



Single Layer Neural Network for Real-time HAR

CAU Artificial Intelligence LAB

임원선

costor107@gmail.com


14th September, 2021

To do list

1. 기존 논문에서 HAR 모델을 보통 3~5개의 layer를 사용한다는 내용 추가
2. Hyperparameter를 늘리는 실험으로 operator의 수를 늘려서 실험
3. 핸드폰의 latency는 포기
4. Search space의 각 operator에 대한 Complexity를 제공




기존 HAR 연구의 모델 구조

1. [IEEE Sensors, 2021] TANG et al. : 3 Conv Layer
2. [Applied Science, 2020]Peppas. et al. : 2 Conv Layer
3. [IEEE TRANSACTIONS ON INDUSTRIAL INFORMATICS, 2020]Eunji Kim : 3 Conv Layer
4. [IEEE Access, 2019]C. Xu et al. : 4 Conv Layer
5. [IEEE Access, 2018]Rui Xi. et al. : 3 Conv Layer + 2 SRU Layer



②

Layer Name	Kernel Size	Stride	Hidden Units
1D conv ReLU 1	12×3	1	-
1D Max Pooling 1	3×1	3	-
1D conv ReLU 2	12×192	1	-
1D Max Pooling 1	3×1	3	-
Flatten	-	-	-
Concat	-	-	-
FC ReLU	-	-	512
Softmax	-	-	6



Search Space의 Operators

✓ Complexity 비교 : Module) ④ $\geq$ ⑤ , Conv) ① $>$ ③ $\geq$ ②

Input Channel : M, Output Channel : N, Kernel Size : K, Input & Output Length : T_i & T_o

1. Standard Convolution

- Computational Complexity : $O(K * M * T_o * N)$

2. Depthwise Seperable Convolution

- Computational Complexity : $O((K+N) * T_o * M)$

3. Mixed Convolution

- j-th Group Input & Output Channel Size : M_j & N_j , j-th Group Kernel Size: $K_j \{3, 5, 7, 9\}$
- Computational Complexity : $O(\sum(K_j + N_j) * T_o * M_j)$

4. Dynamic Convolution(구현 이슈로 보류) : Same Output but Big Model size

- Temperature Constant : r
- Computational Complexity : $O(K * M * T_o * N) + O(\pi)$
- Attention Module : $O(\pi) : T_i * M + M^2/r + M*K/r$

5. Convolutional Block Attention Module(CBAM)

- Computational Complexity : $O(\pi_c) + O(\pi_s)$
- Channel Attention Module : $O(\pi_c)$
- Spatial Attention Module : $O(\pi_s)$

Layer 별 탐색 공간

- ✓ 3번 Mixed Convolution과 5번 Convolutional Attention Block Module(CBAM)은 연산자의 특성으로 인해 1 Layer에 적용 불가하여 2~3 Layer부터 탐색

1. 1-Layer

- Operators : {Standard Conv, Depthwise Seperable Conv}
- Dilation : {1, 2}
- Kernel Size : {3, 5, 7, 9}
- 총 16 개

2. 2~3 Layer

- Operators : {Standard Conv, Depthwise Seperable Conv, CBAM}
- Dilation : {1, 2}
- Kernel Size : {3, 5, 7, 9}
- Operator : {3x5_Mixed Conv, 3x5x7_Mixed Conv, 3x5x7x9_Mixed Conv, 3x5x7x9x11_Mixed Conv}
- 총 31 개

