

머신 러닝을 이용한 고속 시변 OFDM 채널 예측의 성능 개선

임 동 민*

Performance Improvement of Fast Time-Varying OFDM Channel Estimation by Machine Learning

Dongmin Lim*

요 약

CE-BEM을 이용하는 저복잡도 고속 시변 OFDM 채널 예측은 성능 개선에 있어 시스템 파라미터 값을 결정하는 문제가 매우 복잡한 양상을 띠고 있다. 본 논문에서는 머신 러닝에 의한 CE-BEM 문제점을 개선하는 방안을 제시한다.

Key Words : OFDM, fast time-varying channels, channel estimation, machine learning

ABSTRACT

The determination of system parameter values is very complicated for improving the performance of fast time-varying OFDM channel estimation with low complexity CE-BEM. In this letter, we propose a method to mitigate the problem of the CE-BEM by machine learning.

I. 서 론

고속 시변 OFDM 채널 예측에서는 채널 응답을 기저 함수의 선형 결합으로 표현하는 BEM(Basis Expansion Model) 방식을 주로 이용한다^[1,2]. DPSS(Discrete Prolate Spheroidal Sequences)^[3], Legendre 다항식 등 고속 시변 채널 특성에 적합한

기저 함수를 사용하는 경우, 수신 신호로부터 채널 응답의 BEM 계수를 예측하는 절차에는 전체 BEM 계수를 미지수로 하는 선형 연립 방정식의 해를 구하는 과정이 포함된다. 고속 시변 채널의 경우 BEM 기저 함수의 개수가 증가하게 되며 채널 예측 알고리즘의 계산 복잡도도 증가하게 된다. 한편 복소 지수함수(Complex Exponential: CE)를 기저함수로 사용하는 경우에는 주파수 영역 OFDM 채널 행렬의 대역폭이 제한되는 효과가 나타난다. 수식적으로는 전체 BEM 계수에 대한 하나의 선형 연립 방정식이 주파수 성분별로 독립적인 저차원 선형 연립 방정식들로 분리되어 계산 복잡도 및 저장 공간이 크게 감소하게 된다^[2]. 그러나 저복잡도 CE-BEM은 OFDM 심볼 구간의 채널 응답을 주기 함수로 근사화하는 방식이며 기저 함수의 개수가 늘어나도 근사화 오차가 빠르게 감소하지 않는 문제점을 내포하고 있다^[1,4].

이러한 문제점을 해결하기 위하여 참고문헌 [1]에서는 Legendre 다항식에 대한 복소 지수함수의 정사영(orthogonal projection)을 이용하여 채널 응답의 Legendre 다항식 BEM 계수를 간접적으로 구하는 방식을 이용하였다. 참고문헌 [2]에서는 OFDM 심볼 구간의 양 가장자리에서 예측 오차가 가장 크게 발생하는 점에 착안하여 구간의 가장자리 부분을 피하여 채널 응답을 샘플링한 후 이 샘플들을 DPSS-BEM 계수를 구하는데 이용하였다. 이 방식에서는 BEM 기저함수의 개수를 채널 환경에 적합하게 결정하는 것이 관건이나 최적의 기저함수 개수를 결정하는 문제는 채널의 도플러 주파수, 채널 경로의 수, 신호 대 잡음비 등 채널 환경 변화에 따라 달라지는 매우 복잡한 양상을 띠고 있다. 본 논문에서는 머신 러닝 기법을 이용하여 주어진 채널 환경에서 BEM 기저함수의 개수와 무관하게 CE-BEM 계수로부터 DPSS-BEM 계수를 구하여 채널 예측 성능을 개선하는 방안을 제시한다.

