

경사하강법을 이용한 낸드 플래시 메모리 기반 저장 장치의 고효율 수명 예측 및 예외처리 방법

이현섭

백석대학교 컴퓨터공학부 조교수

High Efficiency Life Prediction and Exception Processing Method of NAND Flash Memory-based Storage using Gradient Descent Method

Hyun-Seob Lee

Assistant Professor, Division of Computer Engineering, Baekseok University

요약 최근 빅데이터를 수용하기 위한 대용량 저장 장치가 필요한 엔터프라이즈 저장 시스템에서는 비용과 크기 대비 직접도가 높은 대용량의 플래시 메모리 기반 저장 장치를 많이 사용하고 있다. 본 논문에서는 엔터프라이즈 대용량 저장 장치의 신뢰도와 이용성에 직접적인 영향을 주는 플래시 메모리 미디어의 수명을 극대화 하기 위해 경사하강법을 적용한 고효율 수명 예측 방법을 제안한다. 이를 위해 본 논문에서는 불량 발생 빈도를 학습하기 위한 메타 데이터를 저장하는 매트릭스의 구조를 제안하고 메타데이터를 이용한 비용 모델을 제안한다. 또한 학습된 범위를 벗어난 불량률이 발생 했을 때 예외 상황에서의 수명 예측 정책을 제안한다. 마지막으로 시뮬레이션을 통해 본 논문에서 제안하는 방법이 이전까지 플래시 메모리의 수명 예측을 위해 사용되어 온 고정 횟수 기반 수명 예측 방법과 예비 블록의 남은 비율을 기반으로 하는 수명 예측 방법 대비 수명을 극대화 할 수 있음을 증명하여 우수성을 확인했다.

주제어 : 수명 예측, 플래시 메모리, 저장 시스템, 빅데이터 수용, 수명 예측 모델

Abstract Recently, enterprise storage systems that require large-capacity storage devices to accommodate big data have used large-capacity flash memory-based storage devices with high density compared to cost and size. This paper proposes a high-efficiency life prediction method with slope descent to maximize the life of flash memory media that directly affects the reliability and usability of large enterprise storage devices. To this end, this paper proposes the structure of a matrix for storing metadata for learning the frequency of defects and proposes a cost model using metadata. It also proposes a life expectancy prediction policy in exceptional situations when defects outside the learned range occur. Lastly, it was verified through simulation that a method proposed by this paper can maximize its life compared to a life prediction method based on the fixed number of times and the life prediction method based on the remaining ratio of spare blocks, which has been used to predict the life of flash memory.

Key Words : Storage device lifetime prediction, Flash memory, Storage system,
Big data accommodation, Lifetime prediction model

*This paper was supported by 2021 Baekseok University Research Fund

*This article is extended and excerpted from the conference paper presented at KSIC Spring Conference 2020 of The Korean Society of Industry Convergence

Corresponding Author : Hyun-Seob Lee(hyunseob@bu.ac.kr)

Received October 10, 2021

Revised November 1, 2021

Accepted November 20, 2021

Published November 28, 2021

1. 서론

저장 장치의 수명 예측 방법은 활용성과 데이터 안정성을 극대화할 수 있기 때문에 데이터의 신뢰성과 시스템 관리 측면에서 중요한 요소 중 한 가지이다. 최근 다양한 저장 시스템에서 저장 장치로 사용되고 있는 SSD(Solid State Drive)는 이를 구성하고 있는 낸드 플래시 메모리의 수명이 실질적인 수명과 연결된다. 따라서 SSD를 이용하여 구성된 저장 시스템에서는 낸드 플래시 메모리의 수명을 정확하고 효율적으로 예측하는 방법이 필요하다. 본 논문에서는 다양한 분야에서 활용되고 있는 머신러닝 기술의 학습 방법 중 경사 하강법(Gradient Descent Method)[1,2]을 응용하여 플래시 메모리의 고효율의 수명 예측 방법을 연구한다. 이를 위해 본 논문에서는 불량 발생 빈도를 학습하기 위한 메타 데이터를 저장하기 위한 매트릭스의 구조를 제안하고 메타데이터를 이용한 비용 모델을 제안한다. 또한 학습된 범위를 벗어난 불량이 발생했을 때 예외 상황에서의 수명 예측 정책을 제안한다. 마지막으로 시뮬레이션을 통해 본 논문에서 제안하는 방법이 이전까지 플래시 메모리의 수명 예측을 위해 사용되어 온 고정 횟수 기반 수명 예측 방법과 예비 블록의 남은 비율을 기반으로 하는 수명 예측 방법 대비 수명을 극대화할 수 있음을 증명하여 우수성을 확인한다.