실험 결과 정리

✓ 3 Layer 비교 실험 결과 테이블

Method	Dataset	ACC	Flops	Param Size	Layer1	Layer2	Layer3
Manual	UCIHAR	92.77	2.7	0.24	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	UCIHAR	91.55	0.3	0.17	9x1_DepthConv	3x1_CBAMBlock	3x1_DilatedDepthConv
RL(MnasNet)	UCIHAR	89.41	0.2	0.17	9x1_DepthConv	7x1_CBAMBlock	7x1_CBAMBlock
FBNet	UCIHAR	91.75	0.8	0.2	7x1_DilatedDepthConv	5x1_DilatedDepthConv	3x1_DilatedCBAMBlock
DARTs	UCIHAR	93.89	0.9	0.19	9x1_DilatedConv	7x1_DilatedCBAMBlock	5x1_DilatedConv
Manual	UniMiB	94.27	2.3	0.26	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	UniMiB	90.94	0.3	0.21	9x1_DepthConv	7x1_CBAMBlock	3x5x7x9x11_MixedConv
RL(MnasNet)	UniMiB	91.88	0.3	0.21	7x1_DilatedDepthConv	5x1_CBAMBlock	3x5x7_MixedConv
FBNet	UniMiB	91.05	1.9	0.24	7x1_DilatedDepthConv	3x1_DepthConv	7x1_DilatedConv
DARTs	UniMiB	90.94	0.5	0.21	5x1_DepthConv	3x5_MixedConv	3x1_DepthConv
Manual	WISDM	84.67	1	0.16	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	WISDM	83.38	0.3	0.11	7x1_DilatedConv	3x5x7x9x11_MixedConv	7x1_DilatedCBAMBlock
RL(MnasNet)	WISDM	85.29	0.2	0.11	9x1_DilatedDepthConv	3x5_MixedConv	3x1_CBAMBlock
FBNet	WISDM	84.28	0.8	0.16	7x1_DilatedConv	5x1_DilatedDepthConv	5x1_DilatedDepthConv
DARTs	WISDM	82.43	0.3	0.11	5x1_DilatedConv	7x1_DilatedDepthConv	3x5x7x9_MixedConv
Manual	WISDM2019	88.42	3.4	0.33	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	WISDM2019	78.99	0.4	0.27	3x1_DepthConv	3x1_DilatedCBAMBlock	9x1_CBAMBlock
RL(MnasNet)	WISDM2019	83.6	0.5	0.27	5x1_DilatedDepthConv	9x1_DilatedCBAMBlock	3x5x7x9_MixedConv
FBNet	WISDM2019	88.85	1.8	0.29	9x1_DepthConv	7x1_CBAMBlock	5x1_DilatedCBAMBlock
DARTs	WISDM2019	87.89	1.1	0.28	3x1_Conv	3x5_MixedConv	3x1_Conv



Single Layer Neural Network for Real-time HAR

CAU Artificial Intelligence LAB

임원선

costor107@gmail.com

7th September, 2021

To do list

1. Single, 2, 3 Layer에 대한 실험 결과 완성
2. 목표 설정

실험 결과 정리

✓ Single Layer 비교 실험 결과 테이블

Method	Dataset	ACC	Latency	Flops	Param Size	Layer1
Manual	UCIHAR	89.61	2.438	1.8	1.42	7x1_Conv
ProxylessNAS	UCIHAR	90.8	2.356	1.8	1.42	7x1_DilatedConv
RL(MnasNet)	UCIHAR	92.29	2.36	1.9	1.42	9x1_DilatedConv
FBNet	UCIHAR	92.29	2.36	1.9	1.42	9x1_DilatedConv
DARTs	UCIHAR	91.38	2.356	1.8	1.42	7x1_DilatedConv
Manual	UniMiB	82.89	2.729	1.9	1.68	7x1_Conv
ProxylessNAS	UniMiB	82.89	2.729	1.9	1.68	7x1_Conv
RL(MnasNet)	UniMiB	84.28	2.685	1.8	1.68	5x1_DilatedConv
FBNet	UniMiB	80.07	2.729	1.8	1.68	3x1_DilatedConv
DARTs	UniMiB	82.89	2.729	1.9	1.68	7x1_Conv
Manual	WISDM	85.95	1.128	0.7	0.66	7x1_Conv
ProxylessNAS	WISDM	85.57	1.127	0.7	0.66	7x1_DepthConv
RL(MnasNet)	WISDM	85.57	1.127	0.7	0.66	7x1_DepthConv
FBNet	WISDM	85.57	1.127	0.7	0.66	7x1_DepthConv
DARTs	WISDM	85.58	1.124	0.8	0.66	9x1_Conv
Manual	WISDM2019	82.74	4.025	2.7	2.2	7x1_Conv
ProxylessNAS	WISDM2019	78.03	4.063	2.3	2.2	5x1_DepthConv
RL(MnasNet)	WISDM2019	78.03	4.063	2.3	2.2	5x1_DepthConv
FBNet	WISDM2019	77.82	4.063	2.3	2.2	5x1_DepthConv
DARTs	WISDM2019	78.67	4.006	2.3	2.2	9x1_DepthConv

