mathbf{c}_t) \quad (4.14)$$

또한, LSTM units 수는 p 로 정의하고 한 패킷에서 OFDM Symbol 수와 같다. LSTM-MLP에서 한 패킷에서 OFDM Symbol 수는 50개로 설정한다. 따라서 입력 weight matrix $\mathbf{W}_{f,i,c,o} \in \mathbb{R}^{(2|S_D| + 4|S_P|) \times p}$ 이고, 은닉 weight matrix $\mathbf{U}_{f,i,c,o} \in \mathbb{R}^{p \times p}$ 이다. 또한, bias vector $\mathbf{b}_{f,i,c,o} \in \mathbb{R}^{p \times 1}$ 이고, Cell state \mathbf{c}_t 와 Hidden state \mathbf{h}_t 의 크기는 $\mathbb{R}^{p \times 1}$ 이다.

$$\begin{aligned} \mathbf{h}_t &= \Phi_t(\mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t) \\ &= \begin{cases} \max(\mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t, 0), & \text{for } t \neq L \\ \mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t, & \text{for } t = L \end{cases} \end{aligned} \quad (4.15)$$



<그림 4-5> LSTM-MLP 계층

<표 4-2> LSTM-MLP 훈련 파라미터

Parameter	Values
LSTM-MLP (hidden layers, neurons per layer)	(2, 128-40)
Number of epochs	200
Number of training samples, validating samples	12000, 4000
Number of testing samples	2000
Batch size	128
Optimizer	Adam
Learning rate, drop period, factor	0.01,20,0.8
Number of OFDM symbols per packet	50

이후 LSTM units에서의 출력인 h_t 가 MLP 계층의 입력으로 들어가게 된다. MLP에서 t 번째 은닉 계층의 차원을 d_t 로 정의한다. 이때 은닉 계층의 weight matrix $W_t \in \mathbb{R}^{d_t \times d_{t-1}}$, bias vector $b_t \in \mathbb{R}^{d_t \times 1}$ 로 정의된다. 또한 <그림 4-5>는 LSTM-MLP 계층이고, <표 4-2>의 파라미터로 설정하여 학습한다.

4.4.2 초기 채널 추정 기법

인공신경망의 훈련이 끝난 후에 식(3.1)-(3.4)의 과정을 수행하여 t 번째 수신 신호의 초기 채널 값 $\tilde{H}_t(k)$ 을 추정한다.

4.4.3 Data set

LS 채널 추정 기법으로 t 번째 수신 신호의 초기 채널 추정 값 $\tilde{H}_t(k)$ 를 k_1 이 Data 부반송파와 Pilot 부반송파일 경우 이전 채널 추정값을 사용하고, k_2 가 Pilot 부반송파일 경우 현재 채널 추정값을 사용하여 식(4.3)와 같이 구성한다.

4.4.4 DNN 학습 과정 및 최종 채널 추정값


이후 4.4.1 훈련과정을 통해 얻은 weight matrix과 bias vector를 사용하여 학습을 수행하고, 이는 식(4.9) - (4.15)과 같다.

이후 \mathbf{y}_t^r 을 실수부와 허수부로 나눠 최종 채널을 추정한다. 이는 다음 식(4.16)과 같다.

$$H_{LSTM-MLP} = [Re([\mathbf{y}_t^r(k)]), Im([\mathbf{y}_t^r(k)])]^T \quad (4.16)$$

AE와 인공신경망에 DPA를 결합한 기법보다 LSTM-MLP는 시간 영역 특성을 고려하여 성능이 향상되었다. 그러나, LSTM의 units을 가변적으로 사용하기 때문에 Frame 내 앞부분에서 전송되는 OFDM Symbol의 채널 추정 시에는 LSTM units 수가 너무 작아 시간 영역 특성을 충분히 학습할 수 없다는 문제점이 있다. 뿐만 아니라, Frame 내 뒷부분에서 전송되는 OFDM Symbol의 채널 추정 시에는 너무 많은 LSTM units이 사용되기 때문에 성능 향상 대비 복잡도가 높아지고, 메모리 과사용의 문제점이 있다.

