

DMQA Open Seminar

# Deep Neural Network-Based Open-set Recognition

---

2022.07.22

Data Mining & Quality Analytics Lab.

오혜령

# 발표자 소개



## ❖ 오혜령

- 고려대학교 산업경영공학과
- Data Mining & Quality Analytics Lab. (김성범 교수님)
- M.S. Student (2021.03 ~ )

## ❖ Research Interest

- Machine Learning & Deep Learning Algorithms
- Multivariate Time Series Data
- Open-set Recognition
- Anomaly Detection

## ❖ Contact

- E-mail : hyeryeong5@korea.ac.kr

# Contents

## 1. Introduction

## 2. Deep Neural Network-Based Open-set Recognition Algorithms

- 1) OpenMax
- 2) CROSR(Classification-Reconstruction learning for Open-Set Recognition)
- 3) ii-loss

## 3. Conclusions

# DNN-Based Open-set Recognition Algorithms

## ❖ DMQA Open Seminar – Open-set Recognition

**종료**

### Open Set Recognition

발표자: 백승호

Open Set Recognition

발표자:  백승호

2020년 1월 3일  
오후 1시 ~  
고려대학교 신공학관 218호

세미나 정보 보기 →

**종료**

2020.02.21. HCII Open Seminar

### Open Set Recognition In Deep Networks

김상훈

Open Set Recognition in Deep Networks

발표자:  김상훈

2020년 2월 21일  
오후 1시 ~  
고려대학교 신공학관 221호

세미나 정보 보기 →

종료	multiple sources is combined in one place
<b>Known Known</b>	The data you are currently tracking
<b>Unknown Known</b>	How much of your traffic is real

Open Set Recognition with Background

발표자:  김상훈

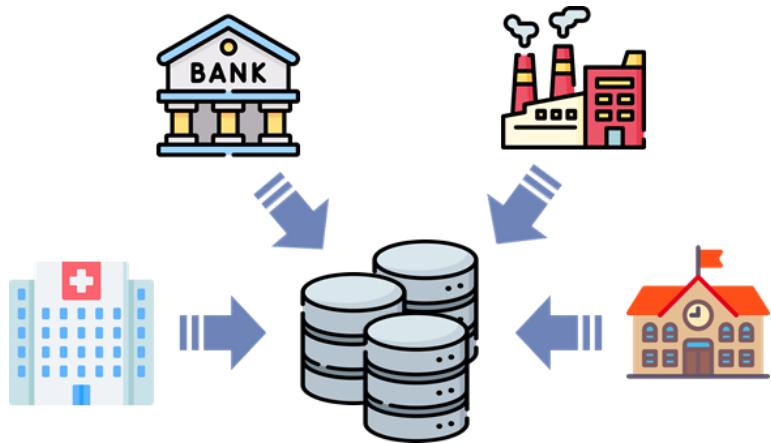
2020년 10월 15일  
오후 1시 ~  
온라인 비디오 시청 (YouTube)

세미나 정보 보기 →

# 1. Introduction

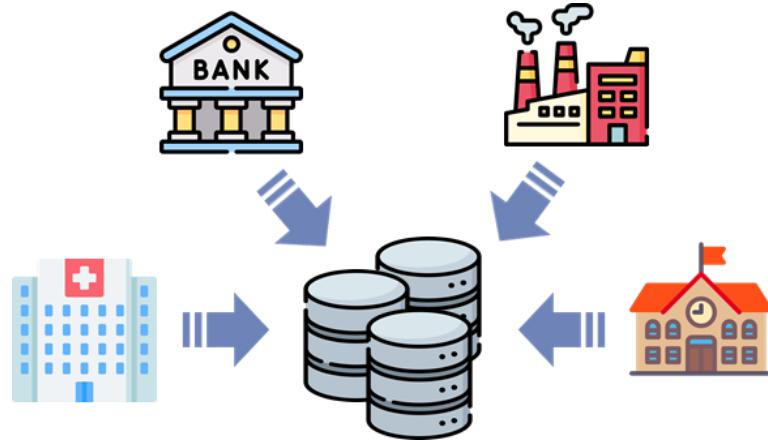
# Introduction

딥러닝 분류 모델의 발전



# Introduction

## 딥러닝 분류 모델의 발전



기사출처

<https://www.yna.co.kr/view/AKR20210510074100017>

<https://www.itbiznews.com/news/articleView.html?idxno=63716>

## AI 아토피 중증도 진단 정확도 99.17%..."전문의 수준"

송고시간 | 2021-05-10 11:29



김잔디 기자  
[기자페이지](#)

| 서울성모병원·광운대, 딥러닝 방식으로 아토피 중증도 측정 알고리즘 개발

(서울=연합뉴스) 김잔디 기자 = 국내 연구진이 피부과 전문의와 유사한 수준으로 아토피 피부염 중증도를 진단하는 인공지능(AI) 모델을 개발하는 데 성공했다.

## "딥러닝(DL) 활용, 수십초 내 98% 정확도로 박테리아 검출 가능"

▲ 김소현 기자 | Ⓛ 입력 2022.02.11 14:02 | Ⓜ 댓글 0



주요기사



검색시장 강자 구글에 도전  
장 던진 유닷컴, 시리즈A 투자유치

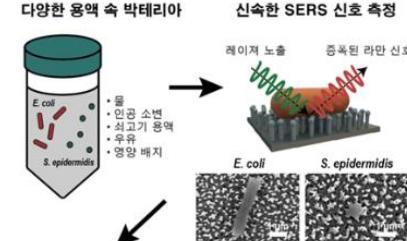


[데스크칼럼] 3년차 맞은 K-  
유니콘 사업, 어떻게 흘러가고  
있나



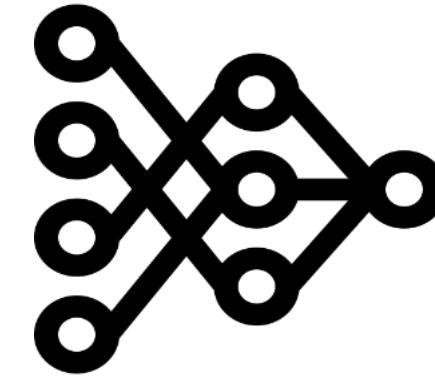
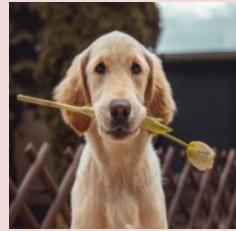
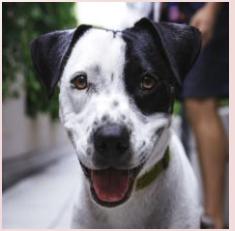
구독 서비스 '유독' 듣칭한  
LGU+..."필요한 서비스만 골라서  
구독한다"

| KAIST 연구진, 표면증강 라만분광법(SERS)에 DL 결합



# Introduction

딥러닝 분류 모델의 한계점

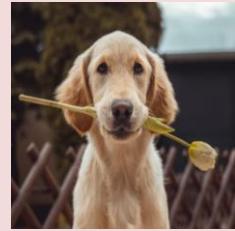
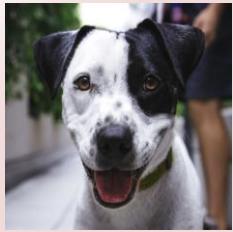


## 학습 데이터

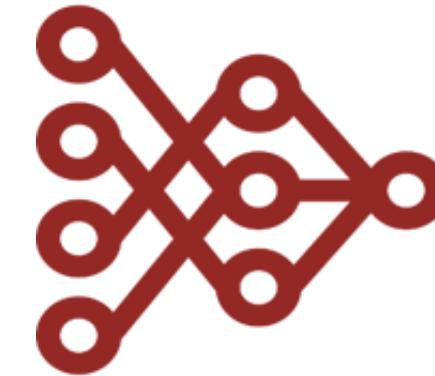
이미지 출처 <https://blog.naver.com/lunaglam/222795140006>

# Introduction

딥러닝 분류 모델의 한계점



Training

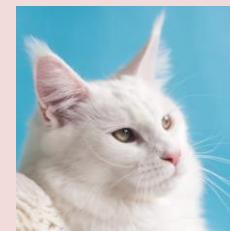
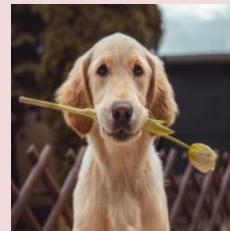
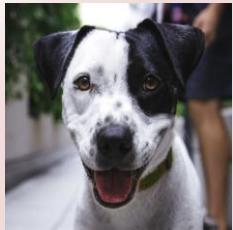


학습 데이터

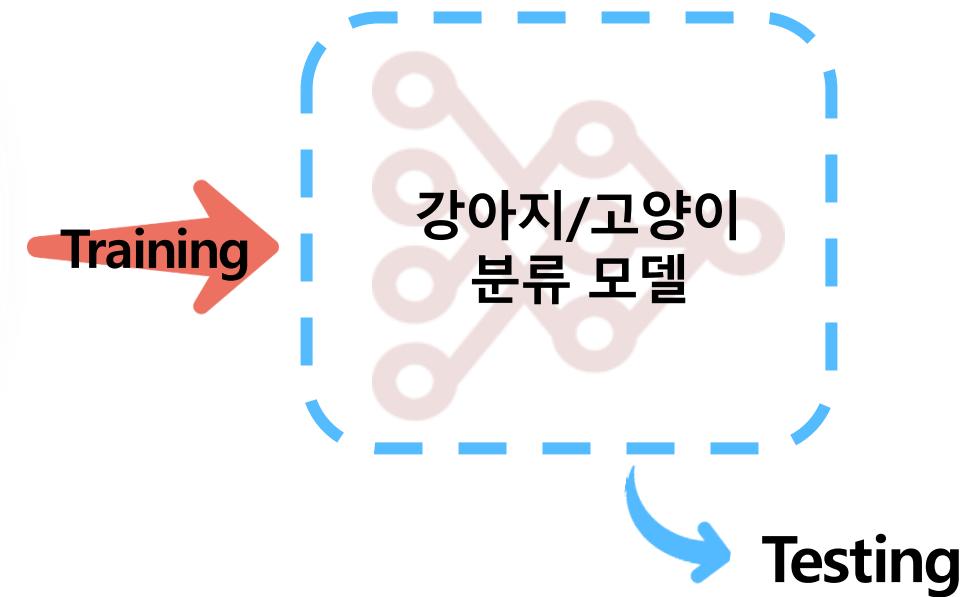
이미지 출처 <https://blog.naver.com/lunaglam/222795140006>

# Introduction

딥러닝 분류 모델의 한계점



학습 데이터



이미지 출처 <https://blog.naver.com/lunaglam/222795140006>

# Introduction

딥러닝 분류 모델의 한계점



강아지/고양이  
분류 모델

## 테스트 데이터

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

<https://blog.naver.com/loefl1/221395102072>

# Introduction

딥러닝 분류 모델의 한계점



테스트 데이터



	강아지	
	고양이	
	강아지	
	고양이	

예측 결과

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

<https://blog.naver.com/loefl1/221395102072>

# Introduction

딥러닝 분류 모델의 한계점



학습 데이터에는 없었던  
클래스(돼지, 곰)

## 테스트 데이터

강아지/고양이  
분류 모델

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

<https://blog.naver.com/loefl1/221395102072>

# Introduction

딥러닝 분류 모델의 한계점



학습 데이터에는 없었던  
클래스(돼지, 곰)

테스트 데이터

강아지/고양이  
분류 모델



강아지



고양이



???



???