실험 결과 정리

✓ 2 Layer 비교 실험 결과 테이블

Method	Dataset	ACC	Latency	Flops	Param Size	Layer1	Layer2
Manual	UCIHAR	93.92	1.179	2.1	0.53	7x1_Conv	7x1_Conv
ProxylessNAS	UCIHAR	93.62	0.932	1.6	0.52	5x1_DilatedConv	5x1_DilatedConv
RL(MnasNet)	UCIHAR	93.72	1.136	1.1	0.5	9x1_DilatedConv	9x1_DepthConv
FBNet	UCIHAR	93.28	1.056	1.1	0.5	9x1_DilatedConv	5x1_DepthConv
DARTs	UCIHAR	91.68	1.052	1	0.5	7x1_DilatedConv	5x1_DepthConv
Manual	UniMiB	92.1	1.368	2.2	0.59	7x1_Conv	7x1_Conv
ProxylessNAS	UniMiB	87.24	1.064	0.7	0.56	5x1_Conv	Zero
RL(MnasNet)	UniMiB	92.75	1.115	0.8	0.57	9x1_DilDepthConv	5x1_DilDepthConv
FBNet	UniMiB	90.43	1.312	2.5	0.6	9x1_DilDepthConv	9x1_Conv
DARTs	UniMiB	84.49	1.042	0.8	0.56	7x1_Conv	Zero
Manual	WISDM	85.67	0.903	0.9	0.26	7x1_Conv	7x1_Conv
ProxylessNAS	WISDM	83.31	0.665	0.3	0.23	9x1_Conv	Zero
RL(MnasNet)	WISDM	84.77	0.825	0.5	0.25	7x1_DepthConv	3x1_Conv
FBNet	WISDM	85.67	0.903	0.9	0.26	7x1_Conv	7x1_Conv
DARTs	WISDM	83.31	0.665	0.3	0.23	9x1_Conv	Zero
Manual	WISDM2019	89.82	1.876	1.1	0.76	7x1_Conv	7x1_Conv
ProxylessNAS	WISDM2019	83.49	1.314	0.8	0.76	5x1_DilDepthConv	Zero
RL(MnasNet)	WISDM2019	86.28	1.571	1.7	0.77	9x1_DilDepthConv	3x1_DilatedConv
FBNet	WISDM2019	84.46	1.545	1.7	0.77	5x1_DilDepthConv	3x1_DilatedConv
DARTs	WISDM2019	86.28	1.69	1.1	0.76	9x1_DepthConv	7x1_DilDepthConv

실험 결과 정리

✓ 3 Layer 비교 실험 결과 테이블

Method	Dataset	ACC	Latency(S9)	Flops	Param Size	Layer1	Layer2	Layer3
Manual	UCIHAR	92.77	0.936	2.7	0.24	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	UCIHAR	93.38	0.598	0.6	0.17	9x1_DilatedConv	Zero	Zero
RL(MnasNet)	UCIHAR	92.67	1.068	2.4	0.22	9x1_DilatedConv	9x1_Conv	3x1_DilatedConv
FBNet	UCIHAR	93.82	0.984	0.9	0.18	9x1_DilatedConv	5x1_DepthConv	9x1_DilDepthConv
DARTs	UCIHAR	93.18	0.953	1.6	0.2	9x1_DilatedConv	5x1_Conv	5x1_DilDepthConv
Manual	UniMiB	94.27	1.267	2.3	0.26	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	UniMiB	90.79	0.587	0.5	0.2	9x1_DilatedConv	Zero	Zero
RL(MnasNet)	UniMiB	92.97	1.004	1.7	0.24	9x1_DilatedConv	5x1_Conv	3x1_DilatedConv
FBNet	UniMiB	91.59	0.982	1.9	0.24	9x1_DilDepthConv	7x1_DilatedConv	3x1_DilatedConv
DARTs	UniMiB	86.66	1.06	0.9	0.21	3x1_DepthConv	3x1_Conv	Zero
Manual	WISDM	84.67	1.244	1	0.16	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	WISDM	83.79	0.789	0.2	0.1	7x1_Conv	Zero	Zero
RL(MnasNet)	WISDM	85.08	0.912	0.4	0.12	9x1_DilatedConv	3x1_DilatedConv	Zero
FBNet	WISDM	84.8	1.108	0.4	0.12	7x1_Conv	5x1_DepthConv	9x1_Conv
DARTs	WISDM	79.86	0.951	0.2	0.11	7x1_DepthConv	3x1_DepthConv	Zero
Manual	WISDM2019	88.42	1.366	3.4	0.33	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	WISDM2019	87.56	0.805	1	0.29	9x1_DilDepthConv	Zero	7x1_DilatedConv
RL(MnasNet)	WISDM2019	85.42	0.793	0.6	0.28	7x1_DilDepthConv	Zero	3x1_DilatedConv
FBNet	WISDM2019	87.67	1.27	1.5	0.29	5x1_DepthConv	9x1_DilDepthConv	3x1_DilatedConv
DARTs	WISDM2019	86.82	0.975	0.8	0.27	3x1_Conv	5x1_DilDepthConv	Zero

