

FDD Massive MIMO 시스템에서의 적응 채널 추정 기법

정진주*, 한용희*, 이정우^o

Adaptive Channel Estimation Techniques for FDD Massive MIMO Systems

Jinjoo Chung*, Yonghee Han*, Jungwoo Lee^o

요약

Frequency-division duplex (FDD) massive multiple-input multiple-output (MIMO) 시스템에서 하향 링크 채널 추정의 계산 복잡도는 기지국의 안테나 개수와 비례한다. 그러므로 이러한 시스템에서의 효율적인 채널 추정 방식이 연구 될 필요가 있다. 본 논문에서는 채널이 시간적, 공간적 상관관계를 가지는 모델에서 Kalman 필터와 least mean square (LMS) 등과 같은 적응 신호처리 기법을 이용한 채널 추정 방식을 제안한다.

Key Words : massive MIMO, adaptive channel estimation, Kalman, LMS

ABSTRACT

In frequency-division duplex (FDD) massive multiple-input multiple-output (MIMO) system, the computational complexity of downlink channel estimation is proportional to the number of antennas at a base station. Therefore, effective channel estimation techniques may have to be studied. In this paper, novel channel estimation algorithms using adaptive techniques such as Kalman and least mean square (LMS) filters are proposed in a channel model with temporal and spatial correlation.

I. 서론

무선 통신 시스템은 더 많은 양의 데이터를 더 빠르게 전송하도록 요구되고 있고, 이에 무선 통신 시스템들은 더 효율적인 대역폭의 활용과 더 큰 채널 용량을 필요로 하게 되었다. 최근 multiple-input multiple-output (MIMO) 시스템을 매우 큰 규모로 확

장하여 무수히 많은 개수의 안테나를 사용하는 massive MIMO 시스템이 소개 되었고, 주파수 효율을 매우 높일 수 있게 되었다¹⁻³. Massive MIMO 시스템은 많은 개수의 안테나를 이용하여 기지국에서 송신 데이터에 하향링크 채널 정보를 이용한 프리코딩 기법을 적용 함으로써 매우 좁은 구역에 선택적으로 빔을 송신할 수 있다. 기지국에서 사용하는 안테나

※ 본 연구는 한국연구재단 일반연구지원사업(NRF-2013R1A1A2008956), 방위사업청 지원 국방생체모방자율로봇특화센터(UD130070ID) 및 BK21플러스 창의정보기술 인재양성사업단의 지원으로 수행되었습니다.

• First Author : Department of Electrical and Computer Engineering, INMAC, Seoul National University, jjpearll@wspl.snu.ac.kr, 정희원

^o Corresponding Author : Department of Electrical and Computer Engineering, INMAC, Seoul National University, junglee@snu.ac.kr, 종신희원

* Department of Electrical and Computer Engineering, INMAC, Seoul National University, yhan@wspl.snu.ac.kr, 학생회원
논문번호 : KICS2015-03-082, Received March 31, 2015; Revised May 8, 2015; Accepted July 15, 2015

개수가 증가할수록 빔을 더 좁게 생성할 수 있으므로 채널 용량이 증가하고 저전력 통신이 가능해진다.

채널 행렬은 송신 단과 수신 단의 안테나 개수에 따라 크기가 정해진다는 것을 고려할 때, 이러한 massive MIMO 시스템은 기지국에 수 십 개에서 수 백 개의 안테나를 배치하므로 채널 행렬의 크기가 매우 커지게 된다. 이에 기존의 연구들은 massive MIMO 시스템에서 발생하는 채널 추정 문제를 해결하기 위해 상향 링크와 하향 링크 간의 채널 상호성을 이용하여 송신단에서 채널 정보를 얻기 용이한 time-division duplex (TDD) 기반의 시스템을 주로 고려하였다¹⁻⁴⁾. TDD 시스템은 채널의 상호성을 이용하여 하향 링크의 채널을 상향 링크의 채널 추정으로 대신할 수 있기 때문에 각 수신기에서 하향링크의 채널을 추정하여 기지국에 피드백 해 줄 필요 없이 기지국이 상향 링크의 채널을 추정하여 하향 링크 채널을 얻을 수 있다.

Frequency-division duplex (FDD) 시스템의 경우, 송신 단에서 채널 정보를 얻기 위해서는 수신 단에서 추정된 채널 정보를 피드백을 통해 전송해 주어야 한다. 채널 상호성을 이용할 수 없는 FDD 시스템에서 채널 추정을 위한 트레이닝 신호의 오버헤드는 송신 단의 안테나 수에 비례한다. 이러한 오버헤드는 massive MIMO 시스템을 사용함으로써 얻을 수 있는 주파수 효율의 증대를 저해한다. 그러나 현재 사용되고 있는 이동통신 시스템은 대부분 FDD 시스템임을 고려할 때, FDD massive MIMO 시스템에서 효율적인 채널 추정 기법을 연구할 필요가 있다.

