

Characterizing the Tail Distribution of Android IO Workload

Changhyun Park[†] · Youjip Won^{**} · Yongjun Park^{***}

ABSTRACT

The use of NAND flash memory has increased rapidly due to the development of mobile fields. However, NAND flash memory has a limited lifespan, so studies are underway to predict its lifespan. Workload is one of the factors that significantly affect the life of NAND flash memory, and workload analysis studies in mobile environments are insufficient. In this paper, we analyze the distribution of workload in the mobile environment by collecting traces generated by using Android-based smartphones. The collected traces can be divided into three groups of hotness. Also they are distributed in the form of heavy tails. We fit this to the Pareto, Lognormal, and Weibull distributions, and Traces are closest to the Pareto distribution.

Keywords : Android, Trace, Workload, Mobile

안드로이드 입출력 부하의 꼬리분포 특성분석

박창현[†] · 원유집^{**} · 박영준^{***}

요약

모바일 분야의 발전으로 인해 낸드 플래시 메모리의 사용이 급증하였다. 그러나 낸드 플래시 메모리는 수명에 제한이 있어서 수명을 예측하기 위한 연구가 진행되고 있다. 낸드 플래시 메모리의 수명에 큰 영향을 주는 요소 중 하나가 워크로드인데, 모바일 환경에서의 워크로드 분석 연구는 미비하다. 이에 본 논문에서는 안드로이드 기반의 스마트폰을 사용하면서 발생하는 트레이스를 수집하고, 모바일 환경에서의 워크로드 분포를 분석하였다. 수집한 트레이스는 hotness 그룹을 3개로 분류할 수 있다. 또한 트레이스의 분포는 무거운 꼬리를 가지는 형태이다. 본 논문은 이를 Pareto, Lognormal, Weibull 분포에 피팅하였고, 그 결과 Pareto 분포에 가장 가까운 것을 확인하였다.

키워드 : 안드로이드, 트레이스, 워크로드, 모바일

1. 서론

최근 몇 년간 모바일 분야에서 기술적으로 많은 발전을 이룩하였다. 이 성장의 배경으로는 낸드 플래시 메모리와 이를 기반으로 하는 SSD의 성장이 있었다. 낸드 플래시 메모리는 기존의 HDD에 비해 크기는 작으면서 낮은 전력으로 높은 성능을 나타내는 스토리지이다. 낸드 플래시의 높은 성능과 안정성으로 인해 모바일 환경뿐만 아니라 서버와 개인 컴퓨팅 영역으로 확장되어 사용되고 있다. 그러나 낸드 플래시 메모

리의 물리적인 특성으로 인하여 일정 수의 쓰기 연산을 수행한 뒤에는 사용할 수 없다. 즉, 수명에 제한이 있다. 따라서 낸드 플래시 및 SSD의 한정된 수명을 예측하기 위한 많은 연구가 진행되었다.

낸드 플래시 메모리의 수명에 영향을 주는 요소들은 대부분 FTL, OVP 등의 낸드 플래시의 내부 요소들이다. 워크로드는 외부 요소 중에 하나인데 내부 요소들에 비해 수명에 주는 영향력이 크다. 현재까지의 낸드 플래시 수명 연구에서 사용하는 워크로드는 임의의 형태로 가공한 워크로드로서 대부분 균등 분포 워크로드(Uniformly distributed workload)이다. 이는 수명 분석을 단순화 시켜서 쉬운 분석을 가능하게 하지만, 실제로 워크로드가 균등분포로 발생하지 않기 때문에 정확성은 매우 떨어진다. 낸드 플래시의 수명 연구를 위해서 워크로드 패턴 분석이 필수적이다. 현재 발표된 대부분의 낸드 플래시 수명 연구는 개인용 컴퓨터나 서버 환경에서 연구한 결과들이다. HDD에서의 워크로드 분석이 많이 되어 있어서 그것을 낸드 플래시 수명 연구에 점점 대입하고 있는 추세이다. 이에 비해 모바일 분야에서의 수명 연구는 최근 모

* 본 연구는 2018년도 정부(과학기술정보통신부)의 재원으로 정보통신기술진흥센터의 지원을 받아 수행된 연구임(2018-0-00549, 매니코어 조애용량 메모리를 위한 확장형 순시보장 운영체제 개발).