예측 결과

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

<https://blog.naver.com/loefl1/221395102072>

# Introduction

딥러닝 분류 모델의 한계점

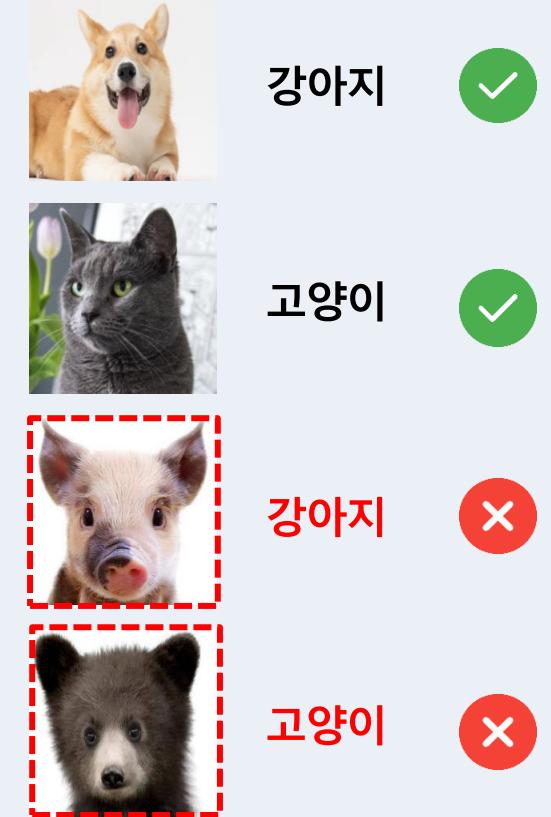


학습 데이터에는 없었던  
클래스(돼지, 곰)

강아지/고양이  
분류 모델



테스트 데이터



예측 결과

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

<https://blog.naver.com/loefl1/221395102072>

# Introduction

Open-set Recognition이란?

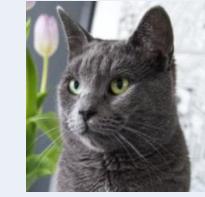
딥러닝 분류 모델이  
학습하지 않은 클래스를  
탐지해낼 수는 없을까?

테스트 데이터

강아지/고양이  
분류 모델



강아지



고양이



강아지



고양이



예측 결과

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

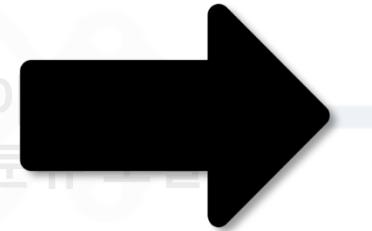
<https://blog.naver.com/loeflf1/221395102072>

# Introduction

Open-set Recognition이란?

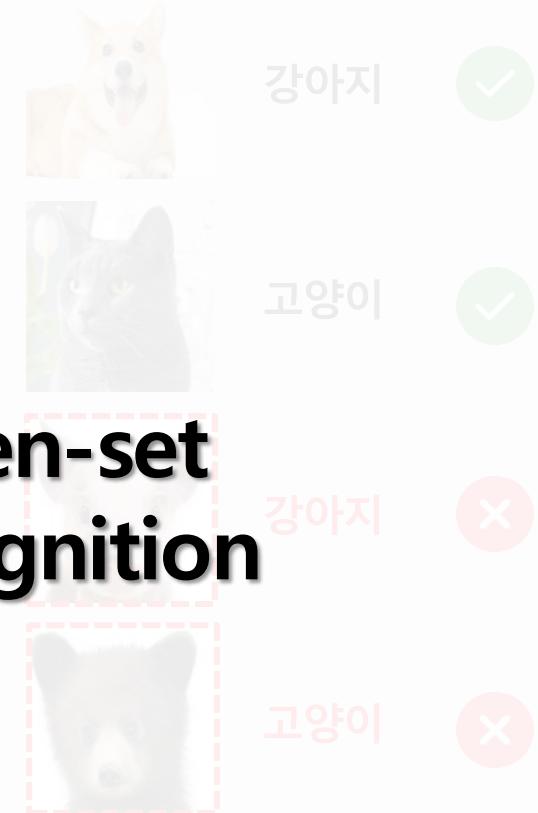
딥러닝 분류 모델이  
학습하지 않은 클래스를  
탐지해낼 수는 없을까?

테스트 데이터



Open-set  
Recognition

예측 결과



이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

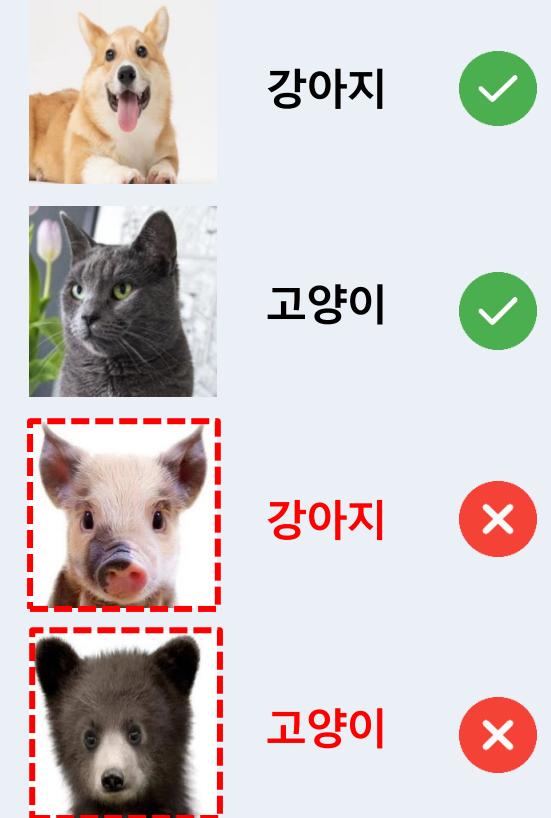
<https://blog.naver.com/loeflf1/221395102072>

# Introduction

Open-set Recognition이란?



강아지/고양이  
분류 모델



예측 결과

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

<https://blog.naver.com/loefl1/221395102072>

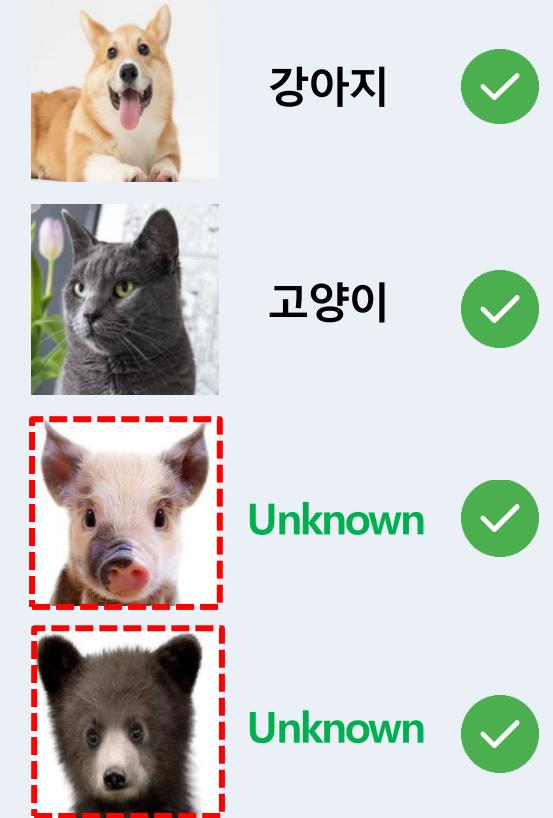
# Introduction

Open-set Recognition이란?



테스트 데이터

강아지/고양이  
분류 모델



예측 결과  
(Open-set Recognition)

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

<https://blog.naver.com/loeflf1/221395102072>

# Introduction

“Closed-set” vs “Open-set”

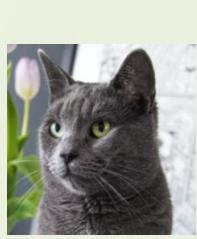
## Open-set Recognition



## Closed-set

# Introduction

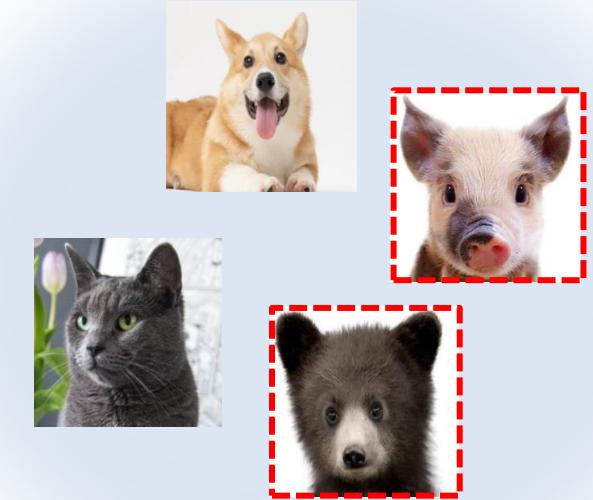
“Closed-set” vs “Open-set”



테스트 데이터  
(강아지, 고양이)



학습 데이터  
(강아지, 고양이)



테스트 데이터  
(강아지, 고양이, Unknown)

## Closed-set

학습 데이터 분포와 테스트 데이터 분포가 같음

## Open-set

학습 데이터 분포와 테스트 데이터 분포가 다름

이미지 출처

<https://blog.naver.com/lunaglam/222795140006>

<https://blog.naver.com/loeflf1/221395102072>

# Introduction

## Open-set Recognition 연구 동향

### ❖ Recent advances in open set recognition: A survey

- Geng, C., Huang, S. J., & Chen, S. (2020). Recent advances in open set recognition: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 43(10), 3614-3631.
- 2022년 7월 19일 기준 281회 인용
- Open-set recognition에 사용되는 대표적인 데이터셋과 평가 지표 소개 및 다양한 방법론에 대한 리뷰 제공

3614

IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, VOL. 43, NO. 10, OCTOBER 2021

## Recent Advances in Open Set Recognition: A Survey

Chuanxing Geng<sup>Id</sup>, Sheng-Jun Huang<sup>Id</sup>, and Songcan Chen<sup>Id</sup>