본 논문에서는 채널이 시간, 공간적으로 서로 상관관계가 있는 경우 FDD massive MIMO 시스템에서 효율적인 채널 추정 기법을 제안한다. 채널이 이런 특성을 가지는 경우 최적의 채널 추정 기법은 칼만 필터를 이용하는 것이다⁵⁾. 그러나 칼만 필터는 행렬 연산으로 이루어져 있기 때문에 채널 행렬이 매우 커지는 경우 계산 복잡도가 매우 증가하는 경향이 있고, 이로 인해 채널 추정에 필요한 처리 지연 시간 또한 증가한다. 제안하는 알고리즘은 이러한 처리 지연 시간을 줄이기 위한 기법으로 칼만 필터와 normalized least mean square (nLMS) 필터를 시간 분할하여 이용하는 방식인 하이브리드 채널 추정 방식과, 데이터 전송 구간 동안 채널을 추가로 업데이트 할 수 있는 decision feedback (DFB) nLMS 방식이다. 2장에서 시스템 모델을, 3장에서 제안하는 알고리즘들을 소개하고 4장에서 모의 실험을 통하여 mean square error (MSE)와 bit error rate (BER) 측면에서 기존의 알고리즘과 제

안된 알고리즘 간의 성능을 비교하고 분석한다.

II. 시스템 모델

본 논문에서는 N_t 개의 송신 안테나와 단일 사용자가 한 개의 수신 안테나를 가지는 FDD multiple-input single-output (MISO) 시스템을 고려한다. 또한 송신 안테나의 개수는 수신 안테나 개수의 총 합보다 매우 크다고 가정한다. 즉, $N_t \gg 1$ 이다.

시간 영역에서 k 번째 심볼 타임에 수신되는 신호는 다음 수식과 같이 표현된다.

$$y_k = \mathbf{h}_k^H \mathbf{x}_k + n_k, \quad k = 1, 2, \dots \quad (1)$$

여기서 \mathbf{x}_k 는 $N_t \times 1$ 송신 벡터, \mathbf{h}_k 는 $N_t \times 1$ MISO 채널 벡터, 그리고 n_k 는 평균이 0이고 공분산이 σ_n^2 인 독립 항등 분포(i.i.d) Gaussian 잡음이다. 채널은 state-space 모델을 따르며 블록마다 변화하는 블록 페이딩 환경을 가정한다. 또한, massive MIMO 시스템의 조밀한 안테나 배열과 제한된 스캐터링 환경을 고려하여 공간적으로 상관되어 있음을 가정하며⁶⁾, 시간적으로도 상관되어 있음을 가정한다.

시간 상관 관계는 first-order stationary Gauss-Markov 프로세스를 따르며⁷⁾, 아래 수식과 같이 표현할 수 있다.

$$\mathbf{h}_{k+1} = a\mathbf{h}_k + \sqrt{1-a^2} \mathbf{b}_k \quad (2)$$

a 는 시간적 상관 계수이며, \mathbf{b}_k 는 평균이 0이고 시간상으로 독립적인 Gaussian 벡터이다. 공간적 상관관계는 아래와 같이 정의된다.

$$\mathbf{R}_h = E[\mathbf{h}_k \mathbf{h}_k^H] \quad (3)$$

\mathbf{R}_h 는 채널 벡터 \mathbf{h}_k 의 공분산 행렬이고 모든 k 에 대해 $\mathbf{R}_h = \mathbf{R}_h$ 를 만족한다. 공분산 행렬 정보는 매우 천천히 변하기 때문에 무시할 만한 오버헤드만으로 송신 단과 수신 단이 \mathbf{R}_h 를 모두 알고 있다고 가정한다.

송신 단과 수신 단 사이의 트레이닝 및 데이터 신호의 전송은 블록 단위로 이루어 지고 블록 시간은 채널의 coherence 시간에 의해 결정 된다. 한 블록은 그림 1과 같이 총 M 개의 심볼로 이루어져 있으며, 이 중 M_p 개는 트레이닝 심볼을, M_d 개는 데이터 심볼을 전송 하는데 사용된다. 이들 심볼은 한 블록 내에서 연속적




그림 1. 트레이닝 및 데이터 심볼 구성도
Fig. 1. Training and data symbol block configuration

으로 전송된다. 트레이닝 심볼을 통해 수신 단에서 추정된 채널은 상향 링크를 통해 송신 단으로 피드백 되어 데이터 심볼 전송 시 프리코딩 기법을 적용하는 데 사용된다. 실제의 시스템에서는 제한된 채널 용량 등의 요인으로 인해 피드백 과정에서 추가적인 오류가 발생할 수 있지만⁸⁾, 본 논문에서는 오류가 없는 피드백 채널을 가정하고 채널 추정 문제만을 다룬다. 또한, 프리코딩 기법으로는 zero-forcing (ZF) 기법이 활용된다.

