

# RF 전력 증폭기 메모리 효과의 효율적인 측정과 모델링 기법

## Effective Measurement and modeling of memory effects in Power Amplifier

김 원 호\* • 황 보 훈\*\* • 나 완 수\*\*\* • 박 천 석\*\*\* • 김 병 성\*\*\*  
(Won-Ho Kim • Hoon Hwangbo • Wansoo Nah • Cheon-Seok Park • Byung-Sung Kim)

**Abstract** - In this paper, we identify the memory effect of high power(125W) laterally diffused metal oxide-semiconductor(LDMOS) RF Power Amplifier(PA) by two tone IMD measurement. We measure two tone IMD by changing the tone spacing and the power level. Different asymmetric IMD is founded at different center frequency measurements. We propose the Tapped Delay Line-Neural Network(TDNN) technique as the modeling method of LDMOS PA based on two tone IMD data. TDNN's modeling accuracy is highly reasonable compared to the memoryless adaptive modeling method.

**Key Words** : Memory Effect, Asymmetries, Intermodulation Distortion(IMD), Neural Network(NN), Power Amplifier

### 1. 장 서 론

기지국의 전력 증폭기 선형화를 위하여 지금까지 많은 연구가 수행되었다.[1],[2] 그 방식으로는 크게 아날로그 방식과 디지털 방식으로 나눌 수 있다. 요즘도 아날로그적인 방식으로 선형화하는 기법들이 소개되고 있지만 아날로그 방식은 효율이 낮으며 단가가 높은 단점이 있다. 더구나 최근의 WCDMA 나 CDMA-2000[3] 과 같은 광 대역, 고 출력 시스템에서 발생하는 메모리 효과[4-7]를 보상하기에는 한계가 있다. 그렇지만 A/D, D/A 변환기의 성능개선으로 인하여 디지털 신호처리 기법[8]으로 메모리 효과를 모델링하고 보상하기 위한 노력들이 다양하게 수행되고 있다. 전력증폭기의 효과적인 메모리 효과 보상을 위해서는 정확한 메모리 효과의 모델링이 필요하다. 지금까지의 디지털 메모리 효과 모델링 기법으로는 Memory Polynomial 방식[9],[10], NTDL(Nonlinear Tapped Delay Line)방식[11-15], Wiener[16],[17] 모델등이 있다. 최근에는 NTDL 기법이 다른 모델링 방식과 복합되어 우수한 모델링 특성을 보이고 있다. 그 일례로 NTDL 기법과 sparse delay tap 을 이용하여 Wiener 합수를 모델링 한 논문[18]이 나왔으며 NTDL 기법과 Neural Network(NN)[19] 방식을 혼용한 모델링 논문[20]이 나왔다. 본 논문에서는 NTDL 기법과 NN 기법을 two-tone IMD 모델링에 적용하였다. 본 논문의 구성은 2장에서 IMD 모델링을 위한 측정과정을 다루고 있으며 IMD의 비대칭성을 통하여 메모리 효과의 실체를 보였고 3장에서는 측정된 IMD를 4가지 다른

방식을 이용하여 Behavioral 모델링을 하며 4장에서 본 연구의 결론을 맺는다.

### 2. 장 IMD 측정

IMD 측정을 위해 모토롤라사의 MRF21125 트랜지스터(Class AB, 125W PEP, LDMOS)를 사용하여 그림 1에 보이는 PA를 설계, 제작하였다.

출력전력이 46dBm(40W Ave.)인 지점(P1dB point)을 기준으로 입력신호를 중심주파수 2.117 GHz와 2.14 GHz에서 각각 2-tone 간격을 1MHz부터 5MHz까지 1MHz씩 변화를 주면서 스펙트럼을 통해 IMD를 관찰하였다. 같은 과정을 출력전력이 43dBm(20W Ave.)인 지점(3dB back off point)에서 반복했다.