** 본 연구는 2017년도 미래창조과학부의 재원으로 한국연구재단 기초연구실지원사업의 지원을 받아 수행된 연구임(No. 2017R1A4A1015498).

† 정 회 원 : 한양대학교 컴퓨터소프트웨어학과 박사과정

** 정 회 원 : 한국과학기술원 전기및전자공학부 교수

*** 비 회 원 : 한양대학교 컴퓨터소프트웨어학과 교수

Manuscript Received : July 25, 2019

First Revision : September 19, 2019

Accepted : September 19, 2019

* Corresponding Author : Youjip Won(ywon@kaist.ac.kr)

바일 분야의 성장세에 비하여 거의 없다. 모바일 환경에서의 워크로드 분석이 잘 되어있지 않기 때문이다. 모바일 환경에서의 워크로드는 기존의 개인용 컴퓨터나 서버 환경에서 발생하는 워크로드와는 차이가 있다. 그렇기 때문에 기존 환경에서의 워크로드로 모바일 환경의 연구를 진행하면 그 결과를 신뢰할 수 없다.

이 논문에서는 모바일 환경에서 낸드 플래시 기반 스토리지에서 발생하는 워크로드를 분석하였다. 이를 위해 실제 모바일 장치인 안드로이드 기반의 스마트폰을 사용할 때 발생하는 트레이스를 수집하고, 이 트레이스가 어떤 형태로 분포되어 있는지 분석하였다.

2. 관련 연구

개인용 컴퓨터, 클라우드 시스템 혹은 서버, 슈퍼 컴퓨터 등에서 워크로드를 분석하여 특성화하는 연구는 많이 진행되어 왔다. 모바일 환경에서 발생하는 워크로드를 분석하기 위하여 다음의 연구물들을 참고하였다. 모바일 환경의 연구를 위함으로 분석 결과보다는 분석 대상과 분석 방법 등을 주로 참고하였다.

Kavalanekar et al.[1]은 윈도우 서버에서 발생하는 스토리지 트레이스를 수집하여 블록레벨 통계, 멀티 파라미터 분포, 파일 액세스 빈도 순위에 따른 입출력 분포 등을 분석하고 특성화하였다.

Darshan[2]는 HPC 환경에서 병렬 IO를 캡처하여 분석하는 병렬 IO 특성화 도구이다. 응용프로그램 수준에서 IO 동작을 캡처하고, IO 트레이싱 방식이 아닌 누적 타이밍 정보를 사용하는 방식으로 시스템 자원 사용을 최소화하여 오버헤드를 줄였다. POSIX 연산, MPI-IP 연산, MPI-IO 등의 데이터를 수집하여 분석할 수 있다.

Khan et al.[3]은 클라우드 컴퓨팅 환경의 VM에서 발생하는 워크로드를 특성화 하였다. VM간의 상관관계가 있는 워크로드 패턴을 CPU 사용률에 따라 특성화하고, 이를 통해 각 VM에서 발생하는 워크로드를 예측하였다.

Casalichio et al.[4]도 클라우드 환경에서의 워크로드를 분석하였다. 클라이언트에서 발생하는 워크로드를 수집하여 액세스 패턴과 일일 액세스 패턴, 세션 길이, CPU 부하, IO 비율 등을 특성화하였다.

Liu et al.[5]는 클라우드 스토리지 시스템의 액세스 트레이스를 분석하였다. 서비스 이용자의 스토리지 사용량, 파일 크기, 카운트, 용량, 서비스 사용이 많은 파일 타입 등을 분석하였다.

Atikoglu et al.[6]은 키-밸류 스토어의 워크로드를 분석하였다. 이를 위하여 Facebook Memcached의 데이터를 이용하였다. 시간에 따라 변동되는 캐시 히트율과 지역성, IO 비율 등을 분석하였다.