III. 채널 추정 기법

이 장에서는 massive MIMO 시스템에서 효율적으로 채널 추정을 하기 위한 알고리즘을 제안한다. 적응 신호처리 기법의 일종인 칼만 필터와 nLMS 필터를 이용한 방식이며, 두 가지 알고리즘을 제안한다. 먼저 칼만 필터와 nLMS 필터를 시간 분할하여 이용하는 하이브리드 채널 추정 방식을 소개한다. 이 방식을 이용하면 채널 추정을 수행할 때 필요한 시간 지연을 효과적으로 줄일 수 있어 실시간 채널 추정이 가능해진다. 계산 복잡도는 기존의 칼만 필터만 이용하는 방식과 비교했을 때 약간 증가하지만, nLMS 필터의 계산 복잡도가 칼만 필터의 계산 복잡도 보다 훨씬 작기 때문에 전체 증가율은 미미한 수준이다. 두 번째는 데이터 전송 구간 동안 추가로 채널 추정을 수행하여 트레이닝 구간 동안 완료된 채널 추정 결과를 업데이트 할 수 있는 DFB nLMS 방식이다. 이 방식은 데이터 전송 구간 동안 성공적으로 복호된 심볼을 트레이닝 신호처럼 이용하여 채널 추정을 수행한다. 이 알고리즘은 기존의 nLMS 알고리즘과 비교하여 매우 적은 계산 복잡도 증가로 성능을 크게 향상시킬 수 있다.

3.1 하이브리드 채널 추정

식 (1)에 표현된 k 번째 심볼 타임에 수신되는 신호는 아래와 같이 다시 표현할 수 있다.

$$y_k = \mathbf{x}_k^H \mathbf{h}_k + n_k^* \quad (4)$$

이 경우 식 (2)와 (4)는 state-space 모델을 형성하고 최적의 채널 추적 기법은 식 (5)-(8)에 표현된 칼만 필터를 이용하는 것이 된다⁵⁾.

$$\mathbf{K}_k = \mathbf{P}_{k|k-1} \mathbf{x}_k (\mathbf{x}_k^H \mathbf{P}_{k|k-1} \mathbf{x}_k + \sigma_n^2)^{-1}, \quad (5)$$

$$\hat{\mathbf{h}}_{k|k} = \hat{\mathbf{h}}_{k|k-1} + \mathbf{K}_k (y_k^* - \mathbf{x}_k^H \hat{\mathbf{h}}_{k|k-1}), \quad (6)$$

$$\mathbf{P}_{k|k} = \mathbf{P}_{k|k-1} - \mathbf{K}_k \mathbf{x}_k^H \mathbf{P}_{k|k-1}, \quad (7)$$

$$\mathbf{P}_{k+1|k} = a^2 \mathbf{P}_{k|k} + (1 - a^2) \mathbf{R}_h, \quad (8)$$

$\hat{\mathbf{h}}_{k|k}$ 는 추정된 $N_t \times 1$ 채널 벡터, $\mathbf{P}_{k|k}$ 와 $\mathbf{P}_{k+1|k}$ 는 각각 추정 오차와 예측 오차의 공분산 행렬, 그리고 \mathbf{K}_k 는 칼만 이득이다. 초기값은 $\hat{\mathbf{h}}_{k|k} = 0$ 과 $\mathbf{P}_{1|0} = \mathbf{R}_h$ 이다.

식 (5)-(8)에서 알 수 있듯이, 칼만 필터는 \mathbf{P} , \mathbf{R}_h 와 같은 행렬 연산들로 이루어져 있다. Massive MIMO 시스템에서 기지국은 무수히 많은 개수의 안테나를 가지고 있기 때문에 이런 행렬의 크기는 매우 커진다. 칼만 필터를 사용하면 행렬 연산이 매우 큰 계산 복잡도를 가지기 때문에, 그림 1 처럼 트레이닝 심볼이 연속적으로 전송되는 시스템에서 현재 트레이닝 심볼의 채널 추정은 다음 트레이닝 심볼이 수신되기 전에 완료될 수 없다. 그러므로 실시간 채널 추정을 위해 칼만 필터에 nLMS 필터를 추가로 사용하는 방식을 제안한다.

트레이닝 심볼은 그림 2 처럼 각 블록의 가장 첫 트레이닝 심볼과 나머지 트레이닝 심볼로 구별될 수 있다. 각 블록의 첫 번째 트레이닝 심볼의 채널 추정은 그 전 블록의 마지막 트레이닝 심볼의 채널 추정 결과를 이용한다. 두 번째부터 마지막 트레이닝 심볼의 채널 추정은 같은 블록 내의 바로 전 트레이닝 심볼의 채널 추정 결과를 이용한다. 각 블록의 첫 트레이닝 심볼의 채널 추정은 그 전 블록에서 채널 추정을 완료하고 데이터를 전송하는 시간만큼 여유가 있다. 이것을 이용하여 첫 번째 트레이닝 심볼의 채널 추정은 칼만 필터를 이용하고, 나머지 트레이닝 심볼의 채