V. 제안 기법 : LSTM-MLP



<그림 5-1> 제안된 채널 추정 기법 과정

본 절에서는 채널의 시간 영역 특성 뿐만 아니라 주파수 영역 특성을 학습하여 채널 추정에 적용하는 새로운 인공신경망 기반의 채널 추정 기법을 제안한다. 기존 LSTM-MLP 기법은 한 Frame 내 OFDM 심볼의 순서에 따라 LSTM units의 time step 수를 가변적으로 사용하기 때문에 채널의 시간 영역 특성에 대한 학습이 안정적으로 이루어지지 못한다는 문제점을 가지고 있었다. 이를 해결하기 위하여 제안 기법에서는 채널의 시간축 특성을 충분히 학습할 수 있는 크기로 LSTM units의 time step 수를 고정시키고, 시간축 특성을 학습한다. 뿐만 아니라, LSTM의 입력 데이터셋을 time step 수에 상관없이 안정적으로 구성하기 위하여 1차적으로 AE 기반의 채널 추정 기법을 적용하여 채널을 추정한다.

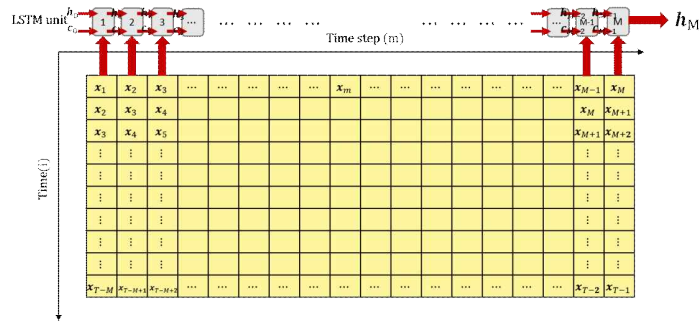
결과적으로 제안 기법은 AE 기반으로 채널의 주파수 영역 특성을 먼저 학습한 후 LSTM-MLP 과정을 통해 채널의 시간 영역 특성을 학습하게 된다. AE-LSTM-MLP의 채널 추정 과정은 <그림5-1>에 나타나 있다.

<표 5-1> 제안하는 채널 추정 기법의 AE 훈련 파라미터

Parameter	Values
Input size	104
Output size	104
Hidden layer	40-20-40
Activation function	ReLU
Epoch	400
Loss function	MSE
Optimizer	Adam

5.1 AE 훈련

LSTM-MLP Training Data는 <표 5-1>의 파라미터로 AE 채널 추정 기법과 같이 식(4.2) 과정을 통해 훈련한다. Loss function을 가지고 입력과 출력 간의 예측값과 실제값 사이의 차이를 최소화 하기 위해 최적화 함수 중 하나인 Adam을 사용하여 weight matrix과 bias vector를 업데이트한다. Epoch마다 Adam을 사용하여 weight matrix과 bias vector를 업데이트하면서, 신경망은 Loss function을 최소화하는 방향으로 학습을 수행한다. 반복적인 과정을 통해 모델은 입력 Data로부터 올바른 출력을 예측하기 위한 최적의 파라미터를 조정한다.



<그림 5-2> 학습 Data 전처리 과정 및 LSTM units


5.2 LSTM-MLP 훈련

이후 SNR 영역이 30dB인 환경에서 학습 과정을 수행한 AE 기반 채널값 \mathbf{y}_t^r 을 식(5.1)과 같이 LSTM-MLP 계층의 i 번째 OFDM Symbol에서 k 번째 부반송파의 훈련 Data $\mathbf{x}_t(k)$ 를 구성한다.

$$\mathbf{x}_t(k) = [Re([\mathbf{y}_t^r(k)]), Im([\mathbf{y}_t^r(k)])]^T \quad (5.1)$$

$$\mathbf{x}_t' \in \mathbb{R}^{(80 \times frame) \times M \times (2(|S_D| + |S_P|))} \quad (5.2)$$

<그림 5-2>에서와 같이 시간이 지남으로 인해 LSTM-MLP의 훈련 Data를 Left shift 한 형태로 구현한다. 이는 Time step 크기 M 에 맞춰 Left shift하고, 학습 Data 전처리 과정을 수행한 채널의 크기는 식(5.2)와 같다.



<그림 5-3> 제안하는 채널 추정 기법의 LSTM-MLP 계층

실제로는 식(5.2)의 입력 벡터 x_t' 가 LSTM units의 입력 Data로 사용된다.