실험 결과 분석 및 정리

1. 정확도 성능 지표상 최소 2개 이상의 layer를 구성하였을 때, 성능의 차이가 적음.
2. Layer의 개수가 많아질수록 operator에 따른 latency의 차이가 나타남.
Ex) Single Layer Model에서는 각 모델 간의 latency의 차이가 작지만, 3 Layer Model에서는 모델 간의 latency 차이가 큼.
3. Layer의 개수에 따라 전체 latency에서 Fully Connected Layer의 latency 비중이 다름.
Ex) Single Layer : FC 66%~90%
2 Layer : FC 30% ~ 60%
3 Layer : FC 15% ~ 30%



Single Layer Neural Network for Real-time HAR

CAU Artificial Intelligence LAB


임원선

costor107@gmail.com

31th August, 2021

To do list

1. Single Layer에 대한 실험 결과
2. 기존 3가지와 추가적으로 유명한 2가지 알고리즘 실험(Fbnet, DARTs)
3. 그 중 Baseline 설정
4. Search Space 늘려서 실험 8 -> 16



실험 결과 정리


✓ Single Layer 비교 실험 결과 테이블

Method	Dataset	ACC	Latency	Flops	Param Size	Layer1, Probability
Manual	UCIHAR	89.61	2.438	1.8	1.42	7x1_Conv
ProxylessNAS	UCIHAR	90.8	2.356	1.8	1.42	7x1_DilatedConv, 0.101
RL(MnasNet)	UCIHAR	92.29	2.36	1.9	1.42	9x1_DilatedConv, 0.895
FBNet	UCIHAR	92.29	2.36	1.9	1.42	9x1_DilatedConv, 0.076
DARTs	UCIHAR	91.38	2.356	1.8	1.42	7x1_DilatedConv, 0.096
Manual	UniMiB	82.89	2.729	1.9	1.68	7x1_Conv
ProxylessNAS	UniMiB	82.89	2.729	1.9	1.68	7x1_Conv, 0.080
RL(MnasNet)	UniMiB	84.28	2.685	1.8	1.68	5x1_DilatedConv, 0.136
FBNet	UniMiB	80.07	2.729	1.8	1.68	3x1_DilatedConv, 0.076
DARTs	UniMiB	82.89	2.729	1.9	1.68	7x1_Conv, 0.080
Manual	WISDM	85.95	1.128	0.7	0.66	7x1_Conv
ProxylessNAS	WISDM	85.57	1.127	0.7	0.66	7x1_DepthConv, 0.252
RL(MnasNet)	WISDM	85.57	1.127	0.7	0.66	7x1_DepthConv, 0.936
FBNet	WISDM	85.57	1.127	0.7	0.66	7x1_DepthConv, 0.097
DARTs	WISDM	85.58	1.124	0.8	0.66	9x1_Conv, 0.162
Manual	WISDM2019	82.74	4.025	2.7	2.2	7x1_Conv
ProxylessNAS	WISDM2019	78.03	4.063	2.3	2.2	5x1_DepthConv, 0.090
RL(MnasNet)	WISDM2019	78.03	4.063	2.3	2.2	5x1_DepthConv, 0.481
FBNet	WISDM2019	77.82	4.063	2.3	2.2	5x1_DepthConv, 0.093
DARTs	WISDM2019	78.67	4.006	2.3	2.2	9x1_DepthConv, 0.090