그림 2. 하이브리드 채널 추정의 심볼 구성도
Fig. 2. Block configuration of hybrid channel estimation

널 추정에는 nLMS 필터를 이용하는 기법을 제안한다. 수신 단에서는 다음 블록에 어떤 트레이닝 심볼이 전송될 지 이미 알고 있기 때문에, 식 (7)과 (8) 그리고 식 (5)에서 σ_n^2 를 제외한 나머지 부분은 현재 블록의 데이터 심볼이 전송되는 구간 동안 미리 계산이 가능하고, 다음 블록의 첫 번째 트레이닝 심볼이 도착했을 때 벡터 연산만이 남게 된다. 두 번째부터 나머지 트레이닝 심볼은 nLMS 필터를 이용하여 채널 추정을 하게 되므로 트레이닝 심볼이 전송되는 동안 전체 채널 추정은 벡터 연산으로만 이루어져 실시간 채널 추정이 가능하다. nLMS 필터를 이용한 채널 추정은 아래와 같다⁹⁾.

$$\hat{y}_k = \mathbf{x}_k^H \hat{\mathbf{h}}_{k-1}, \quad (9)$$

$$e_k = y_k - \hat{y}_k, \quad (10)$$

$$\hat{\mathbf{h}}_k = \hat{\mathbf{h}}_{k-1} + \mu e_k \mathbf{x}_k / \|\mathbf{x}_k\|^2 \quad (11)$$

$\hat{\mathbf{h}}_{k-1}$ 은 식(6)의 $\hat{\mathbf{h}}_{k|k}$ 이고, \hat{y}_k 는 추정된 수신 신호, e_k 는 추정된 채널 오차, μ 는 스텝 크기, 그리고 $\|\cdot\|_2$ 은 Euclidean norm 이다.

nLMS로 채널 추정을 완료 하고 다음 블록에서 칼만 필터로 채널 추정을 하기 위해서는 nLMS 필터로는 계산할 수 없는 $P_{k|k-1}$ 행렬 값이 필요하다. 이 경우 $P_{k|k-1}$ 값은 아래와 같이 계산한다⁹⁾.

$$P_{k|k-i} = a^{2i} P_{k-i|k-i} + (1 - a^{2i}) R_h \quad (12)$$

i 는 그림2에 나타난 것과 같이 전 블록의 칼만 필터 계산으로부터 다음 블록 칼만 필터 계산까지의 심볼 개수이다.

3.2 Decision Feedback nLMS 채널 추정

DFB nLMS 필터는 복호된 데이터 심볼을 트레이닝 심볼처럼 이용하여 데이터 전송 구간 동안 추가로 채널 추정을 하는 방식이다. 수신 단에서 이 알고리즘을 이용하여 채널 벡터를 업데이트 하고 이를 송신 단으로 피드백 하면 데이터 심볼을 전송하는 데 필요한 프리코딩 벡터도 또한 업데이트 될 수 있다. 일반적으로 이런 알고리즘은 다중 경로나 도플러 스프레드에 의한 신호의 왜곡을 보상해 주기 위한 equalizer에 주로 사용된다. 그림 3에 DFB nLMS를 이용한 채널 추정의 블록도를 나타내었다. DFB 알고리즘이




그림 3. DFB nLMS 채널 추정의 블록 구성도
Fig. 3. Block diagram of DFB nLMS channel estimator

equalizer에 이용되는 경우에는 필터 계수를 업데이트 하기 위한 추가적인 피드백 필터가 필요하지만, 제안하는 채널 추정 알고리즘의 경우에는 이미 존재하고 있는 nLMS 필터의 계수를 업데이트 하는 데 사용하기 때문에 추가적인 피드백 필터가 필요하지 않다.

이 알고리즘을 사용할 때 발생할 수 있는 문제 중 하나는 DFB 방식으로 인한 채널 추정 오차의 전달이다. 이 문제를 방지하기 위해 cyclic redundancy check (CRC) 코드를 사용할 수 있다. 수신 된 데이터를 복호한 후, 이 데이터가 올바르게 복호된 것인지를 판단하기 위해 CRC 코드를 이용한다. 데이터가 올바르게 복호된 경우, 이 데이터는 추가로 채널 추정을 하기 위해 사용되고, 올바르게 안게 복호된 경우 추가로 채널 추정을 하지 않고 그 전에 추정 된 채널을 유지한다. 그러므로 정확하지 않은 채널 정보를 가지고 있는 초기에는 복호된 데이터가 틀릴 확률이 높으므로 DFB nLMS 알고리즘은 거의 동작하지 않을 수 있다. 실제 시스템에서 송수신 데이터는 패킷 단위로 이루어 질 것이다. 이 경우, CRC는 한 패킷의 마지막에 한 번만 하는 것이 일반적이므로, 중간에 올바르게 복호되지 않은 데이터를 바로 감지할 수는 없다. 데이터가 잘 못 복호 되었다면 DFB 방식을 이용하여 추정 한 채널은 오차가 생길 것이고, 이것은 다시 다음 복호 될 데이터에 영향을 준다. 그러나 전체 패킷 중 한 bit라도 오류가 나면 CRC코드에서 오류가 나게 될 것이고 해당 패킷은 버려진다. 채널 정보 역시 오류가 생긴 패킷에서 추정 한 채널은 버리고 그 이전 채널 정보를 유지한다.