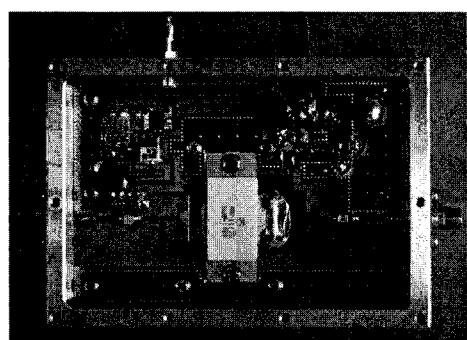


그림 1. 실험에 쓰인 125W 전력 증폭기의 외관

#### 저자 소개

- \* 學生會員 : 成均館大學交 情報通信工學部 碩士課程
- \*\* 學生會員 : 成均館大學交 情報通信工學部 博士課程
- \*\*\* 正會員 : 成均館大學交 情報通信工學部 教授 · 工博

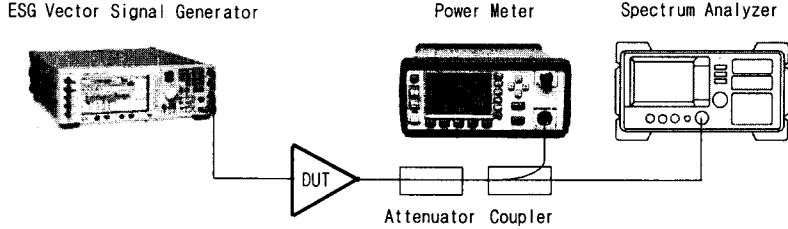


그림 2. 전체 시스템 구성

전체적인 시스템 구성을 그림 2에 나타내었고 IMD 측정결과를 그림 3에 나타내었다. tone 간격을 변화함에 따라서 비대칭성이 관측되었으며 Pout을 바꾸었을 때도 역시 비대칭성이 관측되었다. 중심 주파수를 바꾸어 주었을 때는 확연히 다른 비대칭 특성이 보였다. 이 실험결과는 전력증폭기의 IMD 특성이 tone 간격과 Pout, 중심주파수에 따라서 메모리 효과의 영향을 받는다는 것을 직접적으로 증명하고 있다.[5] IMD와 tone 간격, Pout의 상관관계를 그림 4에 나타내었다.

