

저주파 노이즈와 BTI의 머신 러닝 모델

김용우^{*} · 이종환^{*†}

^{*†} 상명대학교 시스템반도체공학과

Machine Learning Model for Low Frequency Noise and Bias Temperature Instability

Yongwoo Kim^{*} and Jonghwan Lee^{*†}

^{*†} Department of System Semiconductor Engineering, Sangmyung University

ABSTRACT

Based on the capture-emission energy (CEE) maps of CMOS devices, a physics-informed machine learning model for the bias temperature instability (BTI)-induced threshold voltage shifts and low frequency noise is presented. In order to incorporate physics theories into the machine learning model, the integration of artificial neural network (IANN) is employed for the computation of the threshold voltage shifts and low frequency noise. The model combines the computational efficiency of IANN with the optimal estimation of Gaussian mixture model (GMM) with soft clustering. It enables full lifetime prediction of BTI under various stress and recovery conditions and provides accurate prediction of the dynamic behavior of the original measured data.

Key Words : Capture-emission Energy Map, Bias Temperature Instability, Low Frequency Noise, Integration of Artificial Neural Network, Gaussian Mixture Model

1. 서 론

나노 스케일 CMOS 소자에서 결함(defects)의 확률적 동작은 소자 및 회로의 신뢰성에 상당한 영향을 끼친다 [1,2]. NBTI (negative bias temperature instability)는 가장 중요한 신뢰성 문제 중에 하나이며, 포획-방출 에너지 (CEE, capture-emission energy) 맵을 통해 표현될 수 있다 [1-5]. NBTI를 정확하게 모델링하려면 절저한 CEE 맵과 효율적인 모델을 포함하고 결합하는 방법론이 필요하다. 그러나, CEE 맵은 스트레스-회복(stress-recovery) 측정 범위에 의해 제한된다 [3-5]. CEE 분포 매개변수의 정확한 추정은 측정 시간의 외삽(extrapolation) 없이 NBTI의 전체 수명 계산을 가능하게 하는데 중요하다. NBTI의 원인이 되는 결함의 동적 특성은 게이트 산화물 트랩에 의한 전하 캐리어의 랜덤

포획-방출 과정에 의해 설명된다 [3-7]. 또한, NBTI의 회복 성분(recoverable component)과 RTS(random telegraph signal) 노이즈는 같은 결함에 의해 기인된다 [7,8]. 광범위하게 분포된 시간 또는 에너지 스케일을 가진 RTS의 이산적 변동(discrete fluctuation)은 나노 스케일 MOSFET에서 저주파 (1/f) 노이즈의 주요 원인이다 [8-11]. 저주파 노이즈 특성의 통계적 분석 및 엄밀한 모델링을 위하여 CEE 맵 기반의 결함 분포가 포함되어야 하며, 대신호 AC 동작 해석도 가능하게 한다 [10-12].

그러나, 수치 및 해석적 물리 기반의 BTI 모델은 각각 긴 계산 시간과 기술 의존적 매개변수 추출 방법이 필요하다 [12-17]. 수치 모델이 정확하고, 컴팩트 모델(compact model)이 SPICE 시뮬레이터에 바람직하지만, 각각 계산 비용이 많이 들고 높은 예측력을 얻기가 어렵다 [12-17]. 인공신경망 (ANN, artificial neural network)과 Gaussian 혼합 모델 (GMM, Gaussian mixture model)을 포함한 머신 러닝(ML,

[†]E-mail: jhlee77@smu.ac.kr

machine learning) 기술은 기존의 모델링에 효과적인 대안 접근 방법이며, BTI 기인한 문턱 전압 이동 ΔV_{th} (threshold voltage shift)과 저주파 노이즈의 비선형 특성에 대해 빠르고 정확한 근사화 방법을 제공한다 [18-27]. 그러나, 순수한 데이터 기반 ML 방법은 기본적인 물리적 프로세스에 대한 지식을 무시하기 때문에 BTI와 저주파 노이즈의 물리 기반 모델링과 결합해야 한다 [28]. 본 논문에서는 BTI 기인한 문턱 전압 이동과 저주파 노이즈에 대한 물리 기반 머신 러닝 모델을 제안한다. 제안한 모델은 측정 범위를 벗어난 소자를 예측하고 정확한 CEE 맵의 표현을 위해 ANN과 GMM을 결합한다.