2. 배경

2.1 플래시 메모리의 특징

낸드 플래시메모리는 저 전력 소비와 빠른 데이터 읽고 쓰기 속도의 특징이 있다. 이러한 장점 때문에 소규모 임베디드 시스템에서 빅데이터를 관리하는 대용량 데이터 서버까지 여러 분야의 저장 장치 미디어로 활용되고 있다. 그러나 플래시 메모리의 중요 특징 중 한 가지는 한 지역의 블록에 일정 횟수 이상으로 반복적인 쓰기/지우기 동작을 수행하면 블록의 수명이 다한다는 것이다. 이러한 제약사항은 저장 장치의 데이터 신뢰성뿐만 아니라 성능에도 영향을 미칠 수 있기 때문에, 다양한 분야에서 수명 예측을 기반으로 제약사항을 극복하기 위한 연구가 진행되고 있다[3-6].

2.2 플래시 메모리의 수명 예측과 한계점

이전까지 플래시 메모리의 수명을 예측하는 대표적

인 방법으로 쓰거나 지우기 횟수를 활용하는 기법이 있다[7]. 이 방법은 플래시 메모리에 권장하는 최대 쓰기 지우기 횟수를 제공하고 이 동작의 횟수를 이용하여 저장 시스템의 수명을 계산하는 방법이다. 예를 들어 플래시메모리의 권장 쓰기 지우기 횟수가 1만 회이고 현재 100회의 쓰고 지우기 연산을 수행했다면 이 저장 시스템의 수명은 99% 남은 것으로 계산될 수 있다. 그러나 이러한 고정된 횟수는 제조 회사에서 보증하는 최소 신뢰 기준이고 실제로는 제한된 횟수보다 많은 횟수의 쓰고 지우기 연산을 수행 후에도 여전히 동작 가능한 플래시 메모리가 있거나, 보증 기준에 못 미치는 횟수로도 블록의 특성이 나빠져서 더 이상 사용할 수 없기도 하다. 심지어는 생산 과정에서 발생하는 초기 불량 블록도 존재하기 때문에 이러한 고정적인 횟수를 이용한 수명 예측 방법은 대용량의 저장 장치에서는 수명을 예측하는데 부정확 한 단점이 있다.

고정된 수명 문제를 극복하기 위한 또 다른 방법은 예비 블록(Spare block)을 활용하는 방법이다.[8,9] 예비 블록은 불량이 발생한 블록을 교체하기 위해 추가로 제공하는 블록으로, 사용 중인 특정 블록에서 불량이 발생했을 때 정상 상태인 예비 블록 중 하나와 교체하여 전체 불량 중 불량이 발생한 블록을 감추는 방법이다. 예를 들어 1000개의 데이터 블록과 100개의 예비 블록으로 이루어진 저장 장치는 논리적으로는 1000개의 블록으로 보이지만, 물리적으로 1100개의 블록으로 구성되어 있고, 100개의 예비 블록이 모두 교체될 때까지 일반 블록에서 발생하는 불량에 대해 물리적으로 대처할 수 있다. 따라서 예비 블록을 이용하여 수명을 예측하는 방법은 남아있는 예비 블록의 개수를 확인하여 수명을 예측할 수 있는 특징이 있다. 예를 들어, 남아있는 예비 블록의 수가 90개라면 90%의 수명이 남아있다고 예측하는 기법이다. 그러나 이 방법은 발생한 불량에 대한 회복 가능한 비율이기 때문에 데이터 패턴에 따라 변화하는 불량률이 변화할 경우 현재 상태에서 수명 마감까지 몇 번의 연산이 가능한지에 대한 예측이 불가능하다.

2.3 경사하강법을 이용한 학습

머신러닝은 신경망을 통해 연산된 결과는 예상된 기

댓값과의 오차를 역전파(Back Propagation) 과정을 반복하여 줄여나간다. 이때 오차의 최소 비용을 탐색하기 위한 방법 중 하나로 경사하강법을 사용한다[8,9].