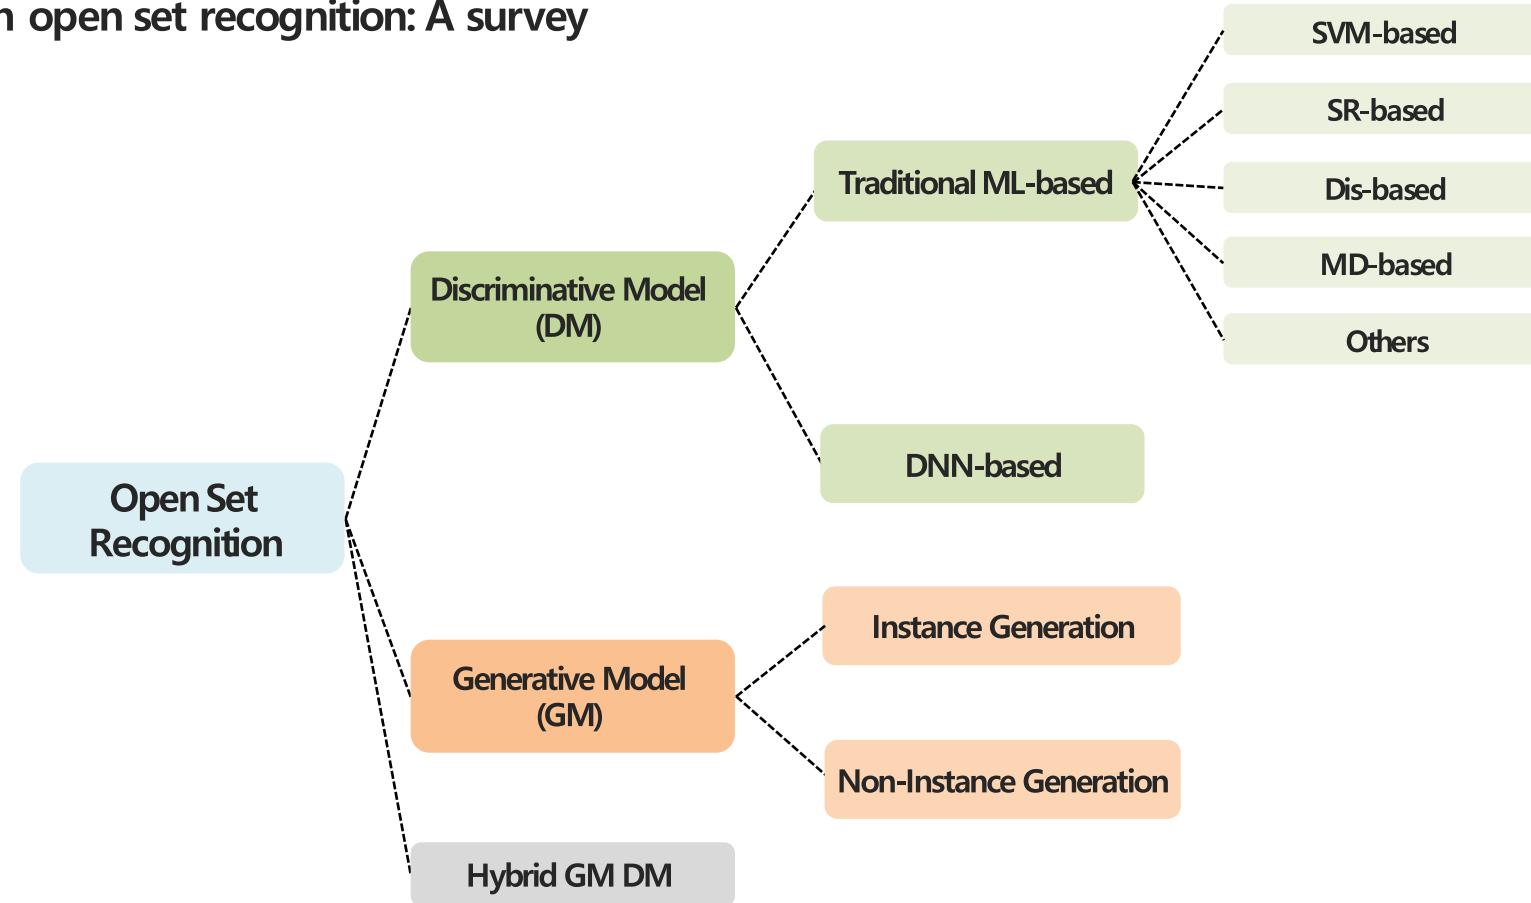
**Abstract**—In real-world recognition/classification tasks, limited by various objective factors, it is usually difficult to collect training samples to exhaust all classes when training a recognizer or classifier. A more realistic scenario is open set recognition (OSR), where incomplete knowledge of the world exists at training time, and unknown classes can be submitted to an algorithm during testing, requiring the classifiers to not only accurately classify the seen classes, but also effectively deal with unseen ones. This paper provides a comprehensive survey of existing open set recognition techniques covering various aspects ranging from related definitions, representations of models, datasets, evaluation criteria, and algorithm comparisons. Furthermore, we briefly analyze the relationships between OSR and its related tasks including zero-shot, one-shot (few-shot) recognition/learning techniques, classification with reject option, and so forth. Additionally, we also review the open world recognition which can be seen as a natural extension of OSR. Importantly, we highlight the limitations of existing approaches and point out some promising subsequent research directions in this field.

**Index Terms**—Open set recognition/classification, open world recognition, zero-short learning, one-shot learning

# Introduction

## Open-set Recognition 연구 동향

- ❖ Recent advances in open set recognition: A survey

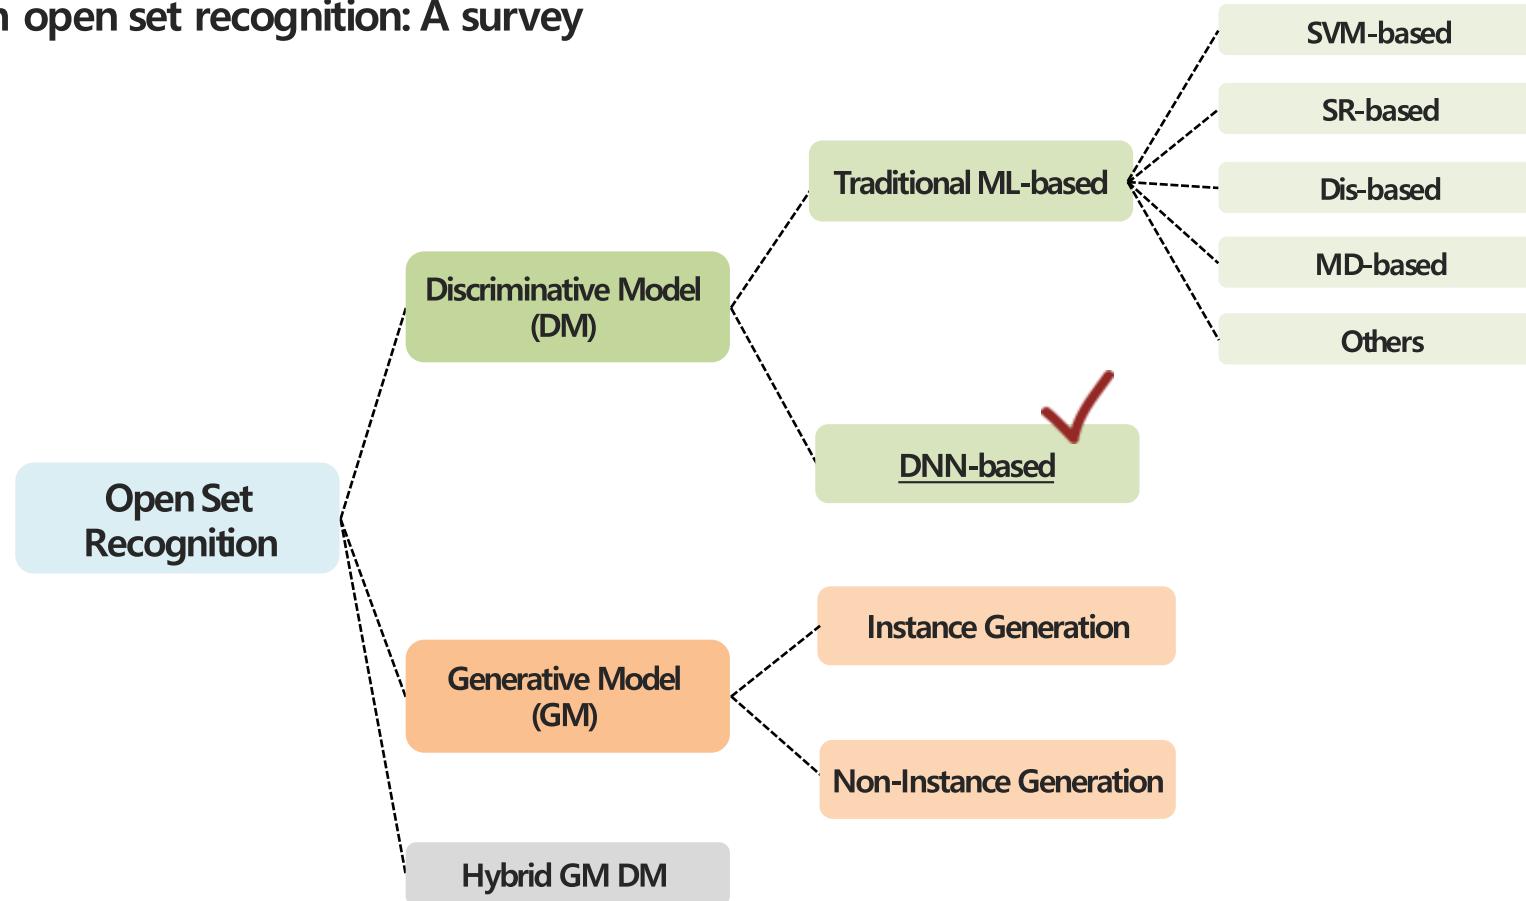


Open-set Recognition 방법론 카테고리

# Introduction

Open-set Recognition 연구 동향

- ❖ Recent advances in open set recognition: A survey

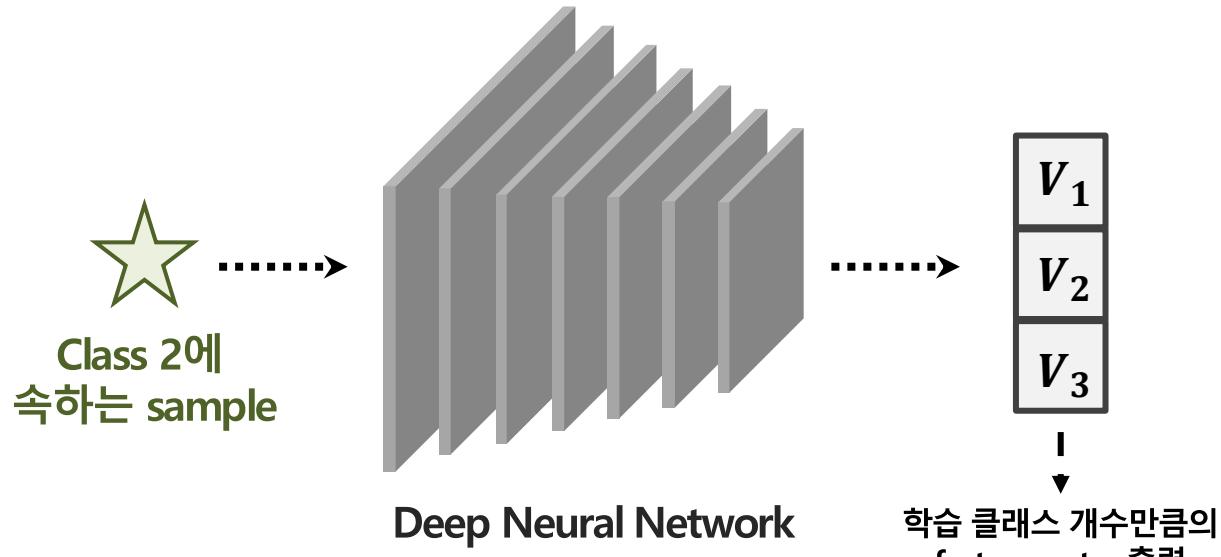
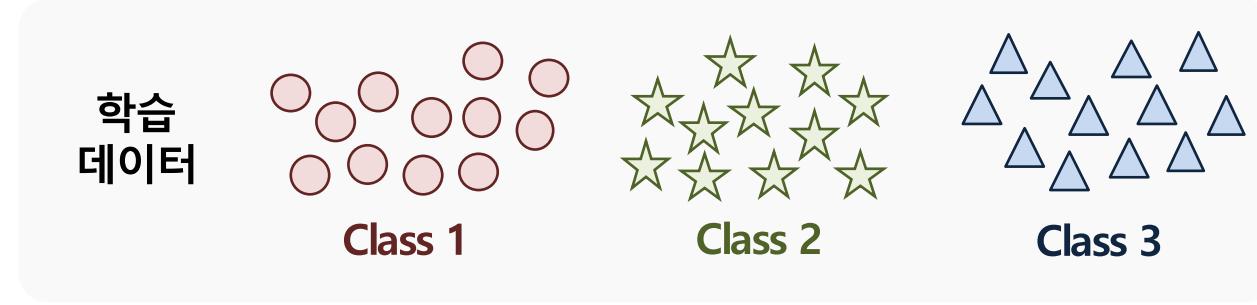