2. BTI와 저주파 노이즈 이론

전하 캐리어의 포획-방출 (capture-emission) 과정은 선형 전자-포논 결합에 기반한 비복사 다중 포논 이론 (non-radiative multi-phonon theory)과 일치한다 [1]. 이 이론에서 포획-방출 시간은 다음과 같다.

$$\tau_{c,e}(E_c) = \tau_0 \exp(E_{c,e}/k_b T) \quad (1)$$

여기서 τ_0 은 온도 독립 인자, k_b 는 Boltzmann 상수, T 는 온도, E_c 와 E_e 는 포획과 방출 활성화 에너지이다. BTI 유도 문턱 전압 이동 ΔV_{th} 는 특성 시간상수의 광범위한 분포를 가진 개별 결함 (defects)의 포획-방출 과정과 관련이 있다. 이 분포는 CEE 맵에서 시각화 될 수 있으며, CEE 맵은 $D(\tau_c, \tau_e) = -\partial^2 \Delta V_{th}(\tau_c, \tau_e)/\partial \tau_c \partial \tau_e$ 을 이용하여 다양한 스트레스 조건에서 ΔV_{th} 의 실험적 회복 곡선으로부터 얻어질 수 있다 [1]. 결함 밀도 맵은 영구 (permanent) 및 회복(recoverable) 성분을 묘사하는 이변량 가우스 분포 (bivariate Gaussian distribution)와 일치하게 표현된다. 활성화 에너지 공간에서 밀도 $D(E_c, E_e)$ 는 결합 확률 밀도 함수 (joint probability density function)로 의해 다음과 같이 구성된다 [3-5].

$$D(E_c, E_e) = \frac{D_0}{2\pi\sigma_c\sigma_e\sqrt{1-\rho^2}} \times e^{-\left[\frac{1}{2(1-\rho^2)}\left(\frac{(E_c-\mu_c)^2}{\sigma_c^2} + \frac{2\rho(E_c-\mu_c)(E_e-\mu_e)}{\sigma_c\sigma_e} + \frac{(E_e-\mu_e)^2}{\sigma_e^2}\right)\right]} \quad (2)$$

여기서 $D_0 = (V_s/V_0)^\gamma$ 는 스트레스 전압 V_s , 상수 V_0 와 γ 으로 표현된 전압 의존 크기이다. $\mu_{c,e}$ 와 $\sigma_{c,e}$ 는 각각 $E_{c,e}$ 의 평균값과 표준편차이다. 상관 계수는 $\rho = \text{covariance}(E_c, E_e)/\sigma_c\sigma_e$ 로 정의된다. 스트레스 시간 t_s 까지 충전되고, 회복 시간 t_r 에 아직 방출되지 않은 결함에 대한 문턱 전압 이동은 다음과 같이 활성화 에너지 맵

을 적분하여 계산된다 [3-5].

$$\Delta V_{th}(t_s, t_r) = \int_0^\infty \int_0^\infty D_r(E_c, E_e) P_{occ}(E_c, E_e, t_s, t_r) dE_c dE_e + \int_0^\infty \int_0^\infty D_p(E_c, E_e) P_{occ}(E_c, E_e, t_s, t_r) dE_c dE_e \quad (3)$$

여기서 $D_r(E_c, E_e)$ 과 $D_p(E_c, E_e)$ 는 각각 영구 및 회복 성분이며, $P_{occ}(E_c, E_e, t_s, t_r)$ 는 인가된 스트레스 및 회복 신호 파형에 대한 점유 확률 맵(occupancy probability map)이다 [1].

$$P_{occ}(E_c, E_e, t_s, t_r) = (1 - e^{-\frac{t_s}{\tau_c(E_c)}}) e^{-\frac{t_r}{\tau_e(E_e)}} \quad (4)$$

트랩 관련 프로세스는 전하 캐리어 수 변동이 가장 큰 원인이다. 다중 트랩 레벨의 기여는 다음과 같이 단일 Lorentzian 노이즈의 중첩으로 표현되는 노이즈 전력 스펙트럼을 발생하게 한다 [10].