Fig. 1. Gradient Descent Algorithm

Fig. 1은 경사하강법의 기본적인 내용을 보여주고 있다. 신경망에서는 노드 간에 값이 잘못 전달되어 오차가 발생했을 때 비용함수의 기울기를 구하고 비용이 최소화 되는 방향으로 오차를 줄여나간다. 그림에서 시작점이 x1인 경우 기울기의 값은 음의 값을 갖기 때문에 최적화된 비용을 갖는 x2를 찾을 때까지 가중치를 점차 증가해가는 과정이 반복적으로 필요하고 x3인 경우 반대로 가중치를 줄여가는 과정이 반복적으로 필요하다.

3. 플래시메모리의 고효율 수명 예측 방법

3.1 플래시 메모리 저장 장치의 불량 발생 경향 분석




Fig. 2. Tendency of Defects with Data Throughput

Fig. 2는 데이터 처리량 증가에 따른 불량 발생의 경향을 보여주고 있다. 그림에서 X축은 SSD가 데이터를 하루에 처리할 수 있는 양인 DWPD(Drive Writes Per Day)를 의미하고, Y 축은 DWPD를 처리할 때 발생하는 불량 횟수를 의미한다. 일반적으로, 불량률의 발생

확률은 임의의 확률 값을 갖고 있지만 이 확률은 사용량에 비례하여 증가하기 때문에, 일정 단위 기간이나 사용 횟수마다 발생하는 불량률의 구간 합이나 평균값을 연결하면 그림과 같은 지수 형태의 곡선에 수렴하는 결과를 얻을 수 있다. 이러한 원인은 SSD에서 블록이 마모(Wear-out) 되기 시작하면 비슷한 사용량을 가지고 있는 이웃하는 블록에서도 연속적으로 마모가 발생할 가능성이 증가하기 때문이다.[10]

3.2 불량률에 대한 경사 하강법 적용

플래시 메모리는 정해진 횟수 이상으로 데이터를 쓰고 지울 경우 마모가 발생하여 불량률이 증가하기 때문에, 특정 횟수의 데이터 처리를 보증하는 보증기간 이후 데이터 처리가 증가할수록 지수곡선 형태로 불량률 발생한다. 그리고 이 곡선은 경사하강법의 곡선과 동일한 형태를 가지며 불량률 곡선의 순간 기울기는 손실함수에서의 비용과 유사한 특성을 갖는다.

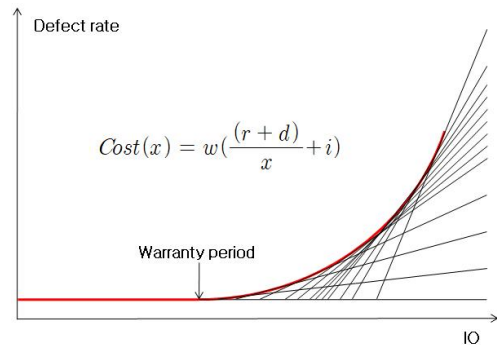


Fig. 3. Gradient Descent Model on the Rate of Flash Failure

Fig. 3는 플래시 메모리의 불량률에 경사하강법을 적용한 것을 보여주고 있다. 그림과 같이 데이터 처리가 증가하여 보증기간이 지난 순간부터 불량률은 지수의 형태로 증가를 하는데, 일정 불량률 이후부터는 더 이상 저장 장치를 사용할 수 없다. 이러한 현상을 경사하강법에 적용하면, 각 불량률이 증가하는 순간의 기울기를 계산하기 위해 손실 함수에 대응했을 때 특정 데이터 처리 횟수에서 계산된 손실비용 이후에는 고장이 더 이상 저장 장치를 사용할 수 없는 수명 마감일이 발생하는 것을 예측할 수 있다. 즉, 여기서 사용하는 경사하강법은 최적화된 값을 찾기 위한 목적이 아니고, 제품

의 불량률 발생 곡선을 학습하고, 이를 이용하여 수명 마감을 예측하는 데 사용된다.