II. 머신 러닝에 의한 성능 개선

고속 시변 OFDM 채널의 특성은 시점 $n-l$ 에서 입력된 임펄스에 대한 시점 n 에서의 응답인 $h(n,l)$ 로 나타낼 수 있다. 시간 지연이 서로 다른 L 개의 채널 경로가 존재한다고 가정하고 최대 도플러 주파수를 OFDM 부채널 간격에 정규화시킨 f_D 는 채널의

* 이 연구는 2016년도 경상대학교 학술진흥지원사업 연구비에 의하여 수행되었음

• First Author : (ORCID:0000-0003-1853-1048)Gyeongsang National University Department of Electronic Engineering, dmlim@gnu.ac.kr, 종신회원

논문번호 : 201812-391-A-LU, Received December 17, 2018; Revised January 4, 2019; Accepted January 13, 2019

시변 특성을 나타낸다. OFDM의 부채널 개수를 N , CP(Cyclic Prefix)의 길이를 $L-1$ 로 표시하면 OFDM 심볼 \mathbf{u} 에 대한 수신 신호 \mathbf{y} 는 다음과 같이 주어진다^[2]

$$\mathbf{y} = \mathbf{F} \text{diag}(\mathbf{w}) [\mathbf{H}^{(t)} \mathbf{F}^H \mathbf{u} + \mathbf{n}]. \quad (1)$$

위 식에서 \mathbf{F} 는 이산 푸리에 변환을 나타내는 유니타리 행렬, \mathbf{w} 는 채널의 대역폭을 제한하기 위한 윈도우 함수, $\mathbf{H}^{(t)}$ 는 시간 영역 채널 행렬, \mathbf{n} 은 복소정규 잡음, $\text{diag}(\mathbf{a})$ 는 벡터 \mathbf{a} 로 구성된 대각 행렬, $(\)^H$ 는 공액복소 전치 연산을 나타낸다.

CE-BEM OFDM 채널 예측에서는 윈도우가 적용된 l 번째 채널 경로의 응답 \mathbf{h}_l 을 기저함수 행렬 \mathbf{B}_c 에 대한 BEM 계수 $\xi_l^{(c)}$ 로 나타낸다^[2]

$$\text{diag}(\mathbf{w}) \mathbf{h}_l = \mathbf{B}_c \xi_l^{(c)}. \quad (2)$$

OFDM 심볼 검출에는 일반적으로 윈도우를 제거한 예측된 채널 응답이 사용되며^[1,2] DPSS-BEM을 이용하는 경우 보다 정확한 표현이 가능해진다

$$\mathbf{h}_l = \mathbf{B}_d \xi_l^{(d)}. \quad (3)$$

위 식에서 \mathbf{B}_d 는 DPSS로 구성된 기저함수 행렬이며 $\xi_l^{(d)}$ 는 해당 BEM 계수를 나타낸다. 채널 예측에서 얻어진 CE-BEM 계수 $\xi_l^{(c)}$ 로부터 DPSS-BEM 계수 $\xi_l^{(d)}$ 을 구하는 기존의 방식은 채널 환경에 따라 최적의 시스템 파라미터 값이 달라지는 매우 복잡한 문제이며^[1,2] 본 논문에서는 컴퓨터 모의실험에 의해 수집된 데이터를 학습에 이용하는 머신 러닝 기법^[5]을 도입한다.

참고문헌 [5]에서는 채널 예측과 데이터 심볼 검출을 동시에 구현하기 위하여 OFDM 시스템의 모델링에 5 계층으로 구성된 심층 신경망(deep neural network)을 도입하고 있다. 본 논문에서는 채널에 대한 서로 다른 표현인 BEM 계수 사이의 변환에 대한 문제를 다루며 다음과 같은 간단한 선형 회기(linear regression) 모델^[6]을 적용한다