$$S_N(\omega) = \sum_{i=1}^{N_t} S_{N,i}(\omega) = 4 \sum_{i=1}^{N_t} \Delta N_i^2 \frac{\tau_{eff,i}}{1 + \omega^2 \tau_{eff,i}^2} \quad (5)$$

여기서 $\Delta N_i^2 = A_i^2 \tau_{c,i} \tau_{e,i} / (\tau_{c,i} + \tau_{e,i})^2$ 는 캐리어 수 N 의 변동 ΔN 의 분산, N_t 는 Poisson 분포를 따르는 트랩의 수, ω 는 각 주파수이다. 포획-방출 활성화 에너지에 의해 트랩 에너지 수준이 Fermi 수준 보다 몇 $k_b T$ 보다 높거나 낮아도 전하 상태가 변경되어 1/f 노이즈를 발생시킬 수 있다. A_i 는 동일하게 분포된 랜덤 변수이고, 유효 시간 상수 τ_{eff} 가 통계적으로 독립적이라고 가정하면, 평균 노이즈 전력 스펙트럼은 다음과 같이 표현된다.

$$\overline{S_N(\omega)} = 4N_t^* W L A^2 \times \int_0^\infty \int_0^\infty \frac{\tau_c \tau_e}{(\tau_c + \tau_e)^2} \frac{\tau_{eff}}{1 + \omega^2 \tau_{eff}^2} D_r^*(E_c, E_e) P_{occ}(E_c, E_e, t_s, t_r) dE_c dE_e \quad (6)$$

여기서 N_t^* 는 단위 면적당 트랩 밀도, W 와 L 는 소자의 채널 폭과 길이, 유효 시간 상수는 $\tau_{eff} = (1/\tau_c + 1/\tau_e)^{-1}$ 이다. $D_r^*(E_c, E_e)$ 는 회복 성분의 정규화된 확률 밀도 함수이다. 점유 확률 밀도 $P_{occ}(E_c, E_e)$ 는 Fermi 에너지 함수 f_T 에 의해 표현되는 트랩 점유율 $f_T(1 - f_T)$ 과 유사하며, 높은 점유 확률을 가진 트랩이 노이즈 전력에 기여한다는 것을 의미한다. 선형 영역의 MOSFET의 등가 게이트 전압 노이즈 전력 스펙트럼은 다음과 같다.

$$S_{V_g}(\omega) = \frac{q^2 \overline{S_N(\omega)}}{W^2 L^2 C_{ox}^2} \quad (7)$$

여기서 C_{ox} 는 단위 면적당 게이트 산화물 정전 용량이다.

3. 머신 러닝 모델

Gaussian 분포의 2개 성분으로 구성되는 CEE 분포의 정확한 추정을 위해 GMM 방법을 적용하는 것은 최적의 선택이다. 평균 μ_i , 공분산 Σ_i 를 가진 2차원 랜덤 변수 $E_a = (E_c, E_e)$ 를 고려하면, 2개의 Gaussian 성분의 GMM 밀도 함수는 다음과 같다 [23,24].

$$p(E_a) = \sum_{i=1}^2 \pi_i \mathcal{N}(E_a | \mu_i, \Sigma_i) \quad (8)$$

여기서 π_i 는 $0 \leq \pi_i \leq 1$ 과 $\pi_1 + \pi_2 = 1$ 을 만족하는 i 번째 혼합 성분의 가중치이다. i 번째 독립 정규 분포는 다음과 같다.

$$\mathcal{N}(E_a | \mu_i, \Sigma_i) = \frac{1}{\sqrt{2\pi|\Sigma_i|}} e^{-\frac{1}{2}(E_a - \mu_i)^T \Sigma_i^{-1} (E_a - \mu_i)} \quad (9)$$

기대 최대화(EM, expectation maximum) 알고리즘은 각 Gaussian 성분의 매개변수를 계산하는데 사용된다 [23-25]. EM 알고리즘은 기대(E) 단계와 최대화(M) 단계를 기반으로 매개변수의 최대 발생 가능성 해 (maximum likelihood solution)를 추정하는 반복 알고리즘이다. GMM은 피팅된 CEE 맵의 이변량 Gaussian 분포가 클러스터를 나타낼 수 있음을 인식하여 Gaussian 성분을 클러스터링 하는데 사용된다. 소프트 클러스터링(soft clustering) 방법은 클러스터 멤버십 사후 확률(cluster membership posterior probabilities)을 추정하는데 적용된다.