실험 결과 정리

✓ 3 Layer 비교 실험 결과 테이블

Method	Dataset	ACC	Latency	Flops	Param Size	Layer1	Layer2	Layer3
Manual	UCIHAR	92.09	1.22	2.2	0.23	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	UCIHAR	92.56	0.59	0.5	0.17	7x1_DilatedConv	Zero	Zero
RL(MnasNet)	UCIHAR	92.73	0.87	1.4	0.2	9x1_DilatedConv	3x1_DilatedConv	5x1_DilatedConv
Manual	UniMiB	93.98	1.267	2.3	0.26	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	UniMiB	84.56	0.573	0.34	0.2	5x1_DilatedConv	Zero	Zero
RL(MnasNet)	UniMiB	93.04	0.871	1.9	0.25	5x1_DilatedConv	5x1_DilatedConv	7x1_DilatedConv
Manual	WISDM2019	88.42	1.366	3.4	0.33	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	WISDM2019	83.17	0.7	0.6	0.27	5x1_DilatedConv	Zero	Zero
RL(MnasNet)	WISDM2019	83.17	0.7	0.6	0.27	5x1_DilatedConv	Zero	Zero



실험 결과 분석 및 정리

1. Single Layer 상황에서는 Operation에 따른 latency 차이가 크지 않고, 정확도의 차이가 드러남.
2. 연구 목표 : Latency는 고정된 factor이고 Accuracy를 목표
3. Single layer 상황에서 NAS의 필요성을 주장하기 부족
 - 그러나 NAS가 효과적인 operator를 찾는다는 것은 기존 연구들에서 실험적 증거가 제시됨
4. 효과적인 Operator를 제안
5. Proposed operator의 효과성을 NAS 알고리즘을 통해 실험적 증거 제시
 - NAS 알고리즘을 통해 proposed operator가 선택된다는 것을 실험적 증거 제시



Searching Efficient HAR Neural Networks

CAU Artificial Intelligence LAB

임원선

costor107@gmail.com

24th August, 2021

실험 결과 정리

✓ 비교 실험 알고리즘


1. Manual : 수동으로 설계된 모델
2. ProxylessNAS : Differentiable NAS기반으로 Latency와 정확도를 목적 함수로 설계하여 탐색된 모델
3. RL(MnasNet) : 강화학습 기반으로 Latency와 정확도를 목적 함수로 설계하여 탐색된 모델
(* MnasNet의 강화학습 알고리즘 부분만을 가져와서 적용.)

실험 결과 정리

✓ 비교 실험 결과 테이블

- **Zero Layer** : 입력 받은 input을 다음 layer로 그대로 전달하는 layer

Method	Dataset	Target	ACC	Latency	Flops	Param Size	Layer1	Layer2	Layer3
Manual	UCIHAR	s9	92.09	1.22	2.2	0.23	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	UCIHAR	s9	92.56	0.59	0.5	0.17	7x1_DilatedConv	Zero	Zero
RL(MnasNet)	UCIHAR	s9	92.73	0.87	1.4	0.2	9x1_DilatedConv	3x1_DilatedConv	5x1_DilatedConv
Manual	UniMiB	s9	93.98	1.267	2.3	0.26	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	UniMiB	s9	84.56	0.573	0.34	0.2	5x1_DilatedConv	Zero	Zero
RL(MnasNet)	UniMiB	s9	93.04	0.871	1.9	0.25	5x1_DilatedConv	5x1_DilatedConv	7x1_DilatedConv
Manual	WISDM2019	s9	88.42	1.366	3.4	0.33	7x1_Conv	7x1_Conv	7x1_Conv
ProxylessNAS	WISDM2019	s9	83.17	0.7	0.6	0.27	5x1_DilatedConv	Zero	Zero
RL(MnasNet)	WISDM2019	s9	83.17	0.7	0.6	0.27	5x1_DilatedConv	Zero	Zero





Searching Efficient HAR Neural Networks

CAU Artificial Intelligence LAB

임원선

costor107@gmail.com

6th August, 2021

1. 효율적으로 동작하는 모델을 탐색하기 위한 방안

✓ SuperNet 구성에서 Dynamic Pooling Layer를 적용


기존 연구) NAS SuperNet 구성에서는 고정된 Pooling(Reduction)층과 Pooling size

1. Pooling Layer를 탐색 가능하게 함으로써 탐색 과정에서 계산량과 연관되는 Feature map을 줄일 수 있는 가능성을 부여
2. HAR sensor 데이터의 1차원 특성상 넓은 인식 영역이 성능에도 좋은 영향을 보임
Ex) 실험에서 Cross-Entropy만을 Loss 함수로 설정한 후 탐색하였을 때에도 Standard Conv보다 Dilated Conv이 좋은 효과를 보임
3. Pooling size가 클수록 뒤쪽 layer에서 작은 kernel size를 사용 가능
 - 계산이 필요하지 않은 효율적인 연산자 Skip Connection을 탐색 공간에 같이 구성하여 효율성 유지하면서 정확도 하락 보정

1. 효율적으로 동작하는 모델을 탐색하기 위한 방안

✓ Dynamic Pooling Layer Overview

1. 같은 Layer에 서로 다른 Pooling size를 적용하면 각기 다른 Feature map 사이즈가 나오므로 Binary Gate를 통해 한 step 학습 시 한 개의 Pooling 연산자만 동작하도록 구성



A vertical bar on the left side of the slide, consisting of a red upper half and a grey lower half.