Alam et al.[7]은 Google 클러스터 트레이스를 분석하였다. 워크로드를 CPU나 메모리 같은 자원의 소모량과 사용 패턴에 따라서 분류하였다.

AID(Automatic I/O Diverter)[8]은 자동으로 IO를 분석하

여 IO 집약적인 작업을 식별하고 이를 스케줄링하는 애플리케이션이다. 슈퍼컴퓨터에서 IO 집약적인 작업의 충돌을 줄이는 것이 목적이다.

Gunasekaran et al.[9]는 슈퍼컴퓨터용 파일시스템과 그 개량 버전을 개발하고, 두 개의 파일시스템에서 발생하는 워크로드 특성을 비교하였다. IO 비율, 대역폭 사용량, 파일시스템 용량, IO 크기의 분포 등을 분석하고 비교하였다.

White et al.[10]은 슈퍼컴퓨터의 워크로드를 분석하였다. 기존에 공개되어 있는 워크로드 분석 도구를 이용하여 수집 및 분석하였다. 시스템 로그, IO, 라이브러리, 애플리케이션 정보 등을 수집하고 분석하였다.

3. 트레이스 수집 및 분석

3.1 트레이스 수집

모바일 환경에서의 트레이스 수집을 위하여 데이터 수집이 용이하고 사용자를 모집하기 비교적 쉬운 안드로이드 기기를 사용하기로 하였다. 실험의 동일성을 위하여 한 가지의 안드로이드 기반 스마트폰(LG G4)을 선정하였다. 해당 기기에 안드로이드 트레이스 수집 및 분석을 위한 프로그램인 AndroTrace[11]을 설치하고, 이를 통하여 트레이스 수집과 분석을 진행하였다. AndroTrace는 안드로이드 기기에서 발생하는 모든 IO 정보를 수집하여 주기적으로 우리의 분석 서버로 수집한 데이터를 전송한다.

트레이스 수집을 위하여 참여 희망자를 모집하였다. 참여 희망 신청자 중에서 실험 참여자를 무작위로 선정하여 소정의 사례를 하고 트레이스 수집에 도움을 받았다. AndroTrace를 설치한 안드로이드 기기를 빌려주어 자신이 원하는 기간 동안 자신의 스마트폰처럼 사용하도록 하였다. AndroTrace가 설치된 것 이외의 환경은 스마트폰의 초기 상태와 동일하다. 실험 참여자는 5명을 선정하였고, 각 사용자별 트레이스 수집 기간은 Table 1과 같다. 3명의 사용자는 2달 이상의 비교적 장기간 실험에 참여하였고, 2명의 사용자는 1달 미만의 짧은 기간 동안만 참여하였다. 이와 같은 방법으로 스마트폰을 실제로 사용하였을 때 발생하는 트레이스를 수집하였다.

Table 1. Duration of Trace Collection

User	Start	End	Duration
1	Jul 10, 2015	Oct 14, 2015	97 days
2	Jul 10, 2015	Nov 4, 2015	118 days
3	Oct 22, 2015	Dec 29, 2015	69 days
4	Oct 5, 2015	Oct 20, 2015	16 days
5	Oct 3, 2015	Oct 25, 2015	23 days

3.2 트레이스 분석

Table 2는 각 사용자별로 수집된 트레이스의 카운트 수를 정리한 표이다. 2번 사용자가 하루 평균 약 722만개의 트레이스를 발생하여 가장 많이 사용하였다. 사용 기간이 가장 길고 일일 사용량도 가장 많다. 그러나 많은 사용량에 비해

쓰기 연산의 비율은 가장 낮다. 5번 사용자는 다른 사용자와는 달리 트레이스 발생량이 하루에 2만개도 되지 않을 정도로 매우 조금 사용하였다.