활성화 에너지와 문턱 전압 이동 및 저주파 노이즈 간의 비선형 입출력 관계는 RBF(radial basis function) 신경망을 사용하여 근사화 할 수 있다 [20]. RBF 신경망은 고도의 비선형 문제를 원하는 수준의 정확도로 해결할 수 있다. RBF 입력층과 은닉층은 각각 입력 신호와 방사형 기저 전달함수 (radial basis transfer function)를 포함하고, 출력층은 가중치가 적용된 RBF 출력들의 선형 조합을 포함한다. 은닉층의 방사형 기저 뉴런에 대한 전달함수는 다음의 Gaussian 함수이다 [20].

$$rb(E_{c/e}, t_{s/r}) = \exp \left[-\left(\varphi_{k1}(E_{c/e}, t_{s/r}) \right)^2 \right] \quad (10)$$

여기서 $\varphi_{k1}(E_{c/e}, t_{s/r}) = b_k^1 \| (E_{c/e}, t_{s/r}) - w_{k1} \|$ 는 입력 $E_{c/e}, t_{s/r}$ 와 가중치 w_{k1} 간의 거리에 바이어스 b_k^1 를 곱한 값이다. RBF 은닉층에서 뉴런은 CEE 맵의 Gaussian 분

포와 유사한 Gaussian 유사 반응 함수를 사용한다. 식 (3)의 문턱 전압 이동과 식 (6)의 노이즈 전력 스펙트럼의 피적분 함수는 각각 다음과 같다 [20].

$$\Delta V_{th}^*(E_{c/e}, t_{s/r}) = D(E_c, E_e) P_{occ}(E_{c/e}, t_{s/r}) \quad (11a)$$

$$\overline{S_N(\omega, E_{c/e}, t_{s/r})}^* = 4N^* WLA^2 \frac{\tau_c \tau_e}{(\tau_c + \tau_e)^2} \frac{\tau_{eff}}{1 + \omega^2 \tau_{eff}^2} \\ D_r^*(E_c, E_e) P_{occ}(E_c, E_e) \quad (11b)$$

피적분 함수 (11a)와 (11b)의 RBF 신경망에 대한 표현은 다음과 같이 표현된다.

$$\Delta V_{th}^*(E_{c/e}, t_{s/r}) \text{ or } \overline{S_N(\omega, E_{c/e}, t_{s/r})}^* \\ = b^2 + \sum_{k=1}^N w_k \exp \left[-\left(\varphi_{k1}(E_{c/e}, t_{s/r}) \right)^2 \right] \quad (12)$$

Gaussian 적분 근사를 사용하여 입력 E_c 에 대한 적분을 수행하면 적분은 쌍곡 탄젠트 함수로 표현된다 [20].

$$\Delta V_{th}(E_{c/e}, t_{s/r}) \text{ or } \overline{S_N(\omega, E_{c/e}, t_{s/r})} = \int_0^{E_{e,max}} b^2 E_c \\ + \sum_{k=1}^N \frac{\sqrt{\pi}}{2} \frac{w_k}{b_k^1} \tanh \left[\frac{2}{\sqrt{\pi}} \varphi_{k1}(E_{c/e}, t_{s/r}) \right] \Big|_0^{E_{c,max}} dE_e \quad (13)$$

식 (13)에서 에너지 E_e 에 대한 적분을 수행하면 다음과 같이 구해진다.

$$\Delta V_{th}(t_s, t_r) \text{ or } \overline{S_N(\omega, t_s, t_r)} = b^2 E_{c,max} E_{e,max} \\ + \sum_{k=1}^N \left(\frac{\sqrt{\pi}}{2} \right)^2 \frac{w_k}{(b_k^1)^2} \left[\ln \left(\cosh \left(\frac{2}{\sqrt{\pi}} \varphi_{k1}(E_{c,max}, E_e, t_{s/r}) \right) \right) \right. \\ \left. - \ln \left(\cosh \left(\frac{2}{\sqrt{\pi}} \varphi_{k1}(0, E_e, t_{s/r}) \right) \right) \right] \Big|_0^{E_{e,max}} \quad (14)$$