본 논문에서는 Fig. 3 내부 수식과 같은 선형 기반의 비용 모델을 제안한다. 수식에서 w 는 생산제품에 따라 변경될 수 있는 미디어 구성의 특성에 대한 가중치이다. 이 가중치는 하나의 불량이 발견되었을 때 다른 하나의 예비 블록으로 대체 가능한 경우는 1이다. 그러나 하나의 블록이 불량이라 발생하더라도 이웃하는 다른 블록들과 같이 여러 개의 블록을 교체해야 할 경우 증가된 교체 비용에 대한 가중치는 실제로 교체된 블록의 개수만큼 증가한다. 그리고 x 는 누적 처리된 DWPD를 의미하고, r 는 마지막 DWPD의 데이터가 처리되는 동안 발생한 불량률의 개수이다. 여기서 d 는 불량률이 예상 값 보다 높거나 낮을 때 이를 보정 해주기 위한 보정 값이다. 마지막으로 i 가 의미하는 것은 생산 과정에서 발생할 수 있는 초기 불량률을 의미한다.

3.3 비용 매트릭스

Table 1. Cost Matrix

Data	Max. Defect	Min. Cost	Max. Cost	Avg. Cost
1000	10	0	10	2
1001	11	0	12	3
...
1100	20	1	20	7
...
1600	100	30	45	40

Table 1은 본 논문에서 제안하는 비용 매트릭스를 보여주고 있다. 그리고 각 열은 DWPD 데이터를 처리하는 동안 발생한 불량률의 최대 횟수 최소 비용, 최대 비용 평균비용을 의미한다. 제안하는 매트릭스의 정보는 미디어 단품이 아닌 완성된 저장 장치에서 많은 양의 데이터를 처리할 때 발생하는 최대 최소 불량률의 개수만을 단계적으로 포함하기 때문에 상세 데이터 처리와 직접적으로 연결된 불량률의 개수는 확인할 수 없도록 보호하였다. 또한 양산 과정에서 추가되어야 하는 기타 정보를 가리기 위해 입력 값들을 신경망을 통해 계산된 비용 값을 유지하도록 하여 어떠한 생산과정에서 사용되는 입력 값이 어떠한 값 들인지 가릴 수 있도록 하였다. 따라서 불량 발생 경향을 학습할 수 있지만 양산 및 생산 과정에서 민감한 정보들은 최종 사용자 입장에서

는 알 수 없도록 보호할 수 있는 장점이 있다.

3.4 빅데이터를 이용한 수명 예측 기법

본 논문에서 제안하는 방법은 저장 장치에서 특정 횟수의 데이터 처리를 진행할 때마다 사전에 학습된 비용 매트릭스의 정보를 기반으로 수명을 예측하는 방법이다. 제안하는 방법의 수명 예측 기법 정책은 다음과 같다. 먼저, 저장 장치에 누적된 쓰기 요청의 횟수를 기반으로 처리된 데이터 량을 DWPD 단위로 환산하여 계산한다. 그다음 계산된 DWPD와 현재까지 발생한 불량률 횟수를 비용 모델에 대입하여 비용을 계산한다. 그리고, 계산된 비용이 사전에 학습된 데이터를 포함하고 있는 비용 매트릭스와 비교하여 예상 범위 내의 비용인지 확인한다. 만약 학습된 예상 범위 내의 비용이면, 비용 매트릭스에 포함되어 있는 최대 불량률과 저장 장치에서 불량률을 처리할 수 있는 예비 블록의 자원을 비교하여 수명을 예측한다. 그러나 만약 예상 범위 밖의 비용이면 보정 정책을 통해 남은 수명에 대한 가중치를 조절하여 비용을 재계산 후 수명을 예측한다.

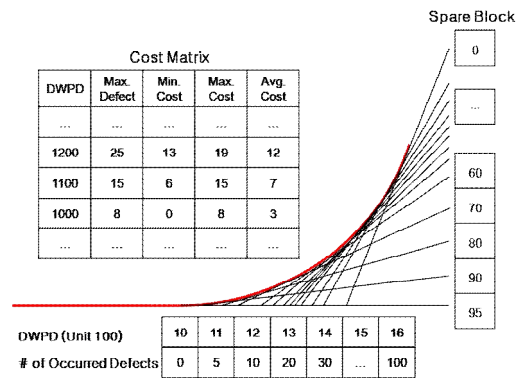


Fig. 4. Prediction Policy for End of Life

Fig. 4는 본 논문에서 제안하는 수명 예측 방법의 예를 보여주고 있다. 그림의 예에서 비용 모델에 의한 산출된 비용은 직전 DWPD 처리 이후 발생한 불량률과 초기 불량률의 합산과 동일하다고 가정하였다. 그리고 초기 불량률은 5로 가정하였다. 또한 예비 블록의 총개수가 100개일 때 최대 1600DWPD까지 처리할 수 있다고 가정을 하고, 각 DWPD마다 최대 불량률, 최소 비용, 최대 비용, 평균 비용의 정보를 유지