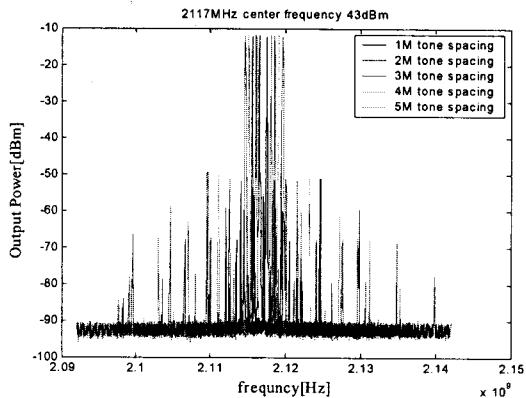


그림 3. tone 간격 변화에 따른 전체 스펙트럼의 분포

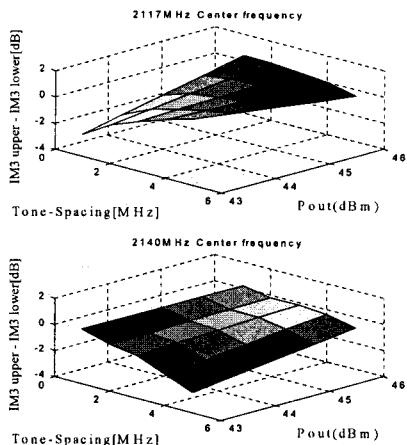


그림 4. tone 간격과 Pout변화에 따른  
IMD의 비대칭 양상

### 3. 장 Behavioral 모델링

전력증폭기의 정확한 모델링을 위해서 최근에 부각되고 있는 기술은 TDL방식과 NN방식이다. 가장 최근에는 이를 복합시킨 TDNN 방식이 나왔다. 본 논문에서는 이 TDNN 방식을 two tone IMD 특성을 모델링 하는 기본 방식으로 채택하였으며 이를 Polynomial 모델링, Non-adaptive Least Mean Square(LMS) 모델링, Adaptive LMS 모델링[21]과 비교 분석하였다. NN 방식의 기본적인 원리는 전력증폭기의 입력과 출력이 주어졌을 때 전력증폭기의 전달함수 특성을 neuron의 training을 통해서 학습하는 방식이다. 그럼에도 불구하고 NN만으로는 전력증폭기의 메모리 효과를 모델링 하는데 한계가 있다. 왜냐하면 메모리 효과라는 것이 기본적으로 과거의 입력이 현재의 출력에 영향을 미치는 것이기 때문이다. 그러므로 TDL 방식을 이용하여 이런 short term 메모리 효과를 모델링 할 필요가 있으며 long term 메모리 효과는 NN의 우수한 학습능력으로 모델링 해야 한다. TDNN의 전체 구조를 그림 5에 나타내었다.

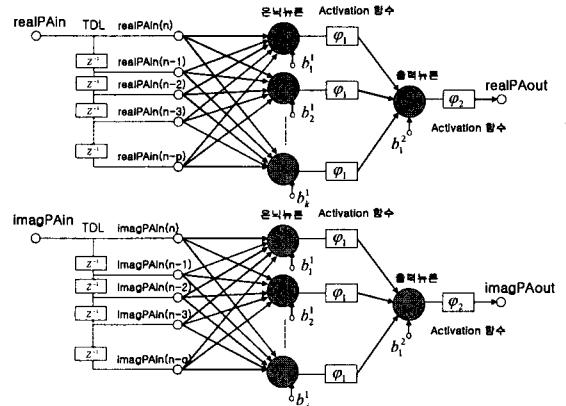


그림 5. TDNN의 전체 구조

본 논문에서 채택한 TDNN 모델링은 Baseband 테이터의 실수부와 허수부를 각기 모델링 하는 방식이며 다음 식과 같이 표현할 수 있다.

$$realPAout = \varphi_2 \left( \sum_{j=1}^k w_j \varphi_1 \left( \sum_{l=0}^y w_l (l) realPAin(n-l) + b_j^1 \right) + b_j^2 \right) \quad (1)$$

$$imagPAout = \varphi_2 \left( \sum_{j=1}^J w_j \varphi_1 \left( \sum_{l=0}^q w_l(l) imagPAin(n-l) + b_l^1 \right) + b_1^2 \right) \quad (2)$$

위 식에서  $\varphi_1, \varphi_2$  는 각각 첫 번째 은너충과 두 번째 은너충에 사용된 Activation 함수이다.  $\varphi_1$ 함수는 Hyperbolic tangent sigmoid 전달함수이며  $\varphi_2$  함수는 선형 전달함수로서 다음 식과 같이 표현된다.[19]

$$\varphi_1(x) = tanh(x) = \frac{1 - e^{-2x}}{1 + e^{-2x}} \quad (3)$$

$$\varphi_2(x) = \begin{cases} 1, & x \geq +\frac{1}{2} \\ x, & -\frac{1}{2} < x < +\frac{1}{2} \\ 0, & x \leq -\frac{1}{2} \end{cases} \quad (4)$$

본 논문에 쓰인 방법과 비교되는 시뮬레이션을 위하여 Polynomial 방식에는 12차까지의 근사방식을 택하였고 Non-adaptive 방식은 580개의 데이터 포인트를 사용하였다. 그리고 Adaptive 방식은 500개의 데이터를 취한 후 delta 값을 0.01로 주었다. TDNN의 시뮬레이션을 위해서 delay tap은 실수부와 허수부 모델링에 각각 20개를 주었고 은너뉴런의 개수는 5개를 취하였다. 시뮬레이션을 위한 데이터는 측정된 IMD를 ifft 변환하여 시간 영역으로 바꾼 후 모델링 하였고 다시 fft 변환하여 실제 데이터와 비교하였다. 정확한 모델링을 위해서는 IMD의 위상성분까지 고려하여야 하지만 본 논문에서는 IMD의 크기성분만 가지고 시뮬레이션 하였다. 전체 시뮬레이션 과정을 그림 6에 도시하였고 결과를 그림 7, 8에 나타내었다.