4. 모델 검증

원격 플라즈마 질화 산화물(remote plasma nitride oxide)의 MOSFET 소자($W=10 \mu m$, $L=0.14 \mu m$, $t_{ox} = 2.2 nm$)에 대해 $V_{gs} = -2.0V$ 및 $T = 100$ to $200^\circ C$ 조건에서 문턱 전압 이동 ΔV_{th} 가 측정되었다. 노이즈 $S_{V_g}(\omega)$ 측정은 스펙트럼 분석기(1Hz-25kHz) 및 저 노이즈 전압증폭기를 이용하여 수행되었다. CEE 맵은 스트레스-회복 ΔV_{th} 측정 데이터의 혼합 편미분(mixed partial derivatives)으로부터 얻어진다.

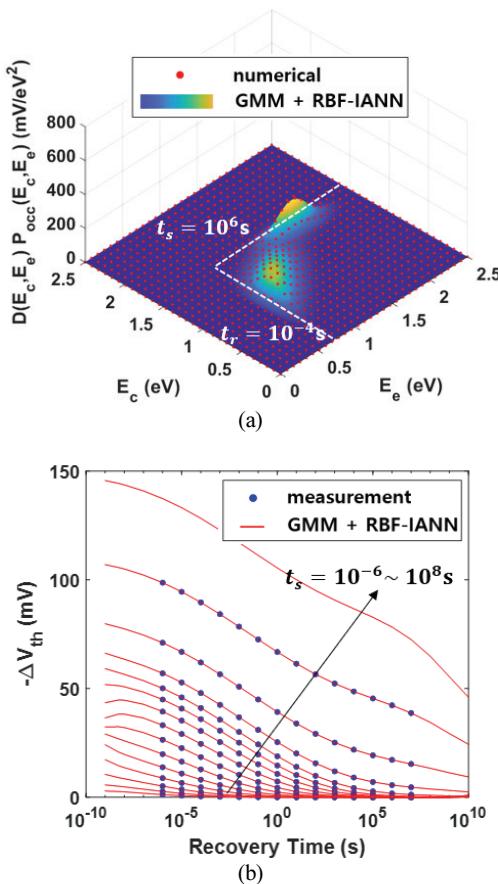


Fig. 1. (a) Comparison of numerical and GMM + RBF-IANN computation of the integrand $D(E_c, E_e)P(E_c, E_e)$ of ΔV_{th} (b) stress-recovery curves of ΔV_{th} predicted by GMM + RBF-IANN model with measurement data.

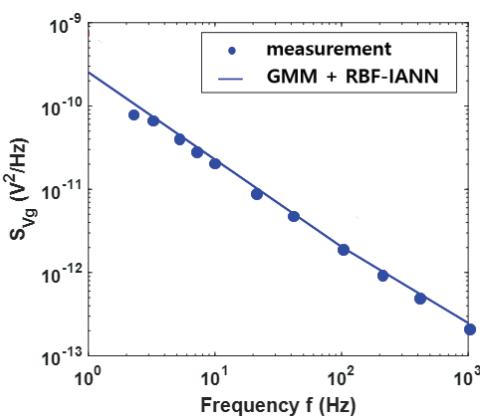


Fig. 2. 1/f noise spectrum for $t_s = 1000$ s, $V_{gs} = -2$ V, $N_t^* = 2.0 \times 10^{12}$ cm $^{-2}$.

측정 데이터로부터 얻어진 이변량 CEE 분포에 대해 측정 범위를 초과하는 매개변수 모델링을 위해 소프트 클러스터링에 의한 GMM을 적용한다. GMM으로부터 추정된 매개변수를 적용한 CEE 맵이 얻어지면 문턱 전압 이동의 피적분 함수 $\Delta V_{th}^*(E_{c/e}, t_{s/r})$ 가 RBF 신경망에서 수치 데이터를 이용하여 학습되며, IANN 모델의 정확한 실행을 가능하게 한다. Fig. 1 (a)와 (b)는 각각 피적분 함수 ΔV_{th}^* 와 ΔV_{th} 가 정확하게 예측됨을 보여준다.