Open-set Recognition 방법론 카테고리

## 2. DNN-Based Open-set Recognition Algorithms

# DNN-Based Open-set Recognition Algorithms

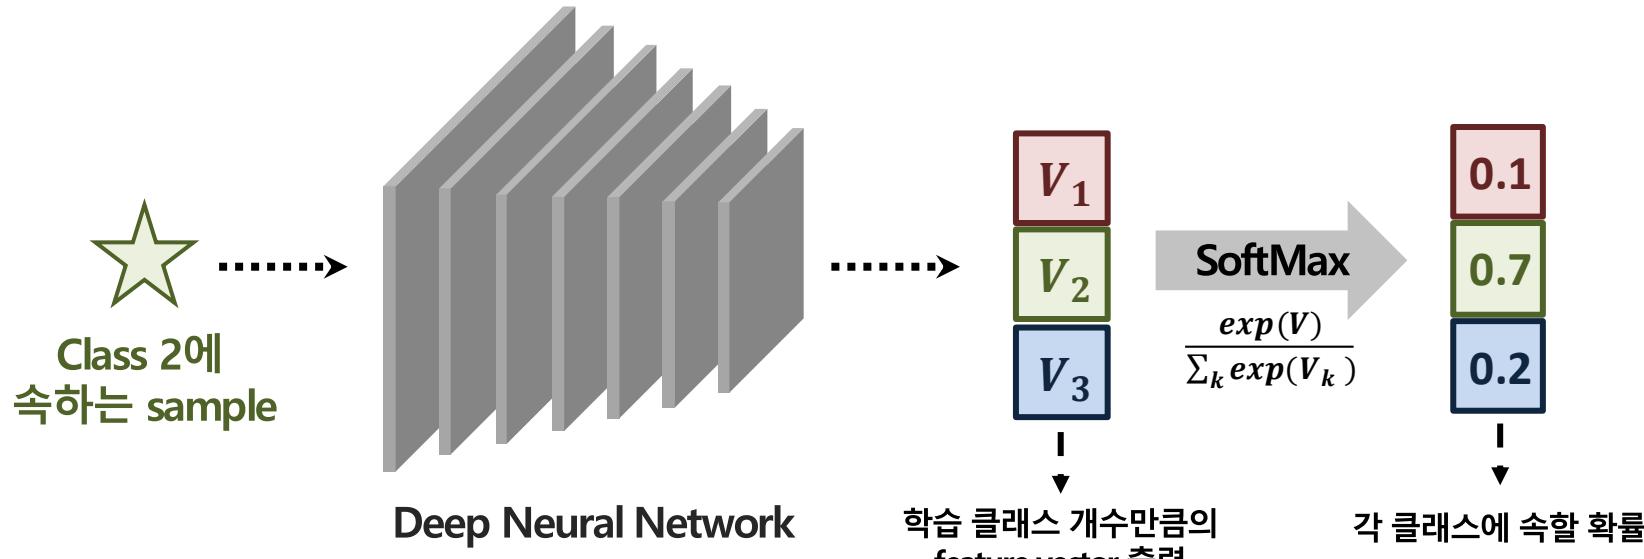
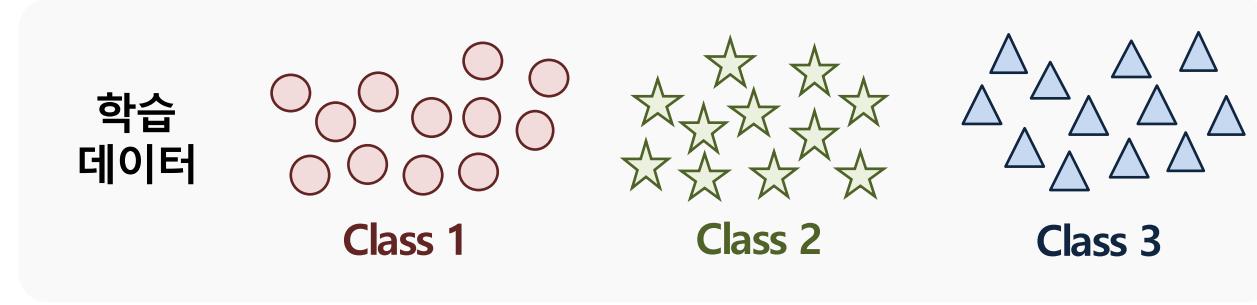
Closed-set DNN 분류 모델