또 다른 문제 중 하나는 데이터 구간 동안 업데이트 되는 채널 정보로 인해 수신 단에서 송신 단으로의 채널 정보 피드백 점유가 높아지는 것이다. 이 문제는 매 심볼마다 피드백을 하는 대신 한 블록에 한번 채널 정보를 피드백 하는 것으로 문제를 해결 할 수 있다. 그러나 이 경우 가장 최근에 추정된 채널을 이용할 수 없어 성능이 약간 저하될 수 있다.

제안하는 DFB nLMS 알고리즘의 전체 과정은 아

래와 같다.

Step 1: 초기화

$$\hat{\mathbf{h}}_0 = \mathbf{0}$$

Step 2: 트레이닝 심볼을 이용한 nLMS 채널 추정

$$\hat{y}_k = \hat{\mathbf{h}}_{k-1}^H \mathbf{x}_k$$

$$e_k = y_k - \hat{y}_k$$

Step 3: 수신 데이터 복호 및 CRC 검사

복호된 데이터 \hat{s}_k 가 올바른 경우 ZF 프리코딩 벡터 \mathbf{w}_k 를 생성하여 복호된 데이터에 곱하여 송신 단에서 전송했을 데이터를 생성

$$\hat{\mathbf{x}}_k = \mathbf{w}_k \hat{s}_k$$

Step 4: 데이터 심볼에서 DFB LMS 채널 추정

Step 2의 \mathbf{x}_k 에 $\hat{\mathbf{x}}_k$ 대입, 채널 추정

3.3 계산 복잡도 비교

본 장에서는 기존의 알고리즘과 제안한 알고리즘의 계산 복잡도를 비교한다. 일반적으로 계산 복잡도를 나타내는 지표로 많이 이용되는 곱셈기와 덧셈기의 개수를 비교하였다. N_t 개의 송신 안테나와 한 개의 수신 안테나로 이루어진 시스템의 경우 추정해야 하는 채널 행렬은 $N_t \times 1$ 이다. 그러므로 식 (5)-(8), 그리고 식 (11)에 포함 된 모든 벡터의 크기는 $N_t \times 1$ 이고, 모든 행렬의 크기는 $N_t \times N_t$ 이다.

표 1에 기존 알고리즘과 제안한 알고리즘의 곱셈기와 덧셈기 개수가 비교되어 있다. 곱셈기는 실제 복소수 곱셈기이며, 식(8)의 곱셈은 정해진 임의의 상수 a 를 곱하는 상수 곱이기 때문에 제외되었다. 표 1에서 보는 것과 같이 하이브리드 알고리즘의 계산 복잡도는 기존의 칼만 필터에 비해 약 10% 증가되었고, DFB nLMS의 경우는 nLMS에 비해 약 3% 증가되었다. 기존 알고리즘들과 비교하여 약간의 계산 복잡도 증가로 실시간 채널 추정이 가능하며, 채널 추정의 성능도 향상시킬 수 있다. 성능 향상의 결과는 4장에서

표 1. 제안 알고리즘의 계산 복잡도
Table 1. Number of operations for proposed algorithms

	Multiplier		Adder	
Kalman	$3(N_t2+N_t)$	100%	$3N_t2$	100%
nLMS	$3N_t$	9%	$3N_t-1$	10%
Hybrid	$3(N_t2+2N_t)$	109%	$3(N_t2+N_t)-1$	110%
DFB nLMS	$4N_t$	12%	$4N_t-2$	13%

볼 수 있다.

IV. 모의 실험

제안된 채널 추정 기법의 성능을 확인하기 위하여 모의 실험을 진행하였다. 성능 비교를 위해 mean square error (MSE)와 bit error rate (BER)가 이용되었으며, 1000회의 독립적인 채널 생성을 통해 얻은 결과이다.

4.1 실험 환경

32개의 송신 안테나와 한 개의 수신 안테나로 이루어진 MISO 환경이다. 각 블록은 10개의 연속적으로 전송되는 심볼로 이루어져 있고 그 중 4개는 트레이닝 신호, 6개는 데이터 신호이다. 즉 $M=10$, $M_p=4$, $M_d=6$ 이다. 반송파 주파수는 2.5GHz이고 한 심볼은 100 μ s이다. 속도는 3km/h와 130km/h 두 가지를 이용하였으며, 이 속도는 각각 사람이 걷는 속도와 차량이 움직이는 속도를 나타낸다. 식(2)의 시간적 상관 계수 a 는 $a = J_0(2\pi f_D T_s)$ 와 같이 계산 할 수 있으며, 앞의 두 속도를 이용하면 a 는 각각 0.9999와 0.99가 된다. 채널의 공간적 상관 계수는 quadratic exponential correlation 모델로 정의할 수 있으며^[7], 아래와 같이 표현할 수 있다.