Table 2. Trace Summary

User	total count	per day	write count	write ratio
1	249,803,001	2,575,289	28,203,595	11.3%
2	852,472,729	7,224,345	41,369,379	4.9%
3	202,513,380	2,934,977	43,940,040	21.7%
4	19,885,081	1,242,818	2,707,908	13.6%
5	367,723	15,988	151,698	41.3%

2번 사용자는 많은 사용에 비해 쓰기의 비중이 5%도 되지 않을 정도로 쓰기의 양이 매우 적다. 그러나 5번사용자는 트레이스에서 쓰기의 비중이 40%가 넘는다. 전체 트레이스에서 쓰기의 비중은 약 9%정도로 읽기의 비중이 매우 높다.

읽기 연산은 낸드 플래시 스토리지의 수명에 영향이 없기 때문에, 이 논문에서는 쓰기 연산에 대해서만 분석하였다.

3.3 Hotness 분류

Fig. 1은 각 사용자 별 LBA 쓰기 발생 횟수를 기록한 그래프이다. x축은 각 사용자 별로 LBA 쓰기 횟수가 많은 순서로 정렬한 순위를 백분율로 나타내었고, y축은 각 순위별 쓰기 비율이다. 그래프를 통하여 상위 약 10%의 LBA에서 대부분의 쓰기가 발생하는 것을 확인할 수 있다. 수집한 트레이스에서 쓰기 명령의 90% 정도가 LBA의 상위 10% 영역에서 발생한다.

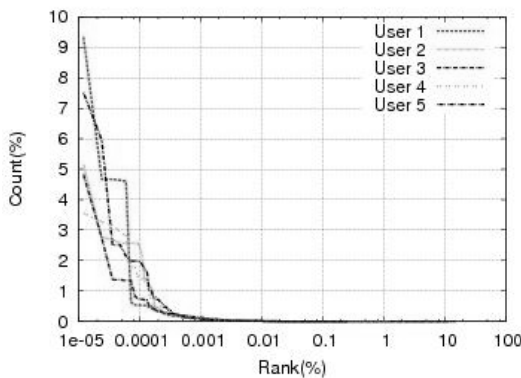


Fig. 1. Popularity vs. Access Frequency

LBA 쓰기 발생 횟수를 몇 개의 hotness 그룹으로 분류하였다. hotness 분류 알고리즘은 여러 가지가 있는데 우리는 iterative segment quantization 알고리즘[12]를 사용하였다. 이 알고리즘은 그룹을 k개로 분할하여 iterative refinement approach를 통하여 각 그룹의 중심을 찾아가는 방식이다. 알고리즘의 특성상 적용할 때마다 결과가 조금씩 다르게 나타나기 때문에, 각 사용자 별로 5회 반복 적용하여 나온 결과 평균값으로 분류 결과를 나타내었다. 또한, 각 사용자 별로

같은 그룹을 평균을 계산하여 그룹별 비율과 비중을 구하였다.

Table 3은 hotness 그룹의 수를 3,4,5개로 하였을 때, 각 그룹 영역의 비율과, 해당 영역에서의 쓰기 비율을 나타낸 표이다. 즉, 3개의 그룹으로 나누었을 때, 상위 0.04%의 LBA에 전체의 31%의 쓰기가 발생하고, 두번째 상위 0.13%의 LBA에 24%의 write가 발생하고, 그 다음 11.58%의 LBA에 나머지 45%의 write가 발생한다. 그룹의 3개 일 때와 4개 일 때, 상위 2개의 그룹은 일치하고, 세번째 그룹이 분할되는 형태로 나타난다. 5개의 그룹일 때의 상위 2개 그룹은 완전히 일치하지는 않지만, 비슷한 크기와 비율로 분류되는 것을 확인할 수 있다. 이것은 상위 LBA에서의 쓰기 연산의 수가 압도적으로 많기 때문이다.