< 학습 과정 >

# DNN-Based Open-set Recognition Algorithms

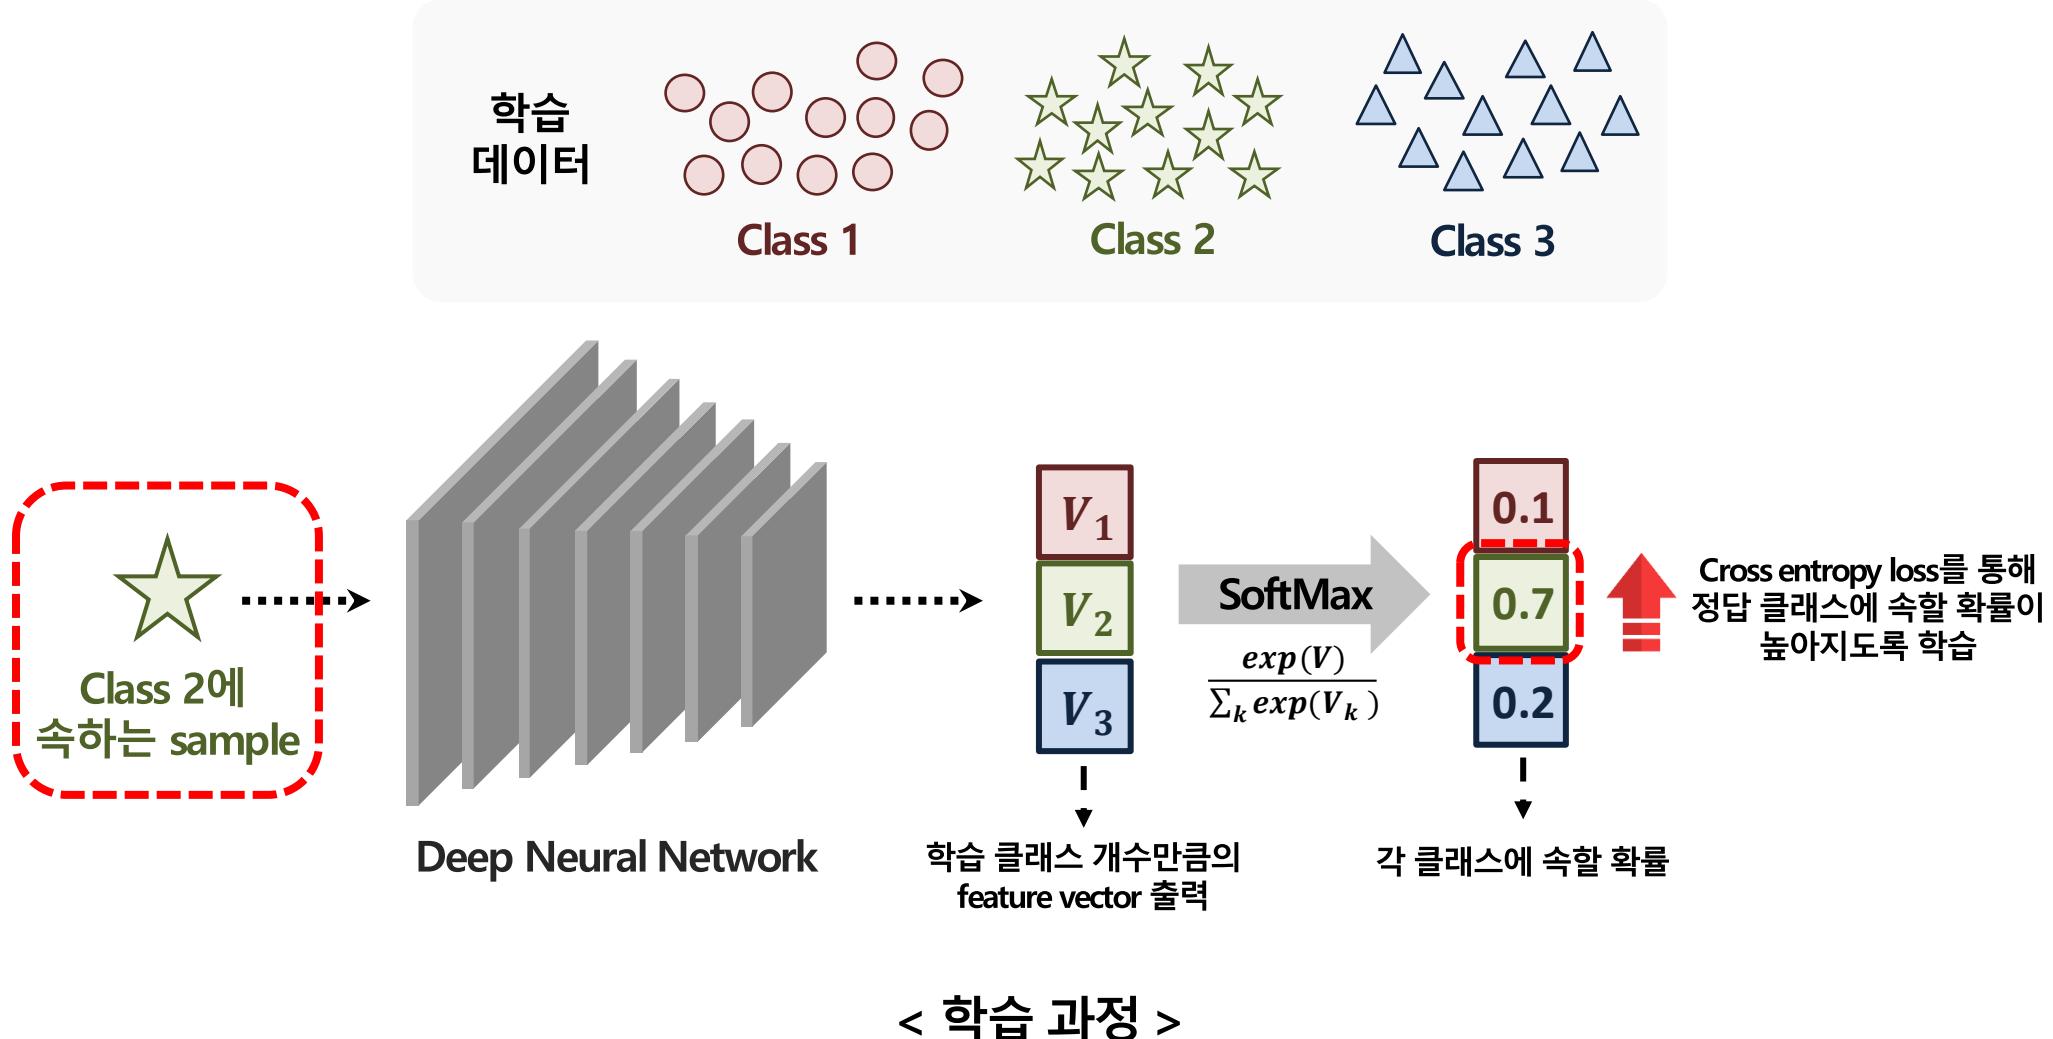
Closed-set DNN 분류 모델



< 학습 과정 >

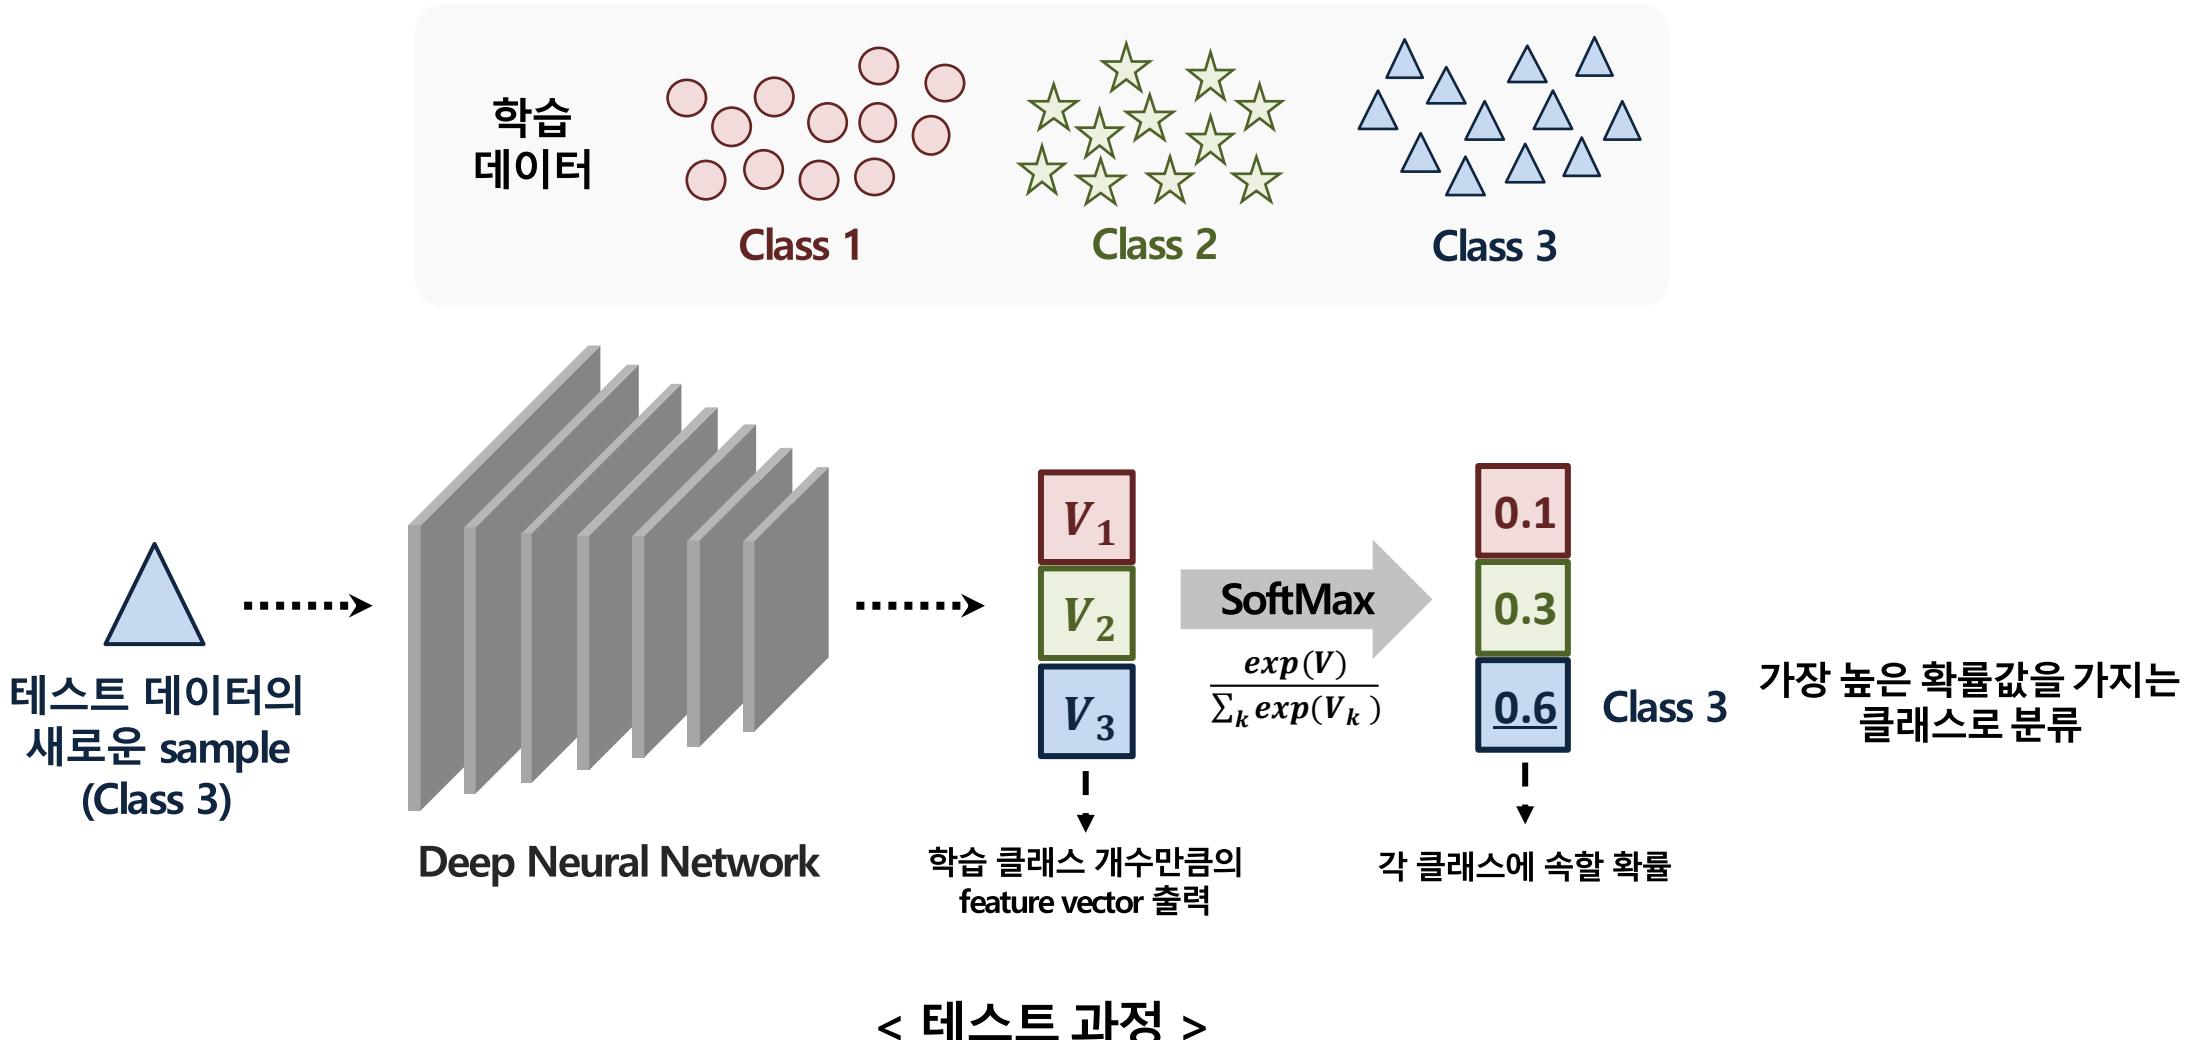
# DNN-Based Open-set Recognition Algorithms

Closed-set DNN 분류 모델



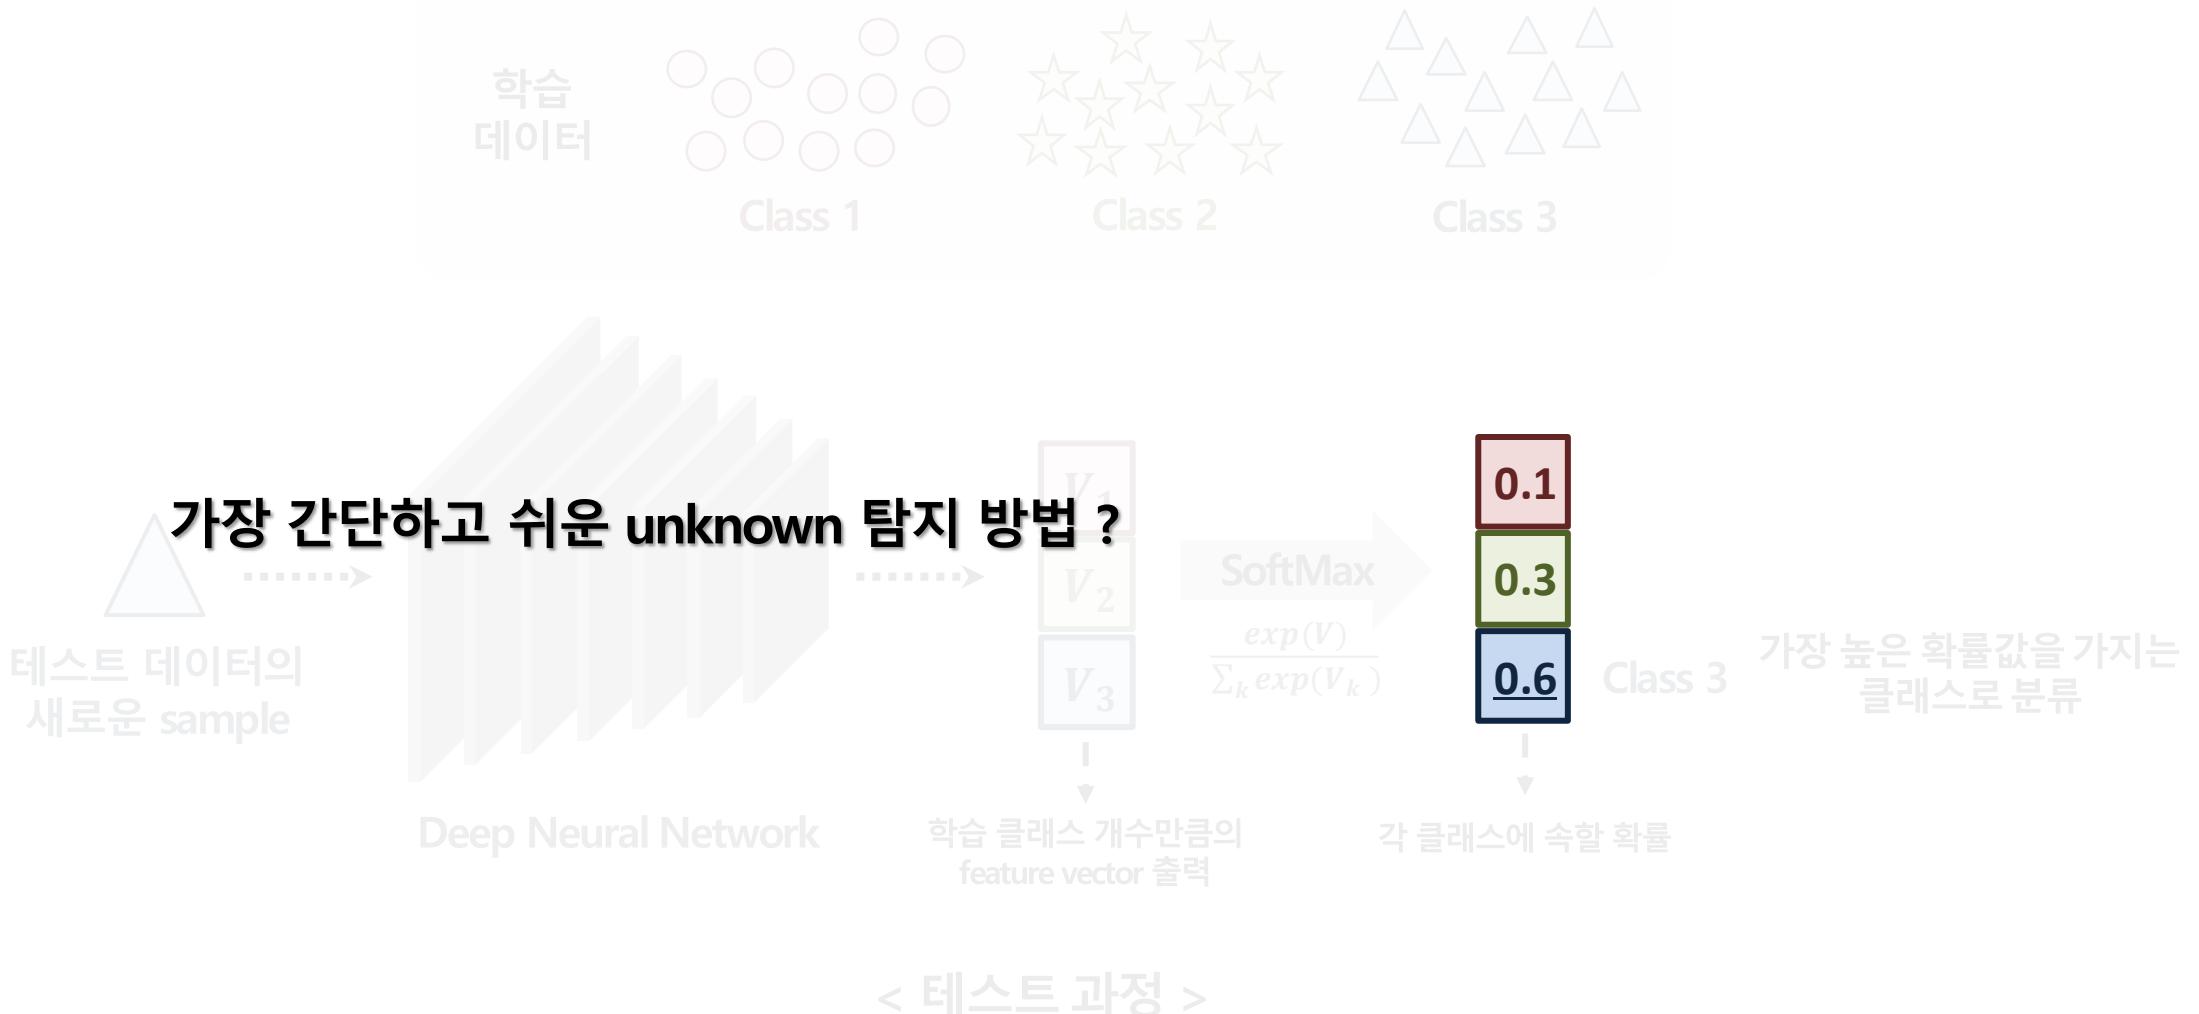
# DNN-Based Open-set Recognition Algorithms

Closed-set DNN 분류 모델



# DNN-Based Open-set Recognition Algorithms

Open-set DNN 분류 모델



# DNN-Based Open-set Recognition Algorithms

Open-set DNN 분류 모델



가장 간단하고 쉬운 unknown 탐지 방법 ?  
확률값이 특정 기준보다 작으면 unknown으로 분류하자!