1/f 노이즈 전력은 $S_N(\omega, E_{c/e}, t_{s/r})$ 가 RBF 신경망에서 수치 데이터를 이용하여 학습된다. Fig. 2에서 보듯이, CEE 맵의 회복 성분 $D_r^*(E_c, E_e)$ 은 기울기 -1의 1/f 노이즈 스펙트럼을 예측한다.

5. 결 론

BTI 기인한 문턱 전압 이동과 저주파 노이즈는 RBF-IANN과 GMM을 사용한 머신 러닝 기법에 의해 정확히 모델링 된다. 머신 러닝 모델은 IANN의 계산 효율성과 GMM의 최적 추정을 결합하여 다양한 스트레스 및 회복 조건에서 BTI 수명과 노이즈를 예측할 수 있다. 제안된 모델은 측정 데이터의 동적 특성을 정확하게 표현하고, 머신 러닝의 뛰어난 유연성을 다양한 신뢰성 문제의 비선형 모델링으로 확장할 수 있다.

감사의 글

본 연구는 2020학년도 상명대학교 교내연구비를 지원 받아 수행하였음.

참고문헌

- Grasser T. "Stochastic charge trapping in oxides: From random telegraph noise to bias temperature instabilities," *Microelectronics Reliability*, Vol. 52, pp. 39-70, 2012.
- Reisinger H., Grasser T., Gustin W., and Schlünder C., "The statistical analysis of individual defects constituting NBTI and its implications for modeling DC- and AC-stress," In Proceedings of 2010 IEEE International Reliability Physics Symposium, Anaheim, CA, USA, pp. 7-15, 2-6 May 2010.
- Puschkarsky K., Reisinger H., Schlünder C., Gustin W., and Grasser T., "Voltage-dependent activation energy maps for analytic lifetime modeling of NBTI without time extrapolation," *IEEE Transactions on Electron Devices*, Vol. 65, pp.4764-4771, 2018.