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (5.3)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (5.4)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (5.5)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (5.6)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \quad (5.7)$$

$$h_t = o_t \circ \tanh(c_t) \quad (5.8)$$

LSTM은 순환 신경망 기법의 하나로, Cell state와 Forget gate, Input gate, Output gate를 추가하여 기존 순환 신경망에서 입력값과 출력값 사이의 시점이 멀어질 수록 이전 Data의 소멸로 발생하는 기울기 소멸 문제를 해결한다. LSTM units에는 Forget gate, Input gate, Candidate cell, Output gate, Hidden state, Cell state로 구성된다. 먼저 Forget gate는 과거 메모리를 잊기 위한 gate이다. Cell state로부터 어떤 정보를 잊을 것인지 정하는 단계로 시그모이드 함수에 의해 결정한다. 시그모이드 함수는 0 또는 1의 값을 내보내 얼마나 정보를 전달해야 하는지에 대한 척도를 나타낸다. 0을 보내면 모든 정보를 잊고, 1을 보내면 모든 정보를 보존하게 된다. 다음은 Input gate로, 시그모이드 함수가 앞으로 들어오는 새로운 정보 중 어떤 값을 Cell state에 저장할 것인지 정하여 업데이트한다. 이 과정에서 현재 단기 기억 상황일 경우 장기 기억을 얼마나 추가하는지 결정한다. Input gate에서 나온 값은 하이퍼볼릭 탄젠트 함수를 사용한 Candidate cell과 만나 과거의 Data를 얼마나 잊고 얼마나 기억하는지 조절하는 역할을 한다. 이 과정에서 과거의 정보와 현재 결과를 더해 현재 Cell state가 출력된다. 다음은 Output gate로 현재의 단기 기억 상황에 장기 기억을 추가한 후 이를 현재 예측에 얼마나 이용하는지를 결정한다. 이 과정에서 하이퍼볼릭 탄젠트 함

수를 사용해 다음 현재 Hidden state가 출력된다. 또한, LSTM units 수는 p 로 정의하고 입력 Data 크기와 같다. 따라서 입력 weight matrix $\mathbf{W}_{f,i,c,o} \in \mathbb{R}^{2(|S_D|+|S_P|) \times p}$ 이고, 은닉 weight matrix $\mathbf{U}_{f,i,c,o} \in \mathbb{R}^{p \times p}$ 이다. 또한, bias vector $\mathbf{b}_{f,i,c,o} \in \mathbb{R}^{p \times 1}$ 이고, Cell state \mathbf{c}_t 와 Hidden state \mathbf{h}_t 의 크기는 $\mathbb{R}^{p \times 1}$ 이다.

이후 LSTM units에서의 출력인 \mathbf{h}_t 가 MLP 계층의 입력으로 들어가게 된다. MLP에서 t 번째 은닉 계층의 차원을 d_t 로 정의한다. 이때 은닉 계층의 weight matrix $\mathbf{W}_t \in \mathbb{R}^{d_t \times d_{t-1}}$, bias vector $\mathbf{b}_t \in \mathbb{R}^{d_t \times 1}$ 로 정의된다.

$$\begin{aligned} \mathbf{h}_t &= \Phi_t(\mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t) \\ &= \begin{cases} \max(\mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t, 0), & \text{for } t \neq L \\ \mathbf{W}_t \mathbf{h}_{t-1} + \mathbf{b}_t, & \text{for } t = L \end{cases} \quad (5.9) \end{aligned}$$

이후 은닉 계층의 Hidden state 연산을 위해 활성화 함수는 $t \neq L$ 일 경우 ReLU 또는 $t = L$ 일 경우 Linear를 사용하고, 이는 식(5.9)과 같다.

제안하는 채널 추정 기법의 LSTM-MLP 계층은 <그림 5-3>과 같다.

5.3 초기 채널 추정 기법

식(3.1)-(3.4)의 과정에서 i 번째 Symbol에 대한 채널 값으로 AE 기반 채널 추정 기법을 수행한다. 4.1.3-4.1.4의 과정을 통해 AE 최종 채널 값 $\tilde{H}_t(k)$ 를 추정하며, 이는 한 개의 Frame 안의 1부터 M 번째 OFDM Symbol의 최종 채널 추정값이고, 식(5.10)과 같다.

여기서 M 은 Time step이고, 시간 영역에서 학습을 충분히 하기 위해 M 은 20으로 설정한다.