Table 3. Workload Classification (%)

Groups	1st	2nd	3rd	4th	5th	
3	ratio	0.04	0.13	11.58		
	frequency	31	24	45		
4	ratio	0.04	0.13	0.44	11.14	
	frequency	31	24	30	15	
5	ratio	0.03	0.12	0.11	0.50	10.99
	frequency	30	17	17	23	13

가장 적절한 그룹의 개수를 구하기 위하여 분류의 척도를 나타내는 실루엣[13, 14]을 적용하였다. 실루엣 $s(i)$ 는 다음과 같이 정의한다.

$$s(i) = \frac{b(i) - a(i)}{\max[a(i), b(i)]} \quad (1)$$

$a(i)$ 는 샘플 i 에서 같은 클러스터의 다른 샘플까지의 평균 거리이고, $b(i)$ 는 다른 클러스터의 평균 거리의 최솟값이다. 실루엣은 정의에 따라 -1~1의 값을 가지며 분류가 완벽할수록 1에 가깝다.

앞의 분류 결과에 실루엣을 적용하면, 3개의 그룹으로 나누었을 때 실루엣 값은 약 0.35, 4개의 그룹으로 나누었을 때는 약 0.33, 5개의 그룹으로 나누었을 때는 약 0.26이다. 수집한 트레이스는 3개의 hotness로 분류하는 것이 가장 타당하다고 할 수 있다.

실사용 안드로이드 트레이스의 hotness 분류 결과는 다음과 같다. 0.04% LBA 영역에 31%의 빈도, 0.13%의 영역에 24%의 빈도, 11.58%의 영역에 45%빈도로 트레이스가 분포되어 있다.

3.4 꼬리 분포 분석

Fig. 1의 그래프는 꼬리가 굉장히 긴 무거운 꼬리(Heavy Tail) 형태로 나타난다. 이 그래프의 꼬리 부분이 무겁게 나온다는 것은 쓰기 횟수가 적은 LBA가 매우 많다는 것을 의미한다. 머리 부분의 쓰기 연산의 양을 고려하여 생각하면, 굉장히 많은 임의 쓰기가 발생하고 있다는 것을 유추할 수

있다. 임의 쓰기는 SSD 내부의 과편화를 증가시켜서 수명을 단축시키는데 큰 역할을 한다. 이러한 임의 쓰기의 패턴 예측을 위하여 확률 분포를 아는 것이 중요하다고 판단하였다. 따라서 트레이스 수집 결과를 최대 우도 추정(MLE: Maximum Likelihood Estimation)[15] 방법을 사용하여 가장 적합한 분포 유형을 결정하였다. 최대 우도 추정 방법은 매개변수를 모르는 확률 변수에서 뽑은 표본(관측 값)을 바탕으로 매개변수를 추정하는 방법이다. 우도 값을 가장 크게 만드는 매개변수를 선택한다. 우도(Likelihood)는 표본으로 매개변수를 추정하였을 때, 해당 매개변수로부터 표본 값이 나올 가능성을 나타내는 지표이다. 즉, 우도의 값이 클수록 매개변수를 적절하게 구하였다고 할 수 있다. Table 4는 피팅에 사용한 확률 분포 함수와 이에 해당하는 매개 변수를 나타낸 표이다. 이 확률 분포 함수를 사용한 이유는 다음과 같다.

Table 4. Fitting Distributions

Distribution	PDF	Params
Pareto	$f(x) = \frac{\alpha k^\alpha}{x^{\alpha+1}}$	$\alpha > 0, k > 0$
Lognormal	$f(x) = \frac{1}{x \sqrt{2\pi} \sigma} e^{-\frac{(\ln x - \mu)^2}{2\sigma^2}}$	μ, σ
Weibull	$f(x) = \frac{\alpha}{\beta} \left(\frac{x}{\beta}\right)^{\alpha-1} e^{-(x/\beta)^\alpha}$	$\alpha > 0, \beta > 0$