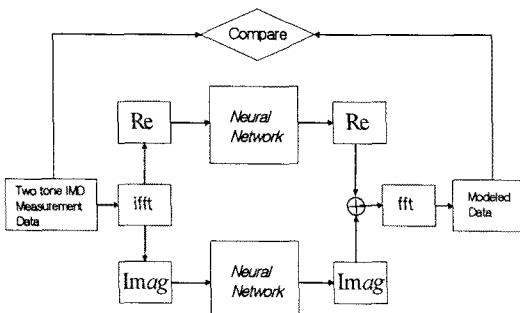


그림 6. 전체 시뮬레이션 Block Diagram

시뮬레이션 결과를 통하여 TDNN 방식이 다른 방식에 비해서 월등한 모델링 특성을 보임을 알 수 있다. Polynomial 방식은 IMD의 양상 자체를 따라가는데 실패하였고 LMS방식은 주파수까진 잘 모델링하지만 그 크기까지 모델링하는데 있어서는 좋은 결과를 보이지 못하고 있다. Adaptive LMS 방식은 LMS방식보다 나은 결과를 보이고 있지만 정확한 모델링에는 실패하였다.

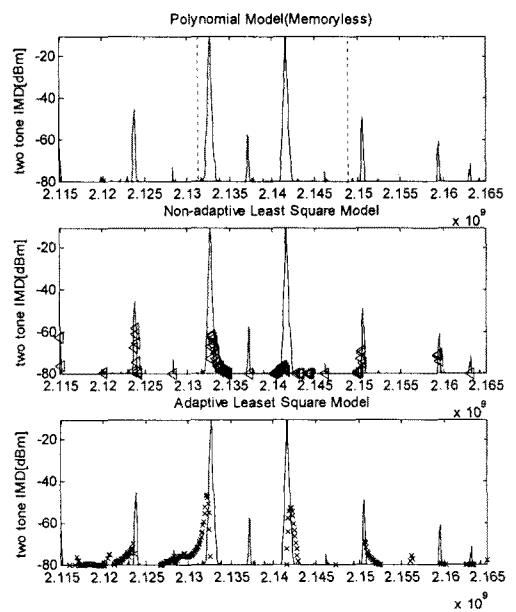


그림 7. Polynomial, LMS, Adaptive LMS의 시뮬레이션 결과 (실선:실제 데이터)

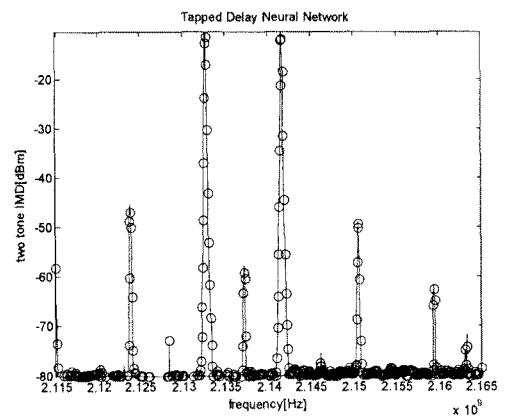


그림 8. 본 논문에 적용한 TDNN 시뮬레이션 결과

TDNN 방식은 전력증폭기의 전달특성을 neuron을 통해 학습한 모델링방식이기 때문에 입의의 신호에 대한 재현성 또한 우수하다. 더욱이 단지 20개의 delay tap을 가지고서도 정확한 모델링 결과를 도출하기 때문에 behavioral 방식의 전력증폭기 모델링 뿐만 아니라 다른 RF 소자들에서 발생하는 dynamic 비선형 현상 모델링에도 유용하게 쓰일 수 있을 것으로 사료된다.