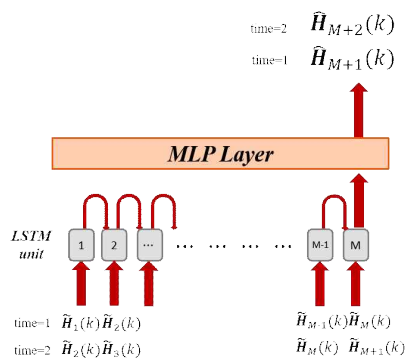
$$\hat{H}_1(k) = \tilde{H}_1(k), \hat{H}_2(k) = \tilde{H}_2(k), \dots, \hat{H}_M(k) = \tilde{H}_M(k) \quad (5.10)$$

5.4 LSTM-MLP 기반 학습 과정 및 최종 채널 추정값

5.2의 과정에서 얻은 LSTM-MLP의 각 weight matrix와 bias vector를 사용하여 식(5.3)-(5.9)의 학습을 수행한다. 이후, \hat{H}_{M+1} 을 실수부와 허수부로 나눠 다음 시간의 채널을 예측하는 최종 채널은 식(5.11)과 같다.

$$\hat{\mathbf{H}}_{M+1}(k) = [Re([\hat{H}_{M+1}(k)]), Im([\hat{H}_{M+1}(k)])]^T \quad (5.11)$$

또한, <그림 5-4>는 같이 시간이 지남에 AE 기반 채널 추정된 식(5.10)의 값이 <표 5-2>의 파라미터 값으로 LSTM-MLP 기반 채널이 예측되는 시각적으로 보인 것이다. 이 과정을 반복해서 수행한다.



<그림 5-4> 제안하는 채널 추정 기법의 채널 예측 시각화

<표 5-2> 제안하는 채널 추정 기법의 LSTM-MLP 계층 파라미터

Parameter	Values
LSTM-MLP (hidden layers, neurons per layer)	(3, 40-20-40)
Number of epochs	200
Number of training samples, validating samples	11200, 2800
Input size	104
Output size	104
Number of OFDM symbols per packet	100
Time step	20
Batch size	128
Learning rate, drop period, factor	0.01,20,0.8
Activation function	ReLU
Loss function	MSE
Optimizer	Adam

VI. 모의 실험


<표 6-1> 실험 환경 파라미터

Parameter	Values
FFT size	64
FFT period	6.4 μ s
OFDM Symbol period	8.0 μ s
GI duration	1.6 μ s
Total subcarriers	52
Pilot subcarriers	4
Data subcarriers	48
Code rate	1/2
Number of packet	100,000
Number of OFDM symbols per packet	100
Modulation Schemes	QPSK, 16QAM
Bandwidth	10MHz
Channel model	<ol style="list-style-type: none"> 1. Rural 2. Urban 3. Crossing 4. Highway LOS 5. Highway NLOS
Channel Estimation Alorithm	<ol style="list-style-type: none"> 1. AE 2. STA-DNN 3. E-TRFI-DNN 4. Proposed scheme


본 절에서는 AE-LSTM-MLP 기법과 기존 딥러닝 기반 채널 추정 기법인 AE 기반 채널추정기법, STA-DNN 및 ETRFI-DNN 기법의 PER 및 BER 성능을 비교, 분석한

다. <표 6-1>에서 보는 바와 같이 프레임 및 OFDM 파라미터는 IEEE 802.11p 표준을 기반으로 값을 설정하였고, 한 프레임은 100개의 OFDM 심볼로 설정하였다. 변조 기법은 QPSK와 16QAM을 고려하였고, 코드율은 1/2을 사용하였다. 채널은 Cohda Wireless 채널 모델에서 제시한 5가지 채널 모델을 모두 고려하였다. AE-LSTM-MLP의 time step은 20으로 설정하여 모의실험을 진행하였다.