Pareto 분포[15, 16]는 사회과학, 지구물리학 등의 많은 현상에 대한 설명에 사용되는 지수 함수 확률 분포이다. ‘사회의 80%의 부를 20%의 인구가 보유하고 있다’는 80-20 법칙을 주장한 이탈리아의 경제학자인 Vilfredo Pareto의 이름을 따왔다. 원래는 부의 분배를 설명하는데 있어서 적용되었지만, 자연 현상과 인류의 활동 등 광범위한 경우에서 80-20 법칙이 적용되는 것이 관찰되어 다양한 경우에 적용되고 있다. 우리의 데이터도 상위의 소규모 그룹에서 대부분의 쓰기연산이 발생하기 때문에 Pareto 분포가 적합하다고 판단하였다. Pareto 분포의 확률 분포 함수와 매개 변수는 Table 4의 첫째 줄과 같다. 여기서 매개변수 α 는 Pareto 지표라는 매개변수로 α 가 클수록 더 큰 불평등을 나타내고, 0에 가까울수록 해당 분포는 균등분포에 가깝다.

Lognormal 분포[16]은 자연 로그(Natural Logarithm)를 취하면 정규 분포(Normal Distribution)를 따르는 확률변수의 분포이다. 로그는 음수에서 정의되지 않기 때문에 확률변수 x 는 0보다 커야한다. 또한 lognormal 분포의 확률 분포 함수는 확률변수 x 가 작을 때 높은 값을 가지고, x 가 증가함에 따라 급격히 작아지는 추세를 나타낸다. 따라서 lognormal 분포도 우리의 데이터를 피팅하는데 적합하다고 판단하였다.

Weibull 분포[16]은 신뢰도 분석, 생존 분석 등에서 사용되는 확률분포이다. 스웨덴의 수학자인 Waloddi Weibull의 이름을 따왔다. 주로 한쪽으로 치우친 형태의 데이터나 대칭적인 형태의 데이터를 분석하는데 사용된다. 매개변수 α 는 형

상 매개변수(shape parameter)로 $\alpha=1$ 이면, 해당 분포는 지수 분포(Exponential Distribution)와 같다. 매개변수 β 는 규모 매개변수(Scale Parameter)이다. 우리의 데이터도 한쪽으로 치우친 형태의 데이터로 Weibull 분포로 분석하는데 적합하다고 판단하였다.




Fig. 2. LLCD of Page Counts

Fig. 2는 각 사용자별로 페이지 쓰기 횟수에 대한 페이지 수의 비율을 LLCD(log-log complementary distributions) [15, 16]로 나타낸 그래프이다. LLCD는 log-log 축에 대하여 상보적 누적분포 $P[X > x]$ 를 보여준다. 카운트 수가 적은 페이지가 전체의 대다수이고, 소수의 페이지가 많은 카운트 수를 차지하는 것을 확인할 수 있다.

Fig. 2의 자료를 최대 우도 추정 방법을 통해 적합한 확률 분포를 결정하였다. 표 5는 최대 가능 추정 방법으로 구한 분포별 매개변수의 값이다. Pareto 분포의 매개변수 k 는 모든 사용자에게 대해서 1이다.

Table 5. Parameters for Each Distribution

User	Pareto	Lognormal		Weibull	
	α	μ	σ	α	β
1	0.917	0.839	1.567	0.386	5.899
2	0.953	0.808	1.601	0.378	5.872
3	0.978	1.220	1.790	0.370	9.532
4	0.933	1.151	1.838	0.365	9.461
5	1.048	0.962	1.798	0.366	7.715




Fig. 3. Log-likelihood for Each Distribution

Fig. 3은 각 사용자 별로 표 5의 매개변수에 대한 로그-우도(log-likelihood)의 값을 나타낸 그래프이다. 로그-우도는 우도의 자연 로그 값이다. 우도와 마찬가지로 로그-우도가 클수록 피팅이 잘 된 것이라고 할 수 있다. Pareto 분포로 피팅 하였을 때 로그-우도의 값은 약 $-0.461 \sim -0.402$ 이다. lognormal 분포로 피팅 하였을 때는 약 $-0.839 \sim -0.807$ 이고, Weibull 분포로 피팅 하였을 때는 약 $-0.601 \sim -0.508$ 이다. Pareto 분포가 다른 분포들 보다 더 큰 로그-우도 값을 가지는 것을 확인하였다. 따라서 우리가 수집한 데이터는 Pareto 분포에 가깝다고 할 수 있다. 이 분석 결과들을 바탕으로 낸드 플래시 메모리의 수명 연구를 위한 워크로드를 모델링 할 수 있다. 우리가 수집한 워크로드는 hotness 그룹을 3개로 하는 Pareto 분포로 모델링 할 수 있다.