$$[\mathbf{R}_h]_{i,j} = r^{|i-j|^2} \tag{13}$$

여기서, $|r|=0.8$ 이며, \mathbf{R}_h 는 정규화 된 것으로 $\text{tr}(\mathbf{R}_h)=N_t$ 이다. MSE 성능 비교를 위해서 SNR은 20dB로 설정 되었으며, BER 성능 비교를 위해 binary phase shift keying (BPSK) 변조 방식을 이용하였다. nLMS 채널 추정 방식에 사용되는 스텝 크기 μ 는 0.2로 설정 되었다.

성능 비교를 위한 트레이닝 심볼 생성에는 직교 트레이닝 심볼과 eigen 값을 이용한 트레이닝 심볼 생성의 두 가지 방법을 사용하였다. 직교 트레이닝 심볼은 Gram-Schmidt 직교화 방식으로 orthonormal basis를 생성하여 트레이닝 심볼로 이용하였다. Eigen 값을 이용한 트레이닝 심볼은 채널 공분산 행렬의 M_p 개의 가장 큰 eigen 값을 이용하여 생성된다. \mathbf{R}_h 를 eigen decomposition 하여 M_p 개의 가장 큰 eigen 값을 선택한다. 이 eigen 값의 인덱스를 가지는 \mathbf{R}_h 의 unitary 행렬의 열 벡터들을 트레이닝 심볼로 이용하는 것이 eigen 값을 이용한 트레이닝 심볼이다^[7].

송신 단에서는 ZF 프리코딩 기법을 이용한다. 본 논문에서 고려하는 시스템은 단일 안테나를 가지는 단일 사용자의 경우이므로 채널 행렬은 벡터가 된다. 그러므로 송신 단에서 프리코딩 벡터는 아래와 같다 [10].

$$\mathbf{w}_k = \hat{\mathbf{h}}_k / \|\hat{\mathbf{h}}_k\|_2 \quad (14)$$

$\|\cdot\|_2$ 는 L2-norm을 나타낸다.

4.2 MSE 성능 비교

먼저, 기존의 알고리즘과 제안한 알고리즘의 MSE 성능을 비교하였다. MSE 성능을 비교하기 위한 지표로 수렴 속도와 잔류 오차를 이용할 수 있다. 직교 트레이닝 심볼을 이용하든, eigen 값을 이용한 트레이닝 심볼을 이용하든 상관 없이 모든 알고리즘에서 수렴 심볼 후 수렴하였고, 수렴한 이후 잔류 오차는 거의 비슷해졌다. 그림 4와 그림 5에서 MSE 성능 비교를 볼 수 있다. 직교 트레이닝 심볼을 이용하는 경우, 제안한 하이브리드 채널 추정 알고리즘의 성능이 기존의 nLMS 알고리즘에 비해 매우 향상된 반면, DFB nLMS 채널 추정 알고리즘의 성능은 기존 nLMS 알고리즘에 비해 약간 향상된 데에 그쳤다. 그러나 DFB nLMS 알고리즘이 아주 약간의 계산 복잡도 증가로 기존의 nLMS 알고리즘에 비해 성능을 향상시켰으므로 이 정도의 성능 향상도 의미가 있다고 볼 수 있다.

Eigen 값을 이용한 트레이닝 심볼로 채널 추정을 한 경우, 직교 트레이닝 심볼을 이용한 것과는 다르게 DFB nLMS 알고리즘을 이용한 방식이 하이브리드




그림 4. 직교 트레이닝 심볼을 이용하는 경우의 MSE 성능 비교 ($v=3km/h$)
Fig. 4. MSE performance comparison using orthogonal training sequence ($v=3km/h$)

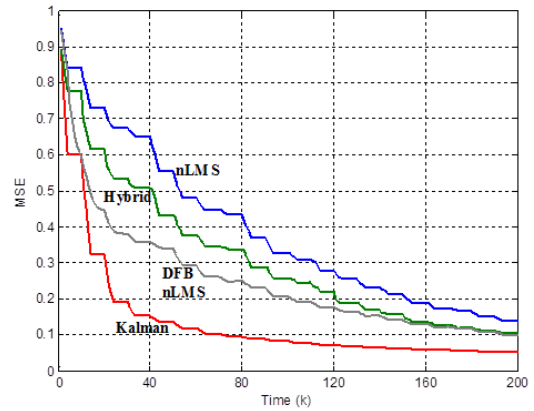


그림 5. Eigen 트레이닝 심볼을 이용하는 경우의 MSE 성능 비교 ($v=3km/h$)
Fig. 5. MSE performance comparison using Eigen training sequence ($v=3km/h$)

알고리즘을 이용한 것보다 성능이 좋은 것을 볼 수 있다. 이것은 4.3절에서 보게 될 BER 성능과 관계가 있는데, eigen 값을 이용한 트레이닝 심볼을 이용하면 직교 트레이닝 신호를 이용하는 것 보다 BER 성능이 좋아진다. 따라서 신호가 올바르게 복호 될 확률이 높아 지고, DFB nLMS 알고리즘을 적용할 기회가 직교 트레이닝 신호를 이용하는 경우보다 많아진다. 직교 트레이닝 신호를 이용하는 경우, 채널 추정 초기에 데이터 신호를 복호 하면서 발생하는 CRC 에러가 증가하기 때문에 DFB 기법이 적용될 기회가 감소하고 이로 인해 DFB 이득을 제대로 얻을 수 없게 된다.