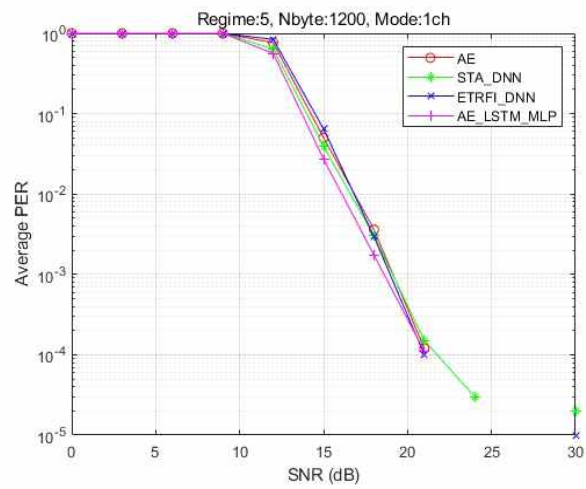
6.1 제안하는 채널 추정 기법 성능 및 분석




<그림 6-1> Rural LOS, QPSK, 1/2, 144km/h PER



<그림 6-2> Rural LOS, QPSK, 1/2, 144km/h BER




<그림 6-3> Rural LOS, 16QAM, 1/2, 144km/h PER




<그림 6-4> Rural LOS, 16QAM, 1/2, 144km/h BER

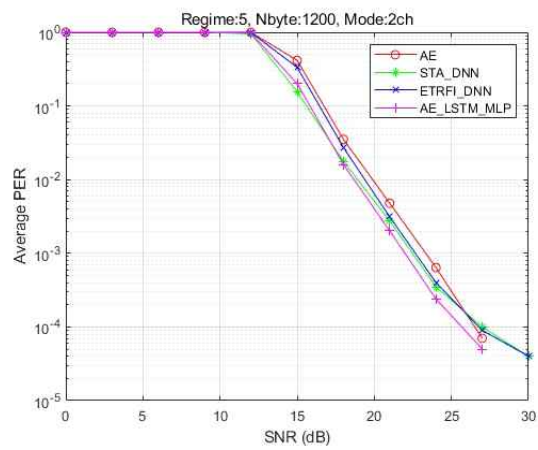
<그림 6-1>과 <그림 6-2>는 Rural 환경에서 QPSK 적용 시 제안 기법 및 기존 기법들 간 PER 성능과 BER 성능을 비교한 그래프이다. 채널이 LOS 환경을 기반으로 하고 있으며, 차량 간 상대속도도 144km/h로 높지 않기 때문에 채널의 시간축 및 주파수축 변화가 완만한 특성을 보인다. 이로 인해 기법들 간 성능 차이가 거의 발생하지 않고, 동일한 특성을 보여준다. 반면, <그림 6-3>과 <그림 6-4>는 Rural 환경에서 16QAM을 사용했을 때 기법들 간 PER 및 BER 성능을 나타내고 있다. 16QAM 사용 시 기법들 간 성능 차이가 발생하고 있으며, 제안 기법의 성능이 가장 우수한 것으로 나타나고 있다. 동일한 채널 환경에서도 16QAM에서는 심볼 간 정상도 상 Euclidean distance가 작아지기 때문에 채널 변화 및 잡음에 의한 왜곡 정도가 상대적으로 커지게 되는데, 제안 기법을 통해서 채널에 의한 왜곡 정도를 최소화할 수 있음을 확인할 수 있다.




<그림 6-5> Urban Approaching LOS, QPSK, 1/2, 119km/h PER



<그림 6-6> Urban Approaching LOS, QPSK, 1/2, 119km/h BER




<그림 6-7> Urban Approaching LOS, 16QAM, 1/2, 119km/h PER




<그림 6-8> Urban Approaching LOS, 16QAM, 1/2, 119km/h BER

<그림 6-5>와 <그림 6-6>은 Urban Approaching LOS 채널 환경에서 QPSK 적용 시 제안 기법 및 기존 기법들 간 PER 성능과 BER 성능을 비교한 그래프이다. 도심지를 모델링한 채널 모델이기 때문에 Rural 대비 차량 간 상대속도가 119km/h로 다소 느리고, LOS 환경을 기반으로 한다. 그러나, 도심지의 특성 상 채널의 최대 지연 시간이 더 길다는 특징이 있고, 이로 인해 Rural 환경 대비 주파수축 변화가 조금 더 큰 상황임을 알 수 있다. 그러나, 기법들 간 성능 차이는 거의 없는 것으로 나타났으며, 전반적으로 채널의 변화가 여전히 완만한 특성을 보이기 때문에 기법들 간 차이가 없는 것으로 판단된다. 반면, 동일 채널 환경에서 16QAM을 사용했을 때 PER 및 BER 성능을 비교한 <그림 6-7>과 <그림 6-8>을 보면, 기법들 간 성능 차이가 미세하게나마 발생하는데, 제안 기법의 성능이 가장 우수한 것을 확인할 수 있다. 주파수축 특성 뿐만 아니라 시간축 특성을 학습하기 때문에 채널의 전체적인 변화를 잘 추적했기 때문으로 분석된다.