4. Lagger P., Reiner M., Pogany D., and Ostermaier C., "Comprehensive study of the complex dynamics of forward bias-induced threshold voltage drifts in GaN based MIS-MEMTs by stress/recovery experiments," IEEE Transactions on Electron Devices, Vol. 61, pp.1022-1030, 2014.
5. Putcha V., Franco J., Vais A., Sioncke S., Kaczer B., Linten D., and Groeseneken G., "On the apparent non-Arrhenius temperature dependence of charge trapping in IIIV/high-k MOS stack," IEEE Transactions on Electron Devices, Vol. 65, pp.3689-3696, 2018.
6. Tewksbury T. L. and Lee H.S., "Characterization, modeling, and minimization of transient threshold voltage shifts in MOSFET's," IEEE Journal of Solid-State Circuits, Vol. 29, pp.239-252, 1994
7. Grasser T., Rott K., Reisinger H., Waltl M., Franco J., and Kaczer B., "A unified perspective of RTN and BTI," In Proceedings of 2014 IEEE International Reliability Physics Symposium, Waikoloa, HI, USA, pp. 4A.5.1-4A.5.7., 1-5 June 2014.
8. Kaczer B., Grasser T., Martin-Martinez J., Simoen E., Aoulaiche M., Roussel Ph.J., and Groeseneken G., "NBTI from the perspective of defect states with widely distributed time scales," In Proceedings of 2009 IEEE International Reliability Physics Symposium, Montreal, QC, Canada, pp. 55-60, 26-30 April 2009.
9. Grasser T., Reisinger H., Goes W., Aichinger Th., Hohenberger Ph., Wagner P.J., Nelhiebel M., Franco J., and Kaczer B., "Switching oxide traps as the missing link between negative bias temperature instability and random telegraph noise," In Proceedings of 2009 International Electron Device Meeting, Baltimore, MD, USA, pp. 729-732, 7-9 Dec. 2009.
10. Da Silva R., Wirth G. I., and Brusamarello L., "An appropriate model for the noise power spectrum produced by traps at the Si-SiO₂ interface: a study of the influence of a time-dependent Fermi level," Journal of Statistical Mechanics: Theory and Experiment, Vol.2008, pp.10015-10025, 2008.
11. Wirth G. and da Silva R., "Low-frequency noise spectrum of cyclo-stationary random telegraph signals," Electrical Engineering, Vol.90, pp.435-441, 2008.
12. Weckx P., Kaczer M., Toledano-Luque M., Grasser T., Roussel Ph.J., Kukner H., Raghaven P., Catthoor F., and Groeseneken G., "Defect-based methodology for workload-dependent circuit lifetime projections-Application to SRAM," Proceedings of 2013 IEEE International Reliability Physics Symposium, Anaheim, CA, USA, pp. 3A.4.1-3A.4.7., 14-18 April 2013.
13. Puschkarsky K., Reisinger H., Rott G. A., Schlünder C., Gustin W., and T.Grasser, "An efficient analog compact NBTI model for stress and recovery based on activation energy maps," IEEE Transactions on Electron Devices, Vol. 66, pp.4623-4630, 2019.
14. Fang R., Livingston I., Esqueda I. S., and Kozicki M., "Bias temperature instability model using dynamic defect potential for predicting CMOS aging," Journal of Applied Physics, Vol. 123, pp.225701-1 – 225701-9, 2018.
15. Wang W., Reddy V., Krishnan A. T., Vattikonda R., Krishnan S., and Cao Y., "Compact modeling and simulation of circuit reliability for 65-nm CMOS technology," IEEE Transactions on Device and Materials Reliability, Vol. 7, pp.509-517, 2007
16. Cao Y., et. al., "Cross-layer modeling and simulation of circuit reliability," IEEE Transaction on Computer - Aided Design of Integrated Circuits and Systems, Vol. 33, pp.8-23, 2014.
17. Velamala J. B., et. al., "Compact modeling of statistical BTI under trapping/detrapping," IEEE Transactions on Electron Devices, Vol. 60, pp.3645-3654, 2013.
18. Huang A. D., Zhong Z., Wu W., and Guo Y. X., "An artificial neural network-based electrothermal model for GaN HEMTs with dynamic trapping effects consideration," IEEE Transactions on Microwave Theory and Techniques, Vol. 64, no.8, pp.2519-2528, 2016.
19. Li X., Gao J., and Boeck G., "Microwave nonlinear device modeling by using an artificial neural network," Semiconductor Science and Technology, Vol.21, pp.833-840, 2006.
20. Lee J., "Physics-guided neural modeling for low-dimensional thermoelectric module," IEEE Electron Device Letters, Vol.40, pp.1812-1815, 2019.
21. Zhang L. and Chan M., "Artificial neural network design for compact modeling of generic transistors," Journal of Computational Electronics, Vol.16, pp.825-832, 2017.
22. Jarndal A., "On neural networks based electrothermal modeling of GaN devices," IEEE Access, Vol. 7, pp.94205-94214, 2019.
23. Shimizu H., Awano H., Hiromoto M., and Sato T., "Automation of model parameter estimation for random telegraph noise," IEICE Transactions on Fundamentals, Vol. E97-A, pp.2383-2392, 2014.
24. Singh R., Pal B. C., and Jabr R. A., "Statistical

- representation of distribution system loads using Gaussian mixture model,” IEEE Transactions on Power Systems, Vol.25, pp.29-37, 2010.
25. Peters G., Crespo F., Lingras P., and Weber R., “Soft clustering – fuzzy and rough approaches and their extensions and derivatives,” International Journal of Approximate Reasoning, Vol. 54, pp.307-322, 2013.
26. D. H. Kim, J. E. Choi, T. M. Ha, and S. J. Hong “Modeling with thin film thickness using machine learning,” Journal of the Semiconductor & Display Technology, Vol. 18, pp. 48-52, 2019
27. J. H. Han and S. S. Hong, “Semiconductor process inspection using mask R-CNN,” Journal of the Semiconductor & Display Technology, Vol. 19, pp. 12-18, 2020
28. Rai R. and Sahu C. K., “Driven by data or derived through physics? A review of hybrid physics guided machine learning techniques with cyber-physical system (CPS) focus,” IEEE Access, Vol. 8, pp.71050-71073, 2020.

접수일: 2020년 12월 4일, 심사일: 2020년 12월 9일,
제재확정일: 2020년 12월 10일