4.3 BER 성능 비교

이 절에서는 기존 알고리즘과 제안하는 알고리즘의 BER 성능을 비교한다. 이 절의 모든 그림은 채널 추정이 어느 정도 수렴 한 이후의 BER을 나타낸다. 그림 6과 그림 7은 시간적 상관 계수 a 가 0.9999, 즉 $v=3km/h$ 인 경우의 BER이다. 이 조건은 채널이 시간 영역에서 큰 상관 관계를 가지는 것을 뜻한다. 이 두 실험에서 BER은 어떤 채널 추정 알고리즘을 이용하더라도 비슷한 성능을 보인다. 한 가지 짚고 넘어갈 점은 DFB nLMS 알고리즘을 이용하는 경우 nLMS 알고리즘을 이용하는 것 보다 BER 성능이 나쁘다는 것이다. 그림 6, 7에서 보는 것과 같이 시간 상관 관계가 매우 큰 채널 환경은 낮은 SNR 영역에서 성능을 평가 하였다. 이러한 낮은 SNR 영역에서는 오히려 DFB nLMS가 채널 정보를 잘못된 방향으로 유도 할 수 있으므로 성능이 낮아질 수 있다.

다음으로 시간적 상관 계수 a 가 0.99인 경우의

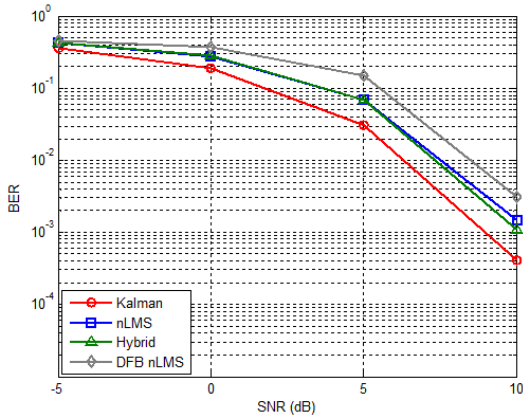


Fig. 6. BER performance comparison using orthogonal training sequence ($v=3km/h$)
 그림 6. 직교 트레이닝 심볼을 이용하는 경우의 BER 성능 비교 ($v=3km/h$)




Fig. 8. BER performance comparison using orthogonal training sequence ($v=130km/h$)
 그림 8. 직교 트레이닝 심볼을 이용하는 경우의 BER 성능 비교 ($v=130km/h$)




그림 7. Eigen 트레이닝 심볼을 이용하는 경우의 BER 성능 비교 ($v=3km/h$)
 Fig. 7. BER performance comparison using Eigen training sequence ($v=3km/h$)




Fig. 9. BER performance comparison using Eigen training sequence ($v=130km/h$)
 그림 9. Eigen 트레이닝 심볼을 이용하는 경우의 BER 성능 비교 ($v=130km/h$)

BER을 비교하였다. 이것은 $v=130km/h$ 이고, 채널이 시간 영역에서 상관 관계가 작은 것을 의미한다. 그림 8과 그림9에서 보는 것과 같이 기존의 nLMS 채널 추정 알고리즘과 비교했을 때 제안한 두 알고리즘을 이용하는 경우 성능이 향상되는 것을 볼 수 있다. 직교 트레이닝 심볼을 이용하는 경우, BER 10^{-2} 에서 하이브리드 알고리즘을 이용하여 약 3.5dB, DFB nLMS 알고리즘을 이용하여 약 6.5dB의 성능이 향상되었고 그림 8에서 이를 확인할 수 있다. Eigen 트레이닝 심볼을 이용하는 경우에도 성능이 비슷한 경향을 보이는 것을 확인할 수 있다. BER 10^{-3} 에서 각각 2.5dB와 5dB가 향상되었다.

Eigen 트레이닝 심볼을 이용하면 직교 트레이닝 심

볼을 이용하는 것 보다 모든 채널 추정 알고리즘에서 성능이 향상되는 것을 볼 수 있다. 그러나 eigen 트레이닝 심볼을 생성하는 것이 직교 트레이닝 심볼을 생성하는 것 보다 계산 복잡도가 높기 때문에, 성능과 계산 복잡도 사이의 trade-off가 발생한다.