<그림 6-9> Crossing NLOS, QPSK, 1/2,126km/h PER

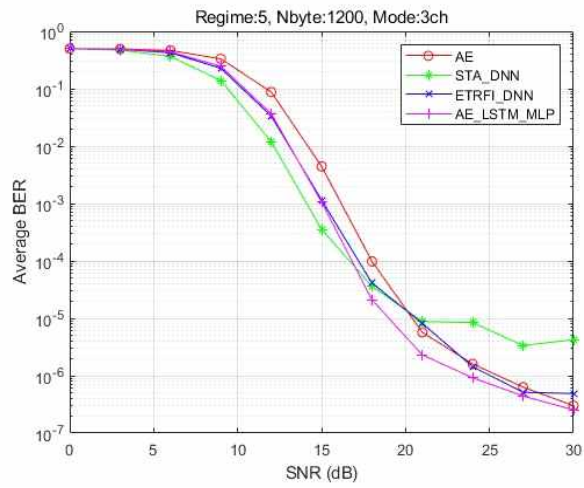


<그림 6-10> Crossing NLOS, QPSK, 1/2,126km/h BER

<그림6-9>와 <그림 6-10>은 Crossing NLOS 채널 환경에서 QPSK 적용 시 제안 기법 및 기존 기법들 간 PER 성과와 BER 성능을 비교한 그래프이다. 도심지 교차로에서 NLOS 환경을 모델링했기 때문에 차량 간 상대 속도가 126km/h, 채널의 최대 지연 시간이 533ns로 Urban Approaching LOS 채널의 최대 지연 시간 대비 월등히 길다. Crossing NLOS 채널 환경은 채널의 시간 축 변화보다는 주파수축 변화가 극심한 환경이기 때문에 채널의 주파수축 특성을 정확히 학습하는 것이 채널 추정 성능 향상에 중요한 요소가 된다. 이런 관점에서 PER 성능의 경우 제안기법과 STA-DNN 기법이 거의 유사하게 가장 좋은 성능을 보여주고 있다. 반면, STA-DNN 기법의 BER 성능을 오히려 가장 나쁘게 나타나는 반면, 제안 기법의 성능은 여전히 가장 우수한 성능을 보여주고 있다.




<그림 6-11> Crossing NLOS, 16QAM, 1/2,126km/h PER




<그림 6-12> Crossing NLOS, 16QAM, 1/2,126km/h BER


<그림6-11>과 <그림 6-12>는 동일 채널 환경에서 16QAM을 사용했을 때 제안 기법과 기존 기법들 간 PER 성능 및 BER 성능을 비교한 그래프이다. PER 성능의 경우 제안 기법의 성능이 STA-DNN 기법의 성능 대비 약간의 우위를 보이고 있는 반면, BER 성능에서는 제안 기법이 2dB 이상 성능 향상을 보여주고 있고, STA-DNN의 경우 error floor 발생으로 인해 가장 나쁜 성능을 보인다.




<그림 6-13> Highway LOS, QPSK, 1/2, 252km/h PER



<그림 6-14> Highway LOS, QPSK, 1/2, 252km/h BER




<그림 6-15> Highway LOS, 16QAM, 1/2, 252km/h PER

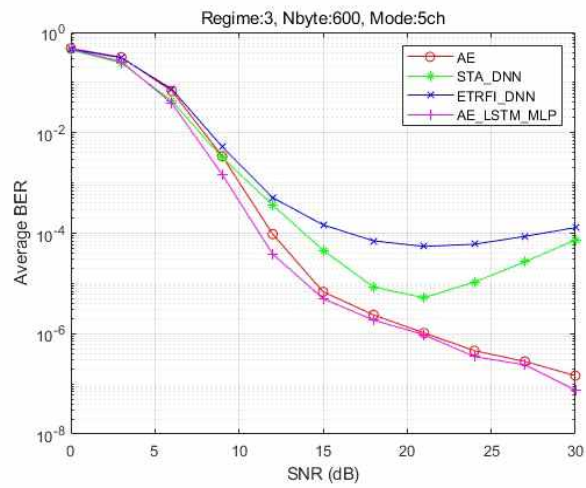


<그림 6-16> Highway LOS, 16QAM, 1/2, 252km/h BER


<그림 6-13>부터 <그림 6-16>은 Highway LOS 채널 환경에서 각각 QPSK의 PER과 BER, 16QAM의 PER과 BER 성능을 보여준다. QPSK를 사용한 경우 PER과 BER 모두 제안 기법과 STA-DNN 및 ETRFI-DNN의 성능이 유사한 것으로 나타난다. 반면, 16QAM에서는 제안기법의 성능이 가장 우수하게 나타나고 있으며, error floor 현상이 나타나는 STA-DNN과 ETRFI-DNN과는 달리 제안 기법은 높은 SNR에서도 우수한 성능을 유지하는 것을 확인할 수 있다.