하고 있는 비용 매트릭스를 이용해 900DWPD 이후, 100DWPD의 데이터가 처리될 때마다 수명을 예측하는 방법의 예제를 보여주고 있다. 그림의 예제에서 1000DWPD를 처리했을 때 이전 대비 증가된 불량률의 개수는 0이다. 따라서 비용 모델을 통해 계산된 불량률은 5이다. 그리고 이 비용 값은 비용 매트릭스의 최대 최소 비용 오차 범위 내의 값이기 때문에 학습된 최대 불량률은 10이고, 앞으로 처리할 수 있는 데이터량은 600DWPD이다. 즉 가까운 시일 안에 5개의 추가 불량률 발생 가능성이 있기 때문에 현재까지 실제로 사용한 예비 블록의 자원은 5이지만 다음 수명 예측 전까지 예비 블록의 소모량은 90프로 남은 것으로 가정한다.

3.5 예외상황 처리를 통한 수명 예측정책

본 논문에서는 DWPD 단위의 대용량 데이터 처리를 할 때 발생하는 불량률 기준을 비용 값을 계산하기 때문에 특정 DWPD 처리 구간에서 발생하는 불량률 개수는 수명 주기 동안 처리할 수 있는 전체 데이터량을 DWPD 처리 구간으로 나누었을 때 각 구간에서 발생하는 불량률 발생의 평균값에 수렴할 것이다. 그러나 예상할 수 없는 여러 가지 원인으로 인해 일시적으로 급작스러운 불량률이 발생하거나, 예측 이하의 불량률이 발생한 경우 수명을 정확하게 예측하기 어렵다는 한계가 있다. 따라서 본 논문에서는 경사하강법을 적용했을 때 예상범위 밖의 불량률이 발생할 경우, 예외 상황을 보정할 수 있는 보정 정책 제안한다.




Fig. 5. Cost Collection Policy

Fig.5는 예외 상황의 불량률이 발생했을 때 비용 값을 보정하는 방법을 보여주고 있다. 그림에서 데이터 처리 증가에 따라 예측된 범위의 불량률 개수의 증가는 A에서 B로 이동하는 것이고, 비용 모델에 따른 변경된 예상

비용 값은 4번 라인의 기울기에서 1라인의 기울기로 변경되는 것이다. 그런데 만약 C나 E, F, G와 같이 불량률 증가의 개수가 예상될 B의 범위 값보다 더 많거나 적은 경우, 이것은 학습된 평균 불량률 증가량과 다른 예외사항이고, 저장 장치의 남은 수명의 소진율이 학습된 예상 값과 다르게 변경될 수 있음을 의미한다. 이 차이를 보정하기 위해 먼저 불량률이 학습된 예상 값 보다 증가한 C의 경우, 이 시점에서의 남은 수명을 예측하기 위해 비용 매트릭스에서 최저 비용과 최대 비용이 C의 비용 값을 포함하는 범위를 갖는 D를 찾고, D의 평균 비용 값을 보정할 수 있는 차이인 보정 값을 비용 모델 수식의 d에 반영한다. 즉 예외 상황으로 증가한 불량률에 의해 증가한 비용의 보정 값을 비용 모델에 반영하여, 보정 된 비용을 이용하여 수명 예측에 수명을 사용하도록 한다. 그리고 불량률의 증가가 예상된 값 보다 줄어든 E, F, G의 경우에는 동일하게 데이터 처리량에 대한 불량률의 변화량을 비용 모델에 반영하도록 한다. 이러한 과정을 보다 단순하게 설명한 예제는 다음과 같다. 첫째 데이터 처리에 따른 실제 불량률의 비용이 C의 1번 선과 같이 예측 범위를 넘어선 경우 비용 매트릭스에서 증가된 비용 값을 포함하는 범위를 갖는 D를 찾고, 실제 처리된 데이터보다 많은 D 항목의 학습 데이터를 이용하여 수명을 예측한다. 예를 들어 1000DWPD의 데이터를 처리하는데 학습된 예상 비용이 0에서 8 사이였으나 실제 측정된 비용이 11인 경우, 1100DWPD를 사용했을 때의 비용 범위에 포함되기 때문에 1100DWPD의 데이터를 처리했을 때와 동일한 학습 데이터를 기준으로 남은 수명을 예측한다. 둘째, 측정된 비용이 E의 3번 선과 같이 예상된 학습 데이터인 B의 비용보다는 적지만 이전 비용 E와 동일 선상인 F의 비용보다 큰 경우, 학습된 B의 데이터를 이용하여 기대 수명을 예측한다. 마지막으로 측정된 불량률의 비용이 이전 F의 4번 선과 G의 5번 선과 같이 이전 A에서 측정된 비용 이하인 경우, 이전과 동일한 A의 비용 값을 이용하여 수명을 예측한다.