보다 실제적인 환경에서 제안한 알고리즘을 사용할 수 있는지 파악하기 위해 M_p 와 M_d 를 변화시킨 후 BER 성능을 비교해 보았다. 이 경우 트레이닝 심볼은 eigen 트레이닝 심볼을 이용하였고, 시간 상관계수 a 는 0.99로 $v=130km/h$ 에 해당한다. 그림 10에서 실험 결과를 확인할 수 있다. 그림 9와 비교 했을 때 트레이닝 심볼의 오버헤드는 절반으로 줄었고, 대신 BER 10^{-3} 에서 칼만 필터를 사용한 경우 약 3.5dB, DFB




Fig. 10. BER performance comparison using Eigen training sequence($v=130\text{km/h}$)
 그림 10. Eigen 트레이닝 심볼을 이용하는 경우의 BER 성능 비교 with $M_p=2$ ($v=130\text{km/h}$)

nLMS를 사용할 경우 약 4dB 성능 열화가 있는 것을 확인 할 수 있다. 그러나 트레이닝 심볼의 오버헤드가 줄었을 때 DFB nLMS가 칼만 필터의 성능에 더 근접한 것을 볼 수 있다.

V. 결론

본 논문에서는 FDD기반의 massive MIMO 시스템에서 채널이 시간적, 공간적으로 상관 관계가 있는 모델을 위한 두 가지 채널 추정 기법이 제안되었다.

첫 번째로 제안된 기법은 연속된 트레이닝 심볼이 전송되어 실시간으로 채널을 추정을 완료해야 하는 경우, 칼만 필터와 nLMS 필터를 시간 영역에서 분할 이용하여 칼만 필터만으로 채널 추정을 하는 경우 발생하는 행렬 연산의 처리 지연을 줄이도록 하는 하이브리드 방식이다. 이 알고리즘은 약간의 계산 복잡도 증가로 실시간 채널 추정을 가능하도록 하였다.

References

[1] T. L. Marzetta, "Noncooperative cellular wireless with unlimited number of base station antennas," *IEEE Trans. Wirel. Commun.*, vol. 9, no. 11, pp. 3590-3600, Nov. 2010.
 [2] F. Rusek, D. Persson, B. K. Lau, E. G. Larsson, and T. L. Marzetta, "Scaling up MIMO: Opportunities and challenges with very large arrays," *IEEE Signal Process. Mag.*, vol. 30, no. 1, pp. 40-60, Jan. 2013.

[3] B. Shim and B. Lee, "Evolution of MIMO technology," *J. KICS*, vol. 38A, no. 8, pp. 712-723, Aug. 2013.
 [4] J. Hoydis, S. ten Brink, and M. Debbah, "Massive MIMO in the UL/DL of cellular networks: How many antennas do we need?," *IEEE J. Sel. Areas Commun.*, vol. 31, no. 2, pp. 160-171, Feb. 2013.
 [5] T. Kailath, A. H. Sayed, and B. Hassibi, *Linear Estimation*, PrenticeHall, Upper Saddle River, New Jersey, 2000.
 [6] J. Jang, J. Kim, and C. Moon, "Analysis of massive MIMO wireless channel characteristics," *J. KICS*, vol. 38B, no. 3, pp. 216-221, Mar. 2013.
 [7] S. Noh, M. D. Zoltowski, Y. Sung, and D. J. Love, "Optimal pilot beam pattern design for massive MIMO systems," in *Proc. IEEE ASILOMAR*, Pacific Grove, CA, Nov. 2013.
 [8] I. Choi, H. Noh, and C. Lee, "A codebook generation and search scheme for FDD downlink massive MIMO," *J. KICS*, vol. 38A, no. 8, pp. 704-711, Aug. 2013.
 [9] S. Haykin, *Adaptive Filter Theory*, PrenticeHall, Upper Saddle River, New Jersey, 2002.
 [10] Q. H. Spencer, A. L. Swindlehurst, and M. Haardt, "Zero-forcing methods for downlink spatial multiplexing in multiuser MIMO channels," *IEEE Trans. Signal Process.*, vol. 52, pp. 461-471, Feb. 2004.

정진주 (Jinjoo Chung)



2006년 : 이화여자대학교 정보통신학과 학사
 2013년 : 서울대학교 전기·정보공학부 석사
 2006년~현재 : 삼성전자 책임연구원
 <관심분야> 무선랜, 차세대 이동통신

한 용 희 (Yonghee Han)



2011년 : 서울대학교 전기공학
학사
2011년~현재 : 서울대학교 전기·
정보공학부 석박통합과정
<관심분야> Massive MIMO,
Interference Alignment

이 정 우 (Jungwoo Lee)



1988년 : 서울대학교 전기공학
학사
1990년 : Princeton대학교 전기
공학 석사
1994년 : Princeton대학교 전기
공학 박사
2002년~현재 : 서울대학교 전기·
정보공학부 교수
<관심분야> 무선 신호처리, Big Data, 차세대 이동
통신