테스트 데이터의  
새로운 sample

Deep Neural Network

학습 클래스 개수만큼의  
feature vector 출력



Class 3

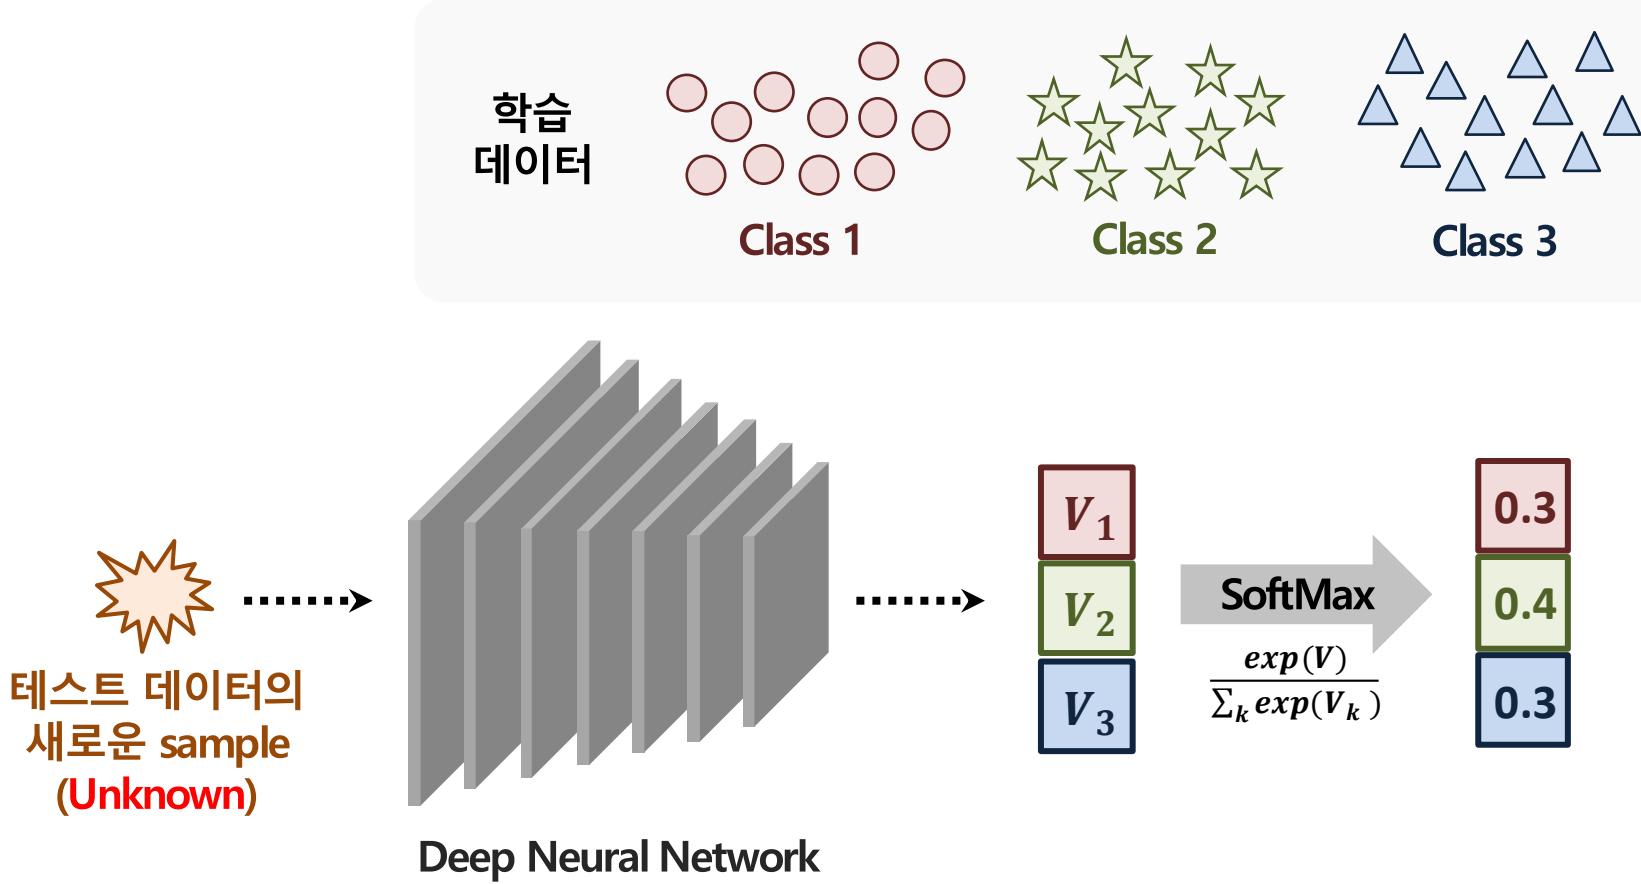
가장 높은 확률값을 가지는  
클래스로 분류

각 클래스에 속할 확률

< 테스트 과정 >

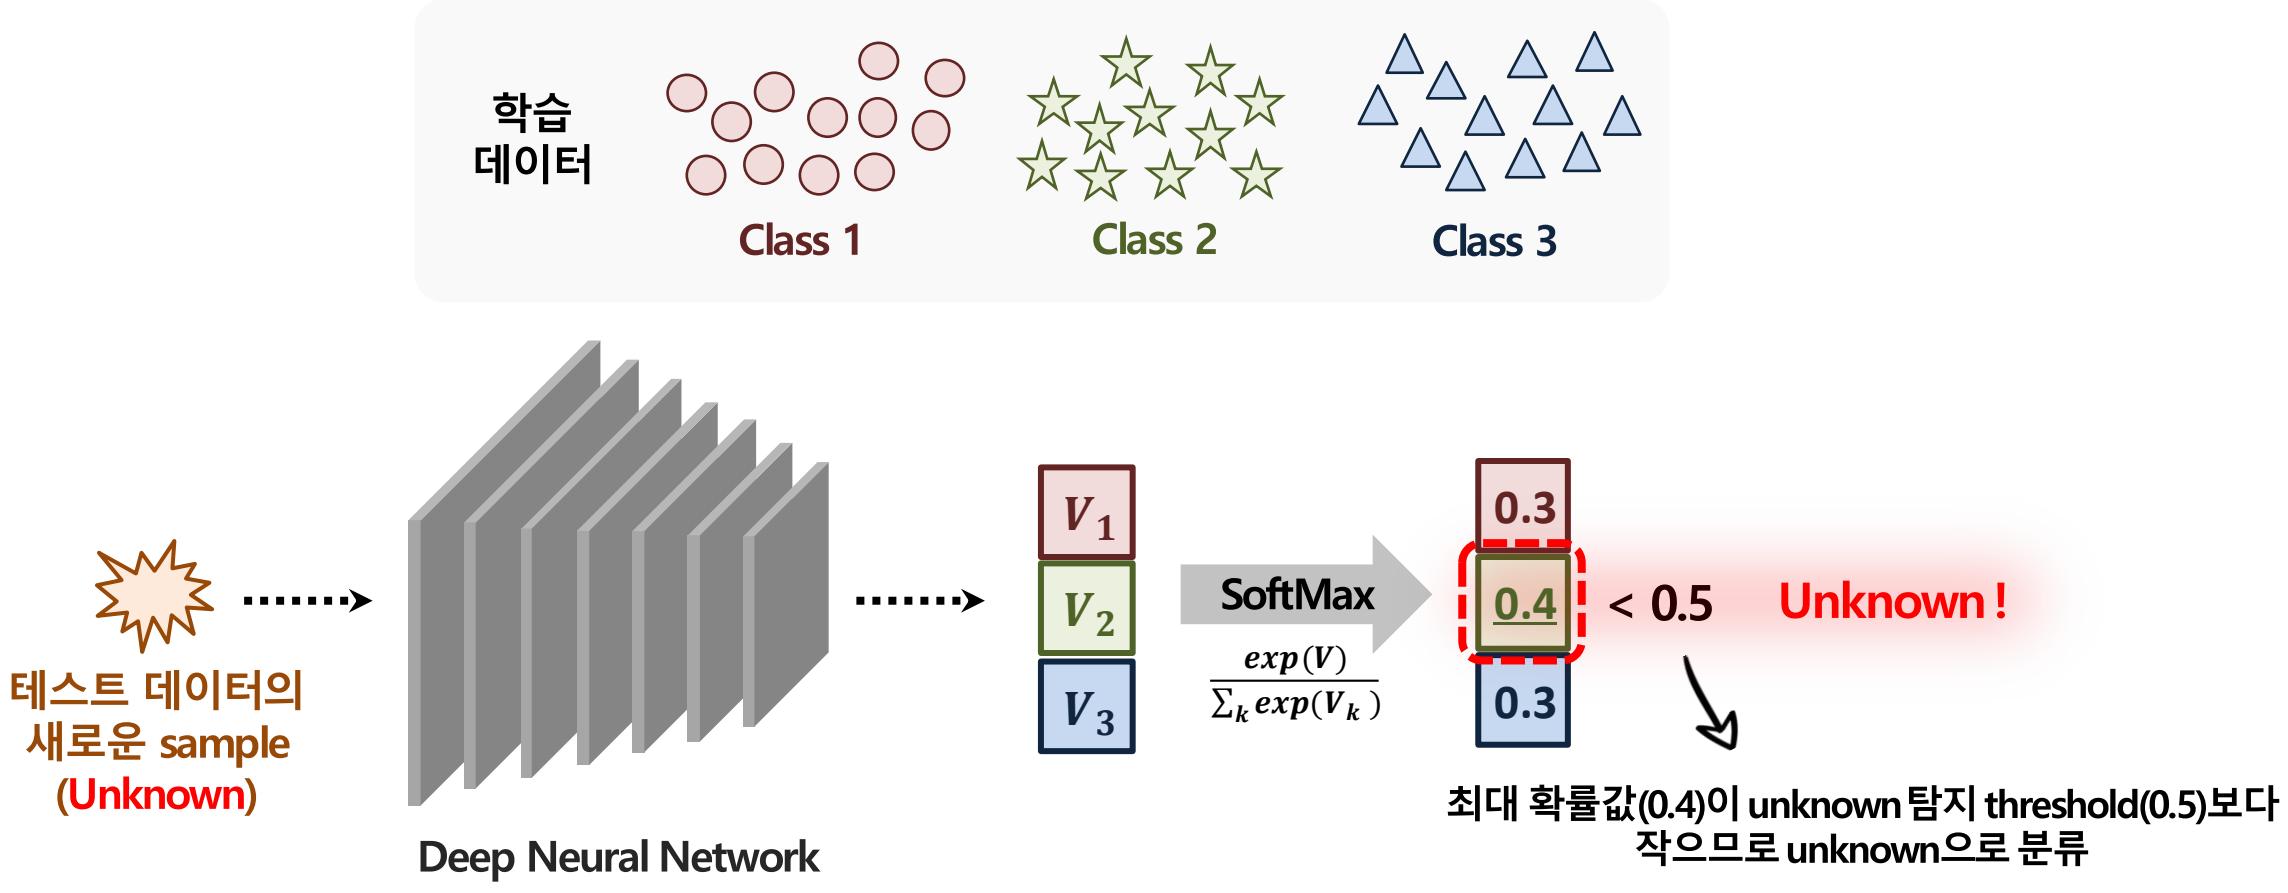
# DNN-Based Open-set Recognition Algorithms