4. 실험 및 결과

본 논문에서는 제안하는 방법의 불량률 예측 효과를 측정하기 위해 시뮬레이션을 통해 수명 예측 과정을 분석하였다. 실제 발생하는 불량률과 유사한 형태의 데이터로 실험을 하기 위해 불량률 발생의 증가는 초기 불량

이후 보증기간까지는 불량 발생하지 않고, 보증기간 이후 지수 선과 같은 비율로 증가한다고 가정하였다. 또한, 실험을 위해 구체적인 구성으로 저장 장치의 보증기간은 2년이고, 1000DWPD까지 보증하는 가상의 저장 장치를 가정하였고, 데이터의 불량 발생률은 지수 형태를 띠어야 하기 때문에 1000DWPD 이후 10DWPD를 처리할 때마다 발생하는 불량의 개수에 계차수열을 적용하였다. 적용한 계차수열에서 계차는 공차가 2인 등차수열로 가정했고, 이로 인해 각 단위에서 발생하는 불량의 개수는 2, 4, 6, 등의 순서로 이전보다 2씩 증가한다. 불량 발생에 계차수열을 적용한 이유는 랜덤하게 발생하는 불량의 개수도 많은 양의 데이터를 처리하는 구간 동안 발생하는 불량률의 구간 합이나 그 평균값은 지수 형태의 증가 경향에 수렴하고, 계차수열을 통한 데이터 증가가 구간별 합산을 이용한 지수 선을 가장 직관적으로 보여줄 수 있기 때문이다. 그리고 수명 예측 데이터의 업데이트 주기는 10DWPD마다 갱신하는 것으로 가정을 하였다. 또한, 발생한 불량을 교체할 수 있는 예비 블록은 200개로 가정하였고, 초기 불량률은 18 블록(예비 블록의 10% 미만으로 임의의 값을 산정) 하였다.




Fig. 6. Results of Simulation

Fig. 6은 시뮬레이션 결과를 보여주고 있다. 그림의 결과와 같이 고정 임계값을 사용하는 방법은 수명주기 동안 보증할 수 있는 최대 처리 가능 데이터는 고정 임계값과 밀접한 관계를 갖는다. 따라서 1000DWPD 이후 수명을 예측하거나 보장할 수 없다. 예약 블록을 사용하는 방법은 불량이 언제 발생되어 예약 블록들을 모두 소진할지 알 수 없으므로 최대 처리 가능한 데이터를 단독으로 알 수는 없기 때문에 고정 임계값 처리 방식과 함께 사용된다. 마지막으로 제안된 방법은 실제로 학습된 데이터를 통해 1130DWPD를 처리할 수 있는

것을 알 수 있다. 이 결과를 통해 이전 방법 대비 13% 수준의 데이터를 처리할 수 있음을 알 수 있다. 그다음, 저장 장치의 현재 상태에서 남은 처리 가능 데이터를 확인하는 방법의 경우 고정 임계값을 사용하는 방법은 처리된 데이터량 대비 남은 임계값을 제공할 수 있으나 실제로 1130DWPD를 처리할 수 있는 저장 장치에서 실제 처리 가능한 데이터를 기반으로 한 것이 아니기 때문에 제안된 방법 대비 부정확하다. 마지막으로, 고정 임계값을 사용하는 방법은 저장 장치에서 보증하는 1000DWPD의 데이터를 모두 처리한 이후의 수명을 예측할 수 없다. 그리고 예약 블록을 사용하는 방법은 남아있는 예약 블록의 개수를 통해 추가 연장사용 가능성은 알 수 있으나 앞으로 몇 번의 DWPD를 처리할 수 있는지 예측할 수 없다. 반면, 제안하는 방법은 보증된 DWPD를 처리한 뒤에도 학습된 정보를 통해 연장사용도 가능하고, 앞으로 남아있는 처리 가능한 데이터량도 예측 가능한 장점이 있다.