4. 결 론

모바일 환경에서의 낸드 플래시 메모리 수명 연구를 위하여 실제 스마트폰을 사용하면서 발생하는 워크로드를 수집하고 분석하였다. 이를 통하여 모바일 환경에서 발생하는 워크로드의 I/O 형태와 분포를 알 수 있었다.

사용자에 따라 조금 다르지만 트레이스의 쓰기과 읽기의 비율은 약 1:9 정도로 읽기의 비율이 압도적으로 높았다. 또한 전체 LBA영역의 약 10% 정도 되는 좁은 영역에서 쓰기 연산 발생하는 것을 확인하였다.

워크로드를 LBA에 접근하는 빈도에 따라 3,4,5개의 hotness 그룹으로 나누었다. 상위 그룹에 접근하는 빈도가 중하위 그룹에 비해 매우 높아서 그룹의 수에 관계없이 상위 2개의 그룹의 분류 결과는 비슷하다. 또한 워크로드를 3개 그룹으로 나누는 것이 가장 적합하다.

우리는 또한 모바일 워크로드의 꼬리 분포 분석을 위하여 수집한 워크로드를 Pareto, Lognormal, Weibull 분포에 피팅하여 적합한 분포를 찾아보았다. 우리가 수집한 모바일 워크로드는 Pareto 분포에 가장 잘 맞는 것을 확인하였다. SSD의 수명 연구를 위한 모바일 워크로드는 Pareto 분포로 모델링 할 수 있다.

References

- [1] S. Kavalanekar, B. Worthington, Q. Zhang, and V. Sharda, "Characterization of Storage Workload Traces from Production Windows Servers," *Proceedings of the 2008 IEEE International Symposium on Workload Characterization*, pp. 119-128. Seattle, WA, USA. Sep. 2008.
- [2] P. Carns, R. Latham, R. Ross, K. Iskra, S. Lang, and K. Riley, "24/7 Characterization of Petascale I/O Workloads," *Proceedings of the 2009 IEEE International Conference on Cluster Computing and Workshops*, New Orleans, Louisiana, USA. Aug. 2009.
- [3] A. Khan, X. Yan, S. Tao, and N. Anerousis, "Workload Characterization and Prediction in the Cloud: A Multiple Time Series Approach," *Proceedings of the 2012 IEEE Network Operations and Management Symposium*, pp.1287-1294. Maui, Hawaii, USA. Apr. 2012.
- [4] E. Casalicchio, S. Iannucci, and L. Silvestri, "Cloud Desktop Workload: a Characterization Study," *Proceedings of the 2015 IEEE International Conference on Cloud Engineering*, pp. 66-75. Tempe, AZ, USA. Mar. 2015.
- [5] S. Liu, X. Huang, H. Fu, and G. Yang, "Understanding Data Characteristics and Access Patterns in a Cloud Storage System," *Proceedings of the 2013 13th IEEE/ACM International Symposium on Cluster, Cloud, and Grid Computing*, pp.327-334. Delft, Netherlands. May 2013.
- [6] B. Atikoglu, Y. Xu, E. Frachtenberg, S. Jiang, and M. Paleczny, "Workload Analysis of a Large-Scale Key-Value Store," *Proceedings of the 12th ACM SIGMETRICS/PERFORMANCE Joint International Conference on Measurement and Modeling of Computer Systems*, pp.53-64. London, UK. Jun. 2012.
- [7] M. Alam, K. A. Shakil, and S. Sethi, "Analysis and Clustering of Workload in Google Cluster Trace based on Resource Usage," *Proceedings of the 2016 IEEE Intl Conference on Computational Science and Engineering (CSE) and IEEE Intl Conference on Embedded and Ubiquitous Computing (EUC) and 15th Intl Symposium on Distributed Computing and Applications for Business Engineering (DCABES)*, pp. 740-747. Paris, France. Aug. 2016.
- [8] Y. Liu, R. Gunasekaran, X. Ma, and S. S. Vazhkudai, "Server-side Log Data Analytics for I/O Workload Characterization and Coordination on Large Shared Storage Systems," *Proceedings of the International Conference for High Performance Computing, Networking, Storage and Analysis*, pp.819-829. Salt Lake City, Utah, USA. Nov. 2016.
- [9] R. Gunasekaran, S. Oral, J. Hill, R. Miller, F. Wang, and D. Leverman, "Comparative I/O Workload Characterization of Two Leadership Class Storage Clusters," *Proceedings of the 10th Parallel Data Storage Workshop*, pp.31-36. Austin, TX, USA. Nov. 2015.
- [10] J. P. White, M. Innus, M. D. Jones, R. L. DeLeon, N. Simakov, J. T. Palmer, S. M. Gallo, T. R. Furlani, M. Showerman, R. Brunner, A. Kot, G. Bauer, B. Bode, J. Enos, and W. Kramer, "Challenges of Workload Analysis on Large HPC Systems: A Case Study on NCSA Blue Waters," *Proceedings of the Practice and Experience in Advanced Research Computing*, New Orleans, Louisiana, USA. Jul. 2017.
- [11] E. Lim, S. Lee, and Y. Won, "Androtrace: Framework for Tracing and Analyzing IOs on Android." *Proceedings of the 3rd Workshop on Interactions of NVM/FLASH with Operating Systems and Workloads*, Monterey, CA, USA, Oct. 2015.
- [12] C. Min, K. Kim, H. Cho, S.-W. Lee, and Y. I. Eom, "SFS: Random Write Considered Harmful in Solid State Drives," *Proceedings of the 10th USENIX conference on File and*