$$\hat{\xi}_l^{(d)} = \Psi^T \xi_l^{(c)}. \quad (4)$$

위 식에서 $(\)^T$ 는 행렬의 전치 연산을 나타낸다. 머

신 러닝에서의 학습 과정은 식 (4)의 선형 회기 모델이 훈련용 데이터에 최적화 되도록 행렬 Ψ 를 설정하는 과정이다. 본 논문에서의 학습 방식은 지도 학습(supervised learning), 오프라인 학습에 해당한다. 컴퓨터 모의실험에 의해 훈련용 데이터를 수집하는 과정은 다음과 같다. 채널 예측에는 매 OFDM 심볼에 길이가 L_p 인 파일럿 심볼 서브블록 M 개를 데이터 서브블록 사이에 등간격으로 배치하는 방식을 이용한다^[1,2]. 우선 사용자 데이터와 파일럿 심볼로 구성된 OFDM 심볼 \mathbf{u} 를 생성한다. 도플러 주파수 f_D 와 Jakes 스펙트럼 모델에 의거 L 개의 시변 채널 응답 \mathbf{h}_l 을 생성하여 시간 영역 채널 행렬 $\mathbf{H}^{(t)}$ 를 구성한다. 주어진 신호 대 잡음비(SNR)에 따라 잡음 \mathbf{n} 을 생성한 후 식 (1)을 이용하여 수신 신호 \mathbf{y} 를 계산한다. 수신 신호 \mathbf{y} 에서 채널 예측에 사용되는 심볼들을 선택하여 저복잡도 LS 채널 예측 방식^[2]을 이용하여 L 개의 CE-BEM 계수 $\xi_l^{(c)}$ 을 구한다(참고문헌 [2]의 식 (14)-(16) 참조). L 개의 CE-BEM 계수 $\xi_l^{(c)}$ 을 행벡터로 전치하여 훈련용 데이터 세트 \mathbf{X} 에 차례로 추가한다. DPSS-BEM 기저함수 \mathbf{B}_d 가 직교 행렬인 점을 식 (3)에 적용하면 목표로 하는 DPSS-BEM 계수 $\xi_l^{(d)} = \mathbf{B}_d^T \mathbf{h}_l$ 로 구할 수 있다. L 개의 DPSS-BEM 계수 $\xi_l^{(d)}$ 를 행벡터로 전치하여 훈련용 타깃 세트 \mathbf{Y} 에 차례로 추가한다. 지금까지 기술한 모의실험 과정을 N_t 번 반복하면 원소의 개수가 각각 $N_t L$ 인 훈련용 데이터 세트 \mathbf{X} 와 타깃 세트 \mathbf{Y} 가 완성된다.

성능 측정 지표로 평균 제곱 오차(MSE)를 선정하면

$$\text{MSE} = \frac{1}{N_t L} \sum_{n=1}^{N_t L} \|\mathbf{X}^{(n)} \Psi - \mathbf{Y}^{(n)}\|_2^2 \quad (5)$$

MSE를 최소화하는 행렬 Ψ 는 직교 방정식(normal equation)의 해로 다음과 같이 구할 수 있다^[6]

$$\hat{\Psi} = (\mathbf{X}^H \mathbf{X})^{-1} \mathbf{X}^H \mathbf{Y}. \quad (6)$$

식 (5)에서 $\mathbf{X}^{(n)}$, $\mathbf{Y}^{(n)}$ 는 각각 세트 \mathbf{X} , \mathbf{Y} 의 n 번째 원소를 나타낸다.

III. 모의실험 결과 및 결론

컴퓨터 모의실험은 Jakes 스펙트럼 채널 환경, QPSK 변조 방식, OFDM 시스템 파라미터 $N=256$, $L=5$, $f_D \leq 1.0$ 범위에서 수행하였다. 파일럿 심볼은 서브블록의 개수 $M=5$, 길이 $L_p=9$ 로 설정하였고 데이터 심볼에 의한 간섭을 줄이기 위하여 해밍 윈도우를 적용하였다. 실제 채널 환경과 훈련용 데이터를 수집하기 위한 모의실험에서 가정된 채널 환경은 일반적으로 정확히 일치하지는 않으며 본 논문에서는 각 채널 경로 응답의 전력 분포, Jakes 스펙트럼 채널 모델에서 정현파 발진기의 개수 등을 다르게 설정하여 이러한 상황을 반영하였다.