5. 결론

본 논문에서는 낸드 플래시 메모리의 불량 발생 빈도를 학습하고 경사하강법을 적용하여 저장 장치의 남아있는 수명을 예측하는 방법을 제안하였다. 이를 위해 불량 발생 빈도를 학습하는 메타 데이터를 저장하기 위한 매트릭스 구조를 설계하였고, 불량 발생 빈도를 이용한 손실 함수 그래프에 경사하강법을 적용하여 수명을 예측하는 방법을 제안하였다. 마지막으로 실험을 통해 제안하는 방법이 고정된 읽고 쓰기 횟수나 예비 블록의 남은 비율을 기반으로 수명을 예측하는 이전 방법들 보다 정확하게 수명을 예측할 수 있음을 증명하였다. 그러나, 본 논문에서는 시뮬레이션을 이용하여 논문을 검증하였다. 향후에는 실제의 불량 빈도 데이터를 확보하여 실험 및 연구 결과의 객관성을 보강 할 예정이다.

REFERENCES

- [1] F. E. Curtis & K. Scheinberg. (2017). Optimization Methods for Supervised Machine Learning: From Linear Models to Deep Learning, *The Operations Research Revolution*, (pp89-113). INFORMS.
- [2] H. Zhang et al. (2017). ZipML: training linear models with end-to-end low precision, and a

- little bit of deep learning, *Proceedings of the 34th International Conference on Machine Learning*, (pp. 4035-4043). PMLR.
- [3] Z. Shi, Y. Fang, Y. Bu & G. Han. (2021). Convolutional Neural Network (CNN)-based Detection for Multi-Level-Cell NAND Flash Memory, in *IEEE Communications Letters*.
- [4] S. Park et al. (2021). Highly-Reliable Cell Characteristics with 128-Layer Single-Stack 3D-NAND Flash Memory, *2021 Symposium on VLSI Technology*. IEEE.
- [5] S. Lee & J. Kim. (2016). Effective Lifetime-Aware Dynamic Throttling for NAND Flash-Based SSDs, *IEEE Transactions on Computers*, 65(4), 1075-1089
- [6] G. H. Lee, S. Hwang, S. Yu J & H. Kim. (2021). Architecture and Process Integration Overview of 3D NAND Flash Technologies. *Applied Sciences*, 11(15), 6703.
- [7] R. Cang, Q. Bahman & S. Farshid. (2004). *Maintaining erase counts in non-volatile storage systems*, United States Patent, US6831865B2.
- [8] H. S. Kim, E. H. Nam, J. H. Yun, S. Lee & S. L. Min, (2017). P-BMS: A Bad Block Management Scheme in Parallelized Flash Memory Storage Devices, *ACM Trans. Embedded Comput. Syst*, 16(5s), 140:1-140:19.
- [9] T. Y. Chen, S. H. Chi, M. C. Yang & T. Y. Chien. (2021). Enabling the Duo-phase Data Management to Realize Longevity Bit-alterable Flash Memory, in *IEEE Transactions on Computers*.
- [10] H. Jang et. al. (2021), An SVM-Based NAND Flash Endurance Prediction Method, *Micromachines*, 12(7), 746.

이 현 섭(Hyun-Seob Lee)

[정회원]



- 2007년 2월 : 한양대학교 컴퓨터공학과 (공학석사)
- 2013년 2월 : 한양대학교 컴퓨터공학과 (공학박사)
- 2012년 3월 ~ 2021년 2월 : 삼성 전자 책임연구원

- 2021년 3월 ~ 현재 : 백석대학교 컴퓨터공학부 조교수
- 관심분야 : 머신러닝, 임베디드시스템
- E-Mail : hyunseob@bu.ac.kr