Thank you

참고 문헌

[1] Zela, Arber et al. “Understanding and Robustifying Differentiable Architecture Search.” ICLR, 2020.

Appendix

문제 정의) HAR이 주로 동작하는 모바일 환경에 최적화된 효율적인 모델 구조 탐색

✓ Differentiable-NAS(DARTS)기반의 Accuracy와 Latency를 최적화하는 방식에서의 1 Phase 최적화의 문제점

원인 파악)

1. $\text{Loss} = \text{Cross-Entropy} + \lambda E[\text{latency}]$ 에서 각 term의 scalability가 다름
 - > Latency term이 dominant하면서 구조가 결정되는 경향
 - > 오히려 효율적인 모델 구성에 장점 가능
 - > 또한, 단순히 각 term의 scale을 조절하면 해결 가능한 문제

Appendix

✓ Differentiable-NAS(DARTS)기반의 Accuracy와 Latency를 최적화하는 방식에서의 1 Phase 최적화의 문제점

원인 파악)


2. DARTS기반 최적화 방식의 구조적 문제 : α 가 섀는 지표르 보자치지 않으

$$\begin{aligned} \min_{\alpha} \quad & \mathcal{L}_{val}(w^*(\alpha), \alpha) \quad \text{--- (1) outer optimization} \\ \text{s.t.} \quad & w^*(\alpha) = \operatorname{argmin}_w \mathcal{L}_{train}(w, \alpha) \quad \text{--- (2) inner optimization} \end{aligned}$$

식(1)을 최적화 하기 전에 식(2)가 최적화 되어야 하는데,
계산비용이 크게 들기 때문에 inner optimization을
식(3)Approximation을 통해 계산 비용을 감소

$$\begin{aligned} & \nabla_{\alpha} \mathcal{L}_{val}(w^*(\alpha), \alpha) \\ & \approx \nabla_{\alpha} \mathcal{L}_{val}(w - \xi \nabla_w \mathcal{L}_{train}(w, \alpha), \alpha) \end{aligned} \quad \text{--- (3)}$$

여기서 구조 파라미터 α 가 업데이트할 때 사용하는 $\nabla_{\alpha}^2 \mathcal{L}_{valid}$
에 대한 Hessian Matrix의 eigenvalues의 크기에 따라
생성된 구조의 Test error가 증가한다는 상관 관계를
증명한 [연구 결과 보고](#)^[1]



Appendix

✓ Differentiable-NAS(DARTS)기반의 Accuracy와 Latency를 최적화하는 방식에서의 1 Phase 최적화의 문제점

원인 파악)



3. 최종 네트워크 구조 선택 과정에서 continuous space의 optimal 구조 파라미터 α^* 를 discretize하였을 때, α^{disc} 구조의 loss는 α^* 성능의 주위에 존재

-> α^* 가 Sharp minima에 있을 경우 α^{disc} 와의 loss 차이가 크게 나타남

-> Dominant eigenvalue를 α 의 discretize에 따른 Loss 변화량 을 확인한 결과에서도 클수록 loss 차이가 크게 나타남

Loss 변화량 : $\mathcal{L}_{valid}(\alpha^{disc}, w^*) - \mathcal{L}_{valid}(\alpha^*, w^*)$

따라서, α 가 정확도를 직접적으로 반영하는 지표가 되기 어려운 경우 존재



Appendix

✓ 기존 주장에 대한 고찰

- 결론적으로 현재 목표로 하는 효율적으로 동작하는 모델 탐색에 대한 원인으로는 작용하지 않고 모델의 generalization 문제
- Model Selection 과정에서 고려는 가능
- Latency와 같은 다른 Metric이 포함되었을 때의 영향은 더욱 알기 어려우므로 해당 문제는 다루지 않음

✓ 효율적으로 동작하는 모델을 탐색하기 위한 방안 제시