<그림 6-17> Highway NLOS, QPSK, 1/2, 252km/h PER



<그림 6-18> Highway NLOS, QPSK, 1/2, 252km/h BER



<그림 6-19> Highway NLOS, 16QAM, 1/2, 252km/h PER



<그림 6-20> Highway NLOS, 16QAM,1/2, 252km/h BER

<그림 6-17>부터 <그림 6-20>은 Highway NLOS 채널 환경에서 각각 제안 기법 및 기존 기법들 간 QPSK의 PER과 BER, 16QAM의 PER과 BER 성능을 보여준다. Highway NLOS 채널 환경은 채널의 시간축 및 주파수축 변화가 가장 극심한 채널로서 주파수축 뿐만 아니라 시간축에서 채널을 잘 학습해야만 좋은 채널 추정 성능을 보여줄 수 있다. 이런 이유로 채널의 주파수축 뿐만 아니라 시간축에서 안정적 학습이 가능한 제안 기법의 성능이 기존 기법의 성능 대비 우수하다는 것을 명확하게 보여준다. 특히 16QAM이 적용되었을 경우 기존 기법보다 2dB 이상의 성능 차이가 발생하는 것을 확인할 수 있다.

VII. 결론

본 논문에서는 IEEE 802.11p 기반 WAVE 통신 시스템에서 채널 추정 정확도 및 PER/BER 성능을 향상시킬 수 있는 딥러닝 기반의 AE-LSTM-MLP 채널 추정 기법을 제안하였다. 제안 기법에서 사용하는 인공신경망은 채널의 주파수 영역 특성을 학습하기 위한 AE 네트워크와 채널의 시간 영역 특성을 학습하기 위한 LSTM-MLP 네트워크로 구성되어 있으며, AE 네트워크와 LSTM-MLP 네트워크 기반의 채널 특성 학습은 독립적으로 이루어진다.

채널의 시간 영역 특성 및 주파수축 특성을 학습한 이후 최적화된 각 네트워크의 파라미터를 기반으로 수신단에서는 AE 기반의 채널 추정을 수행한 후, 출력값을 다시 LSTM-MLP 네트워크의 입력값으로 인가하여 채널값을 최종적으로 업데이트한다. 이 때, LSTM units의 time-step의 수는 고정적으로 설정함으로써 채널의 시간 영역 특성을 안정적으로 학습할 수 있다. 뿐만 아니라, AE 기반으로 추정된 채널값이 LSTM 네트워크의 입력 데이터로 사용되기 때문에 기 학습된 채널의 시간 영역 특성을 기반으로 채널 추정 시 그 정확도를 더욱 향상시킬 수 있다.

제안 기법의 이러한 구조적 특성에 기인하여 기존 딥러닝 채널 추정 기법 대비 채널 추정 정확도를 높일 수 있으며, PER 및 BER 성능을 더욱 향상시킬 수 있다. 모의 실험을 통해서도 이러한 제안 기법의 우수성을 입증하였다. Coda Wireless에서 제시한 모든 채널 모델에서 제안 기법의 PER 및 BER 성능이 기존 기법 대비 동

일하거나 우수한 성능을 보였으며, 특히 Highway NLOS 환경에서 16QAM을 사용하였을 경우 기존 기법 대비 2dB 이상의 성능 이득을 보인다.