우선 선형 회귀 모델의 학습에 사용한 데이터를 수집하기 위한 모의실험의 횟수 N_i 에 대한 채널 예측 성능 변화를 그림 1에 도시하였다. 훈련용 데이터의 개수가 증가하면 채널 예측 성능이 빠르게 수렴하는 현상을 보이며 이후 모의실험에서는 $N_i=10$ 으로 설정하였다. 그림 2에 제안된 머신 러닝에 의해 개선된 채널 예측 성능을 기존 방식과 비교하여 도시하였다. $f_D=0.2$ 인 경우 CE-BEM 모델의 문제점 개선으로 성능이 크게 개선됨을 확인할 수 있으며 비교적 고속 시변 채널인 $f_D=1.0$ 인 경우에는 데이터 심볼에 의한 간섭이 성능을 저하시키는 주요 원인이며 따라서 CE-BEM 모델의 문제점 개선으로 인한 성능 개선 효과는 제한적이다. 그림 2에서 SNR이 낮은 영역에서의 성능 개선 효과는 머신 러닝 학습 과정에서 SNR 예측값을 적용한 것이 주요 원인이다. 동일한 조건에서의 성능 비교를 위하여 그림 3에서는 SNR 예측값과 Jakes 스펙트럼 채널 모델의 통계적 2차 특성을 반




그림 1. 모의실험 횟수 N_i 에 대한 채널 예측 성능
Fig. 1. MSE performances according to different values of N_i

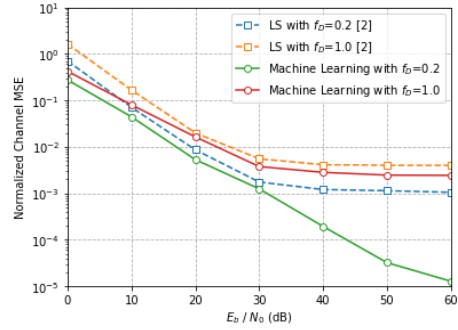


그림 2. 채널 예측 방식의 성능 비교(LS)
Fig. 2. Performance comparisons for channel estimation methods(LS)




그림 3. 채널 예측 방식의 성능 비교(MMSE)
Fig. 3. Performance comparisons for channel estimation methods(MMSE)

영한 MMSE 예측 방식을 사용하고 DPSS-BEM 기저함수의 개수 K_d , 샘플링 인덱스 i_k (참고문헌 [2]의 식 (17) 참조), 샘플의 개수 N_s 등을 최적화하여 얻어진 성능을 머신 러닝 방식의 성능과 비교하였다. 기존 방식의 경우 최적의 성능을 구하기 위하여 여러 번의 모의실험을 수행하여 $f_D=0.2$ 인 경우 $K_d=3$, $N_s=4$, $f_D=1.0$ 인 경우 $K_d=4$, $N_s=7$ 로 설정하였으며 머신 러닝 방식의 경우에는 기저함수의 개수 $K_d=5$ 로 고정하였다. 주어진 f_D 와 SNR 범위의 채널 환경에서 제안된 머신 러닝 방식에 의한 채널 예측 성능 개선 효과를 확인할 수 있었다.

References

[1] T. Hrycak, S. Das, G. Matz, and H. Feichtinger, "Practical estimation of rapidly varying channels for OFDM systems," *IEEE Trans. Commun.*, vol. 59, no. 11, pp. 3040-

- 3048, Nov. 2011.
- [2] D. Lim, "Performance improvement of low complexity LS channel estimation for OFDM in fast time varying channels," *J. IEK*, vol. 49-TC, no. 8, pp. 25-32, Aug. 2012.
 - [3] T. Zemen and C. F. Mecklenbrauker, "Time-variant channel estimation using discrete prolate spheroidal sequences," *IEEE Trans. Signal Process.*, vol. 53, no. 9, pp. 3597-3607, Sep. 2005.
 - [4] T. A. Driscoll and B. Fornberg, "A Padé-based algorithm for overcoming the gibbs phenomenon," *Numerical Algorithms*, vol. 26, no. 1, pp. 77-92, 2001.
 - [5] H. Ye, G. Li, and B. Juang, "Power of deep learning for channel estimation and signal detection in OFDM systems," *IEEE Trans. Wireless Commun. Lett.*, vol. 7, no. 1, pp. 114-117, Feb. 2018.
 - [6] K. Murphy, *Machine Learning: A Probabilistic Perspective*, The MIT Press, 2012.