Open-set DNN 분류 모델



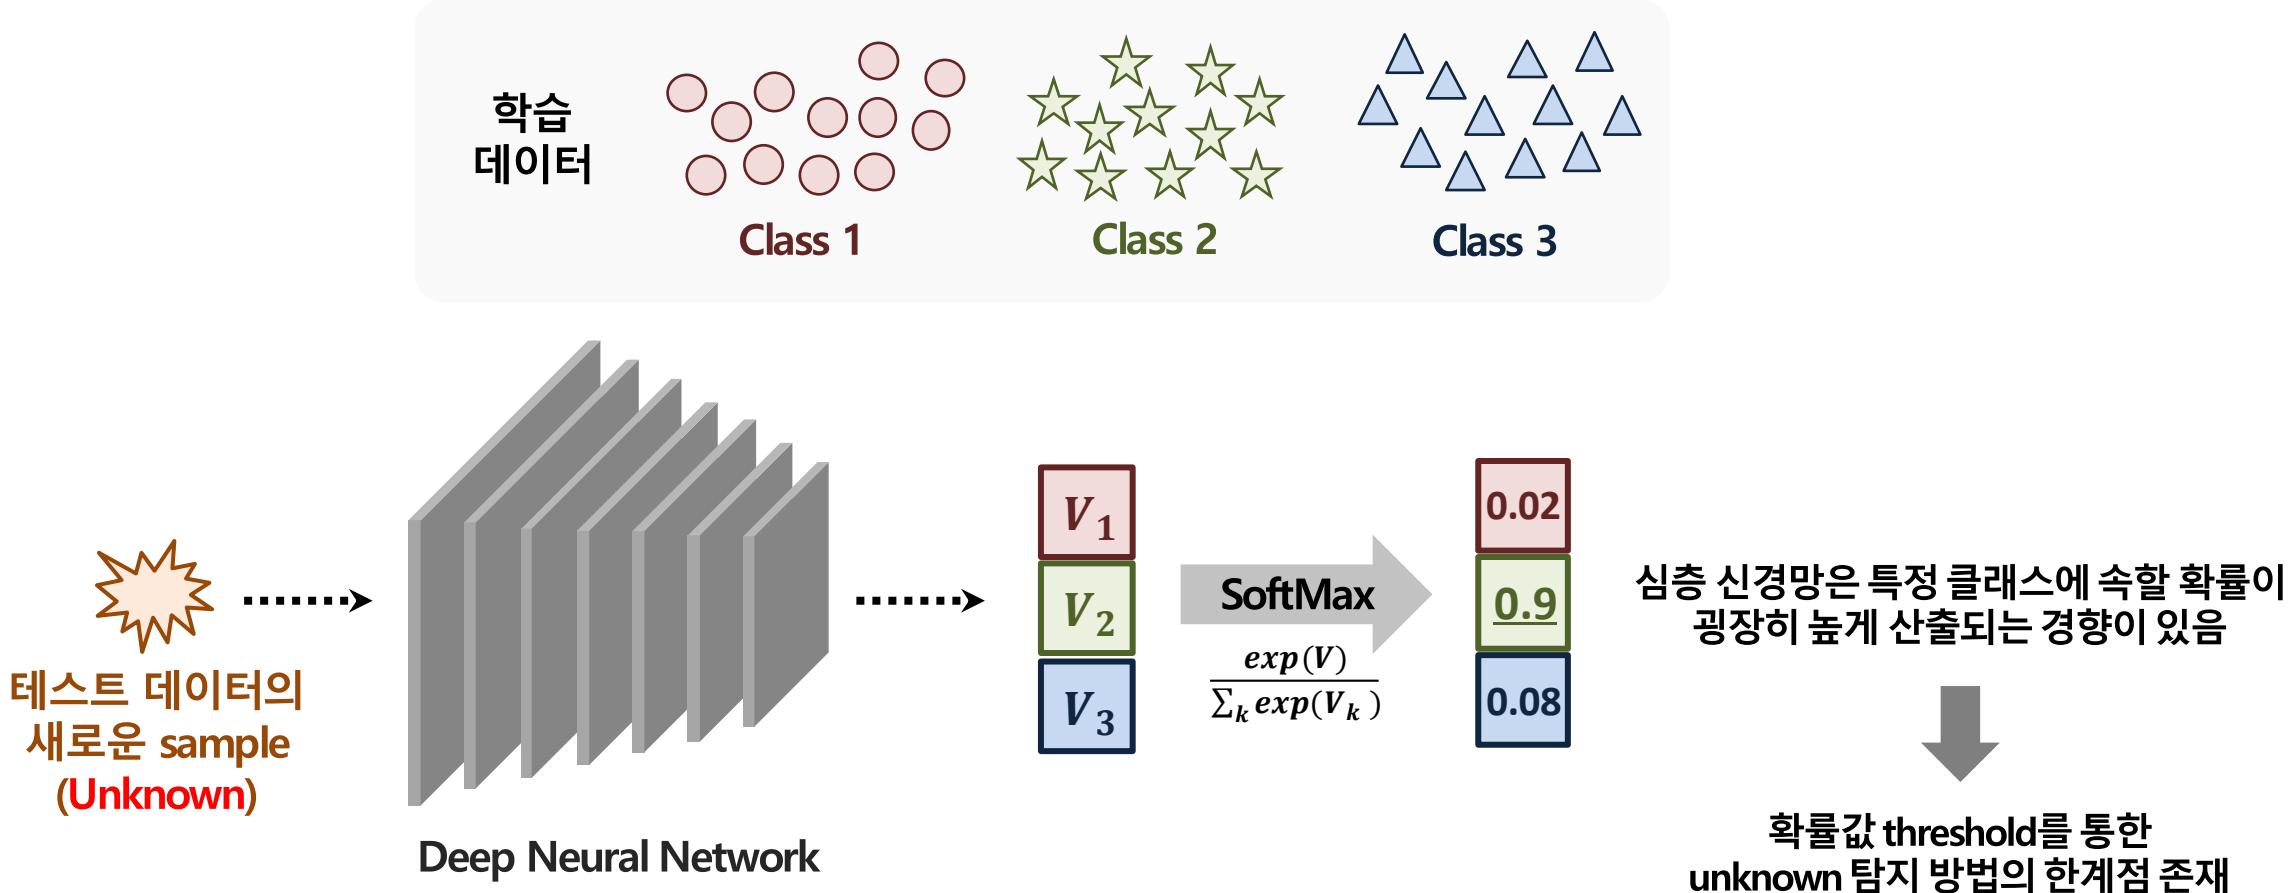
# DNN-Based Open-set Recognition Algorithms

Open-set DNN 분류 모델



# DNN-Based Open-set Recognition Algorithms

Open-set DNN 분류 모델



< 테스트 과정 >

# DNN-Based Open-set Recognition Algorithms

2. CROS(R(Classification-Reconstruction learning for Open-Set Recognition)

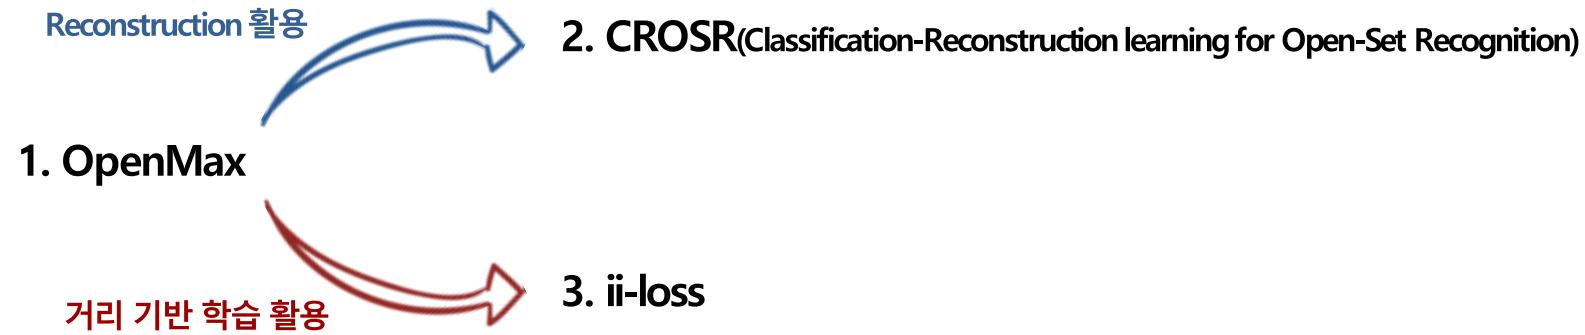
1. OpenMax

DNN에 open-set recognition을 처음 적용

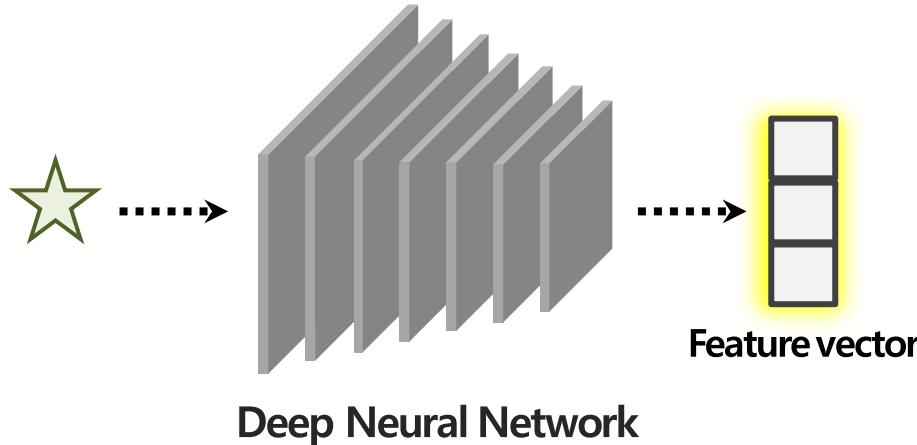
OpenMax의 단점을 보완하기 위해 제안된 알고리즘

3. ii-loss

# DNN-Based Open-set Recognition Algorithms



## 1. 모델 학습 방법



Unknown 탐지에 유용한 feature vector를 학습

## 2. Unknown 탐지 방법



Feature vector를 통해 unknown 탐지 수행

## 2.1 OpenMax

# DNN-Based Open-set Recognition Algorithms

OpenMax

## ❖ Towards open set deep networks

- Bendale, A., & Boult, T. E. (2016). Towards open set deep networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1563-1572).
- 2022년 7월 21일 기준 802회 인용
- 심층 신경망(DNN)에 open-set recognition을 처음 적용한 **OpenMax** 제안



This CVPR paper is the Open Access version, provided by the Computer Vision Foundation.  
Except for this watermark, it is identical to the version available on IEEE Xplore.