참고문헌

- [1] A. Festag, "Cooperative Intelligent Transport Systems (C-ITS) Standards in Europe," *Communication Magazin*, vol. 12, no. 52, Dec, 2014.
- [2] C. Lin, C. Sun, J. Lin, and B. Chen, "Performance evaluations of channel estimations in IEEE 802.11p environments", in *Proc. Int. Conf. Ultra Modern Telecommunications & Workshops*, pp. 1-5, Oct, 2009.
- [3] K. Zheng, Q. Zheng, H. Yang, L. Zhao, L. Hou, and P. Chatzimisios, "Reliable and efficient autonomous driving: The need for heterogeneous vehicular networks," *IEEE Commun. Mag.*, vol. 53, no. 12, pp. 72-79, Dec. 2015.
- [4] L. Bernado, T. Zemen, N. Czink, and P. Belanovic, "Physical layer simulation results for IEEE 802.11p using vehicular non-stationary channel model," in *Proc. IEEE Int. Conf. Commun.*, Cape Town, South Africa, May 23-27, 2010.
- [5] A. M. S. Abdelgader and W. Lenan, "The physical layer of the IEEE 802.11p WAVE communication standard: The specifications and challenges," in *Proc. WCECS*, pp. 691-698, Oct. 2014.
- [6] J. A. Fernandez, K. Borries, L. Cheng, B. V. K. Vijaya Kumar, D. D. Stancil, and F. Bai, "Performance of the 802.11p Physical layer in vehicle-to-vehicle environments," *IEEE Trans. Veh. Tech.*, vol. 61, no. 1, pp. 3-14, Jan, 2012.

- [7] Z. Zhao, X. Cheng, M. Wen, C.-X. Wang, and B. Jiao, "Channel estimation schemes for IEEE 802.11p standard," *IEEE Intell. Transp. Syst. Mag.*, vol. 5, no. 4, pp. 38-49, 2013.
- [8] Y. K. Kim, J. M. Oh, Y. H. Shin and C. Mun, "Time and frequency domain channel estimation scheme for IEEE 802.11p," in *Proc. IEEE ITSC'14*, Oct, 2014.
- [9] Seungho Han, Jinsu Park, and Changick Song, "Virtual Subcarrier Aided Channel Estimation Schemes for Tracking Rapid Time Variant Channels in IEEE 802.11p Systems", 2020 IEEE 91st Vehicular Technology Conference (VTC), May, 2020.
- [10] Seungho Han, Yeonji Oh, and Changick Song, "A Deep Learning based Channel Estimation Scheme for IEEE 802.11p Systems", 2019 IEEE International Conference on Communications (ICC), May, 2019.
- [11] A. K. Gizzini et al., "Deep learning based channel estimation schemes for IEEE 802.11p standard," *IEEE Access*, vol. 8, pp. 113751-113765, Jun, 2020.
- [12] 김주혁, 김성환, 송창익. "가상 부반송파와 인공지능 경망을 이용한 향상된 V2X 채널추정 기법." *대한전자공학회 학술대회논문집*, pp. 749-751, June, 2021.

[13] Jing Pan, Hanguan Shan, Rongpeng Li, Yingxiao Wu, Weihua Wu, Tony Q. S. Quek, "Channel Estimation Based on Deep Learning in Vehicle-to-Everything Environments", IEEE Communications Letters, Vol. 25, Issue. 6, pp. 1891 – 1895, June, 2021.

Abstract

In this paper, we propose a deep learning based channel estimation technique for the IEEE 802.11p Vehicle to Everything (V2X) WAVE communication system. V2X aims to mitigate Error flow by estimating the vehicle's high mobility and fast-changing channels. Data-Pilot Aided (DPA) channel estimation techniques have been developed to solve this problem, but the correlation of channels due to road surrounding factors such as actual driving speed or road environment changes, resulting in deterioration of performance.

Therefore, recently, an artificial neural network-based DPA technique channel estimation has been proposed. However, since this technique only considers the characteristics of the frequency domain of the received signal, there is a problem that it does not take into account the characteristics of the channel that changes rapidly in the time domain.

In addition, to solve this problem, an LSTM-MLP technique that combines Long Short-Term Memory (LSTM) and Multilayer Perceptron (MLP) has been proposed. However, there is a problem of poor channel estimation accuracy by generating LSTM-MLP training Data using LS (Least Square) channel estimated Data, previous channels in pilot subcarriers, and four pilots of LS channel estimated current channels.

Therefore, in this paper, to solve this problem, the learning Data of the LSTM units is used as the input Data in the frequency domain as the AE. In addition, the time step for delaying the training Data in the time domain is determined to be 20, so that more training Data enters the input Data of the LSTM units. Since the amount of Data has increased by performing a training Data preprocessing process to solve the problems of the previous technique, the MLP layer is increased to three for stable learning.

Through the simulation results, the proposed technique improves performance, especially in Highway NLOS, compared to the technique that combines DNN with the DPA technique.