Storage Technologies, San Jose, CA, USA. Feb. 2012.

- [13] B. Seo, S. Kang, J. Choi, J. Cha Y. Won, and S. Yoon, "Io workload characterization revisited: A data-mining approach," *IEEE Trans. Computer*, Vol.63, No.12, pp.3026-3038, Dec. 2014.
- [14] P. N. Tan, M. Steinbach, and V. Kumar, "Introduction to Data Mining, (First Edition)," Addison-Wesley Longman Publishing Co., Inc., 2005.
- [15] B. C. Arnold, "Pareto Distributions (Second Edition)," CRC Press, Taylor & Francis Group, 2015.
- [16] R. Adler, R. Feldman, and M. Taqqu, "A Practical Guide to Heavy Tails: Statistical Techniques and Applications," Birkhauser, 1998.



박창현

<https://orcid.org/0000-0002-7253-2028>

e-mail : pch1984@hanyang.ac.kr

2010년 한양대학교 전자통신컴퓨터공학부 (학사)

2013년 한양대학교 전자컴퓨터통신공학부 (석사)

2013년~현재 한양대학교 컴퓨터소프트웨어학과 박사과정
관심분야: 운영체제, 스토리지 시스템, 모바일 스토리지



원유집

<https://orcid.org/0000-0001-7178-5245>

e-mail : ywon@kaist.ac.kr

1990년 서울대학교 계산통계학과(학사)

1992년 서울대학교 계산통계학과(석사)

1997년 University of Minnesota
전산학과(박사)

2019년~현재 한국과학기술원 전기및전자공학부 교수
관심분야: 운영체제, 파일 시스템, 스토리지 시스템



박영준

<https://orcid.org/0000-0003-3725-0380>

e-mail : yongjunpark@hanyang.ac.kr

2007년 포항공과대학교 전기전자공학과 (학사)

2009년 University of Michigan
전자공학과(석사)

2013년 University of Michigan 전자공학과(박사)
2017년~현재 한양대학교 컴퓨터소프트웨어학과 교수
관심분야: 컴퓨터 구조, 운영체제, 컴파일러