## Towards Open Set Deep Networks

Abhijit Bendale\*, Terrance E. Boult  
University of Colorado at Colorado Springs  
`{abendale,tboult}@vast.uccs.edu` \*

### Abstract

*Deep networks have produced significant gains for various visual recognition problems, leading to high impact academic and commercial applications. Recent work in deep networks highlighted that it is easy to generate images*

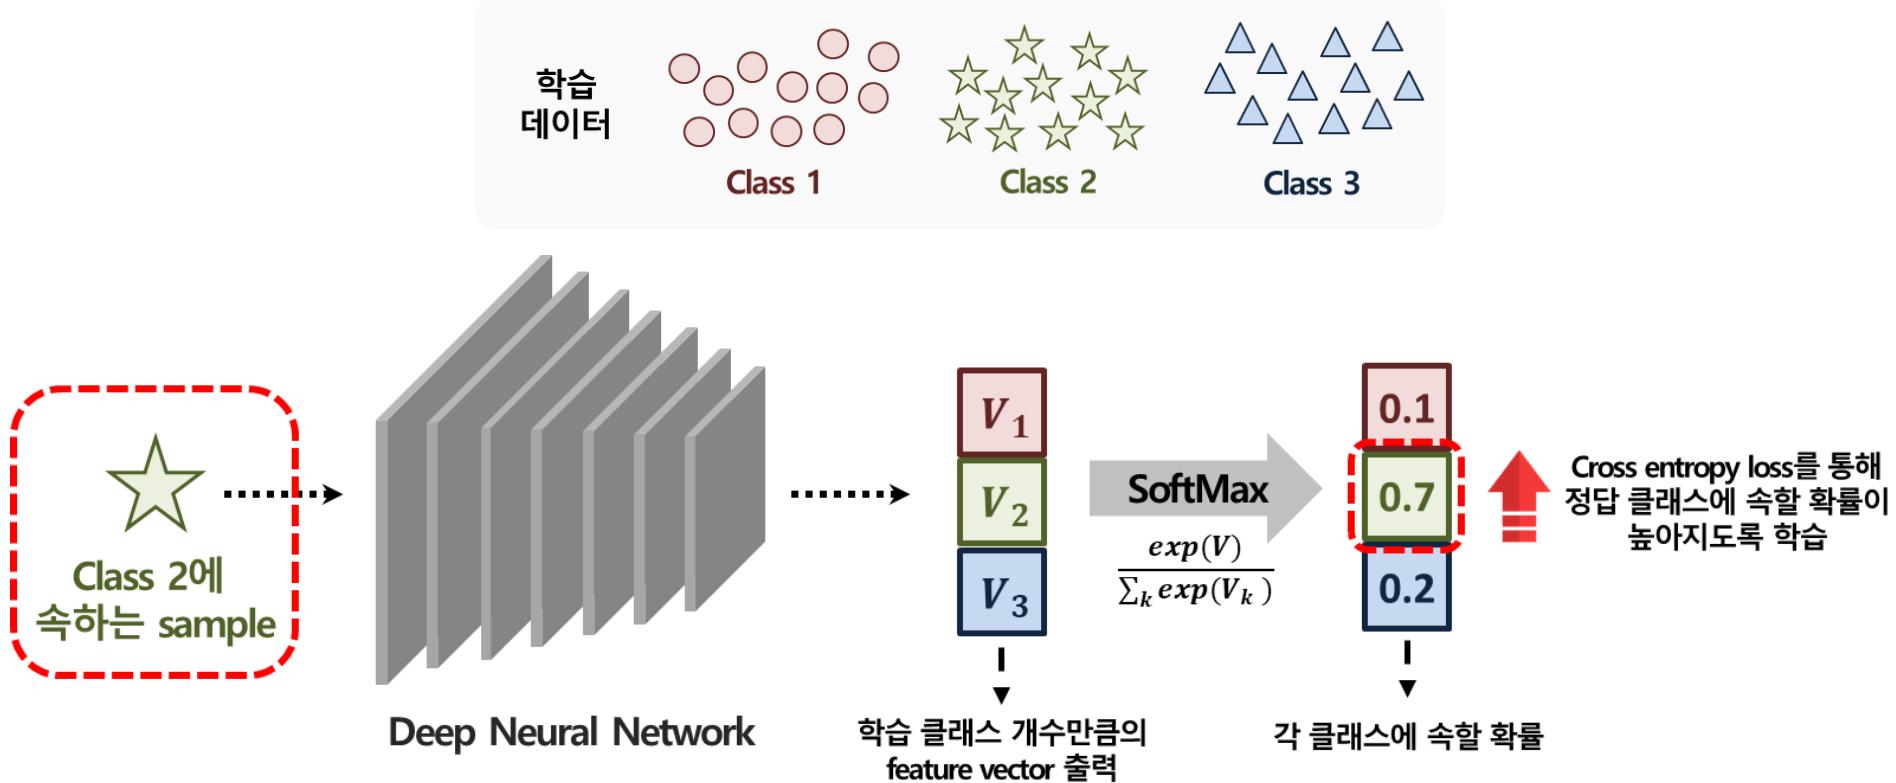
*vision and learning. Recent research in deep networks has significantly improved many aspects of visual recognition [26, 3, 11]. Co-evolution of rich representations, scalable classification methods and large datasets have resulted in many commercial applications [5, 28, 16, 6]. However, a wide range of operational challenges occur while deploying*

# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ 모델 학습 방법

- OpenMax는 학습이 완료된 closed-set DNN 모델을 open-set 상황에 적합하게 변형해주는 알고리즘
- 일반적인(closed-set) DNN 학습 방법과 동일하게 **cross entropy loss**를 활용하여 모델 학습
- Unknown 탐지가 잘 수행되기 위해서는 **잘 학습된 모델** 필요

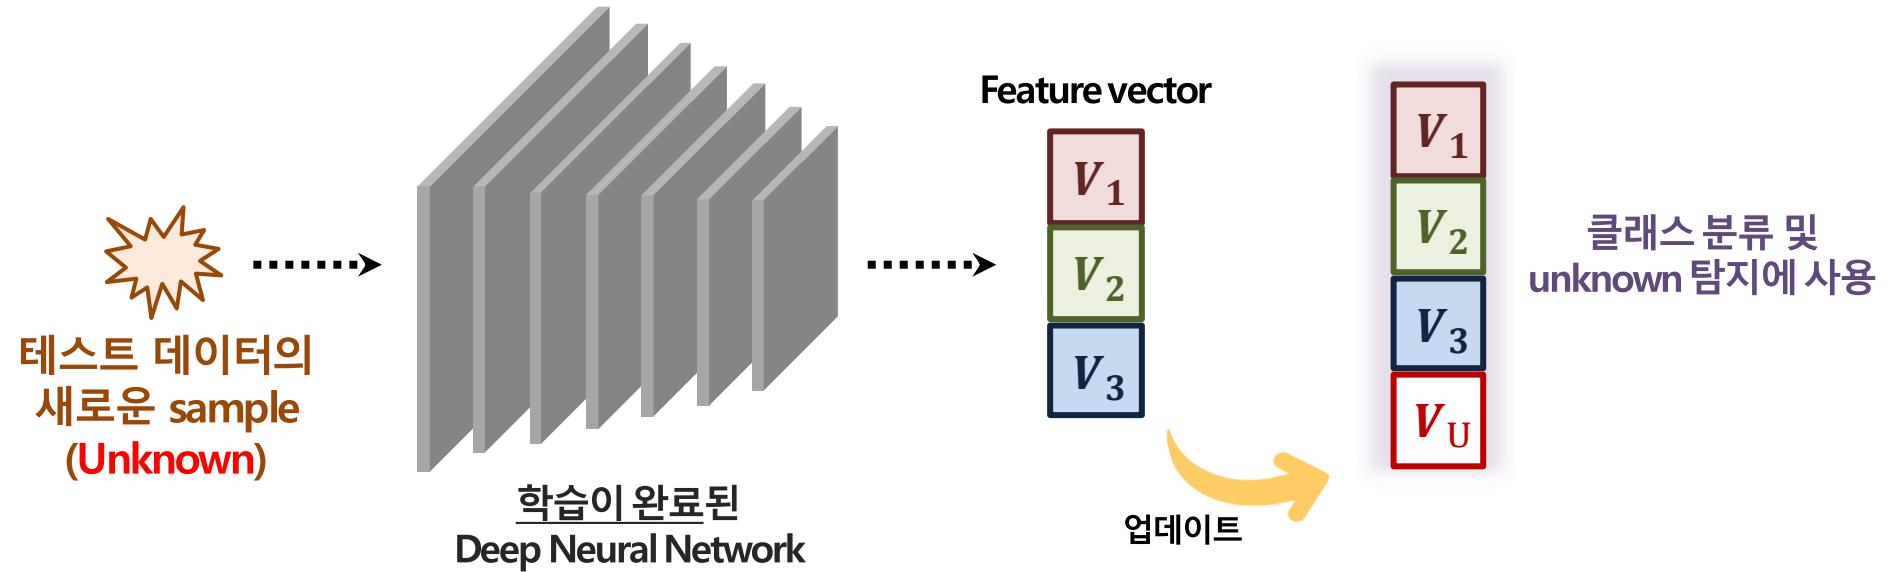


# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

- 학습 데이터로부터 추정된 클래스별 극단 분포(Weibull 분포)를 통해 **feature vector** 업데이트
- 업데이트된 feature vector로 known 클래스 분류와 함께 unknown 탐지 수행

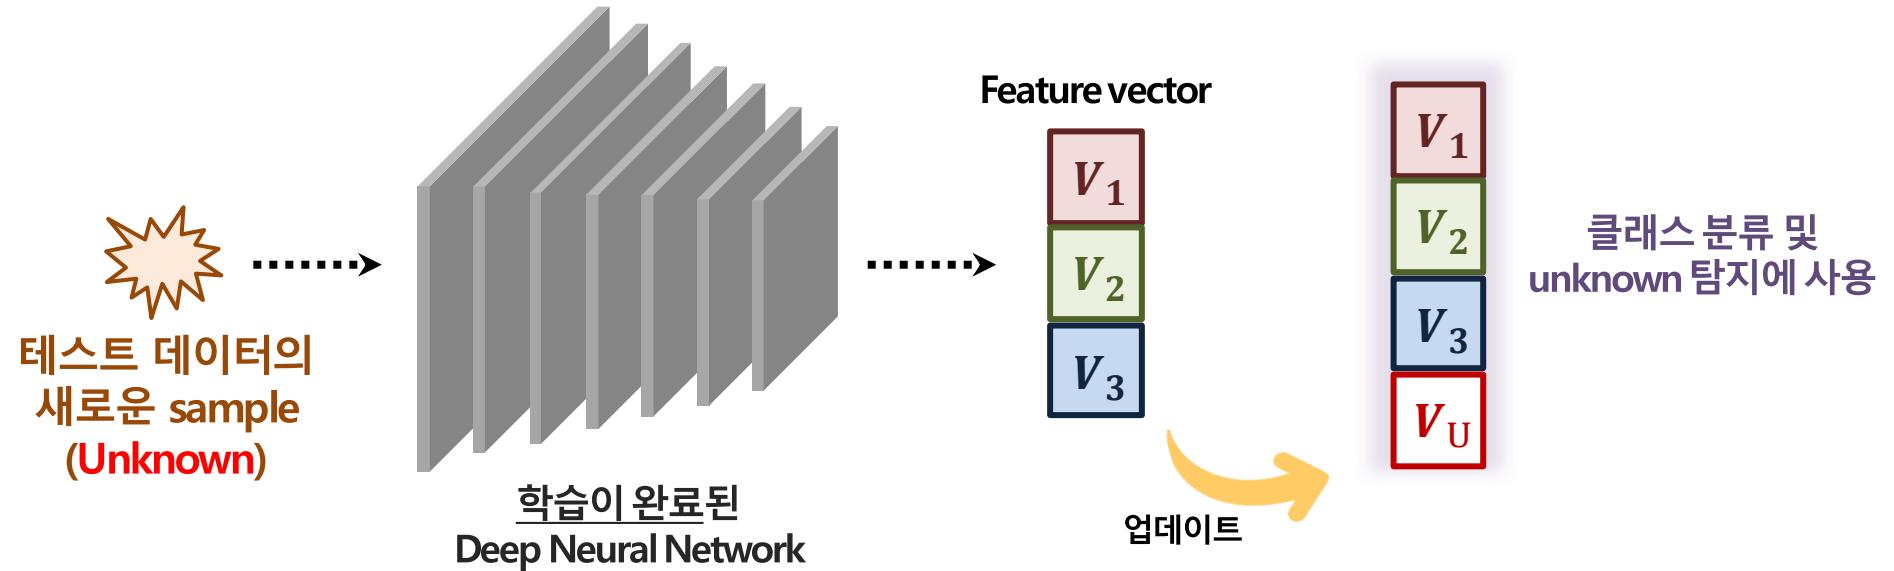


# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

- 학습 데이터로부터 추정된 클래스별 극단 분포(Weibull 분포)를 통해 **feature vector** 업데이트
- 업데이트된 feature vector로 known 클래스 분류와 함께 unknown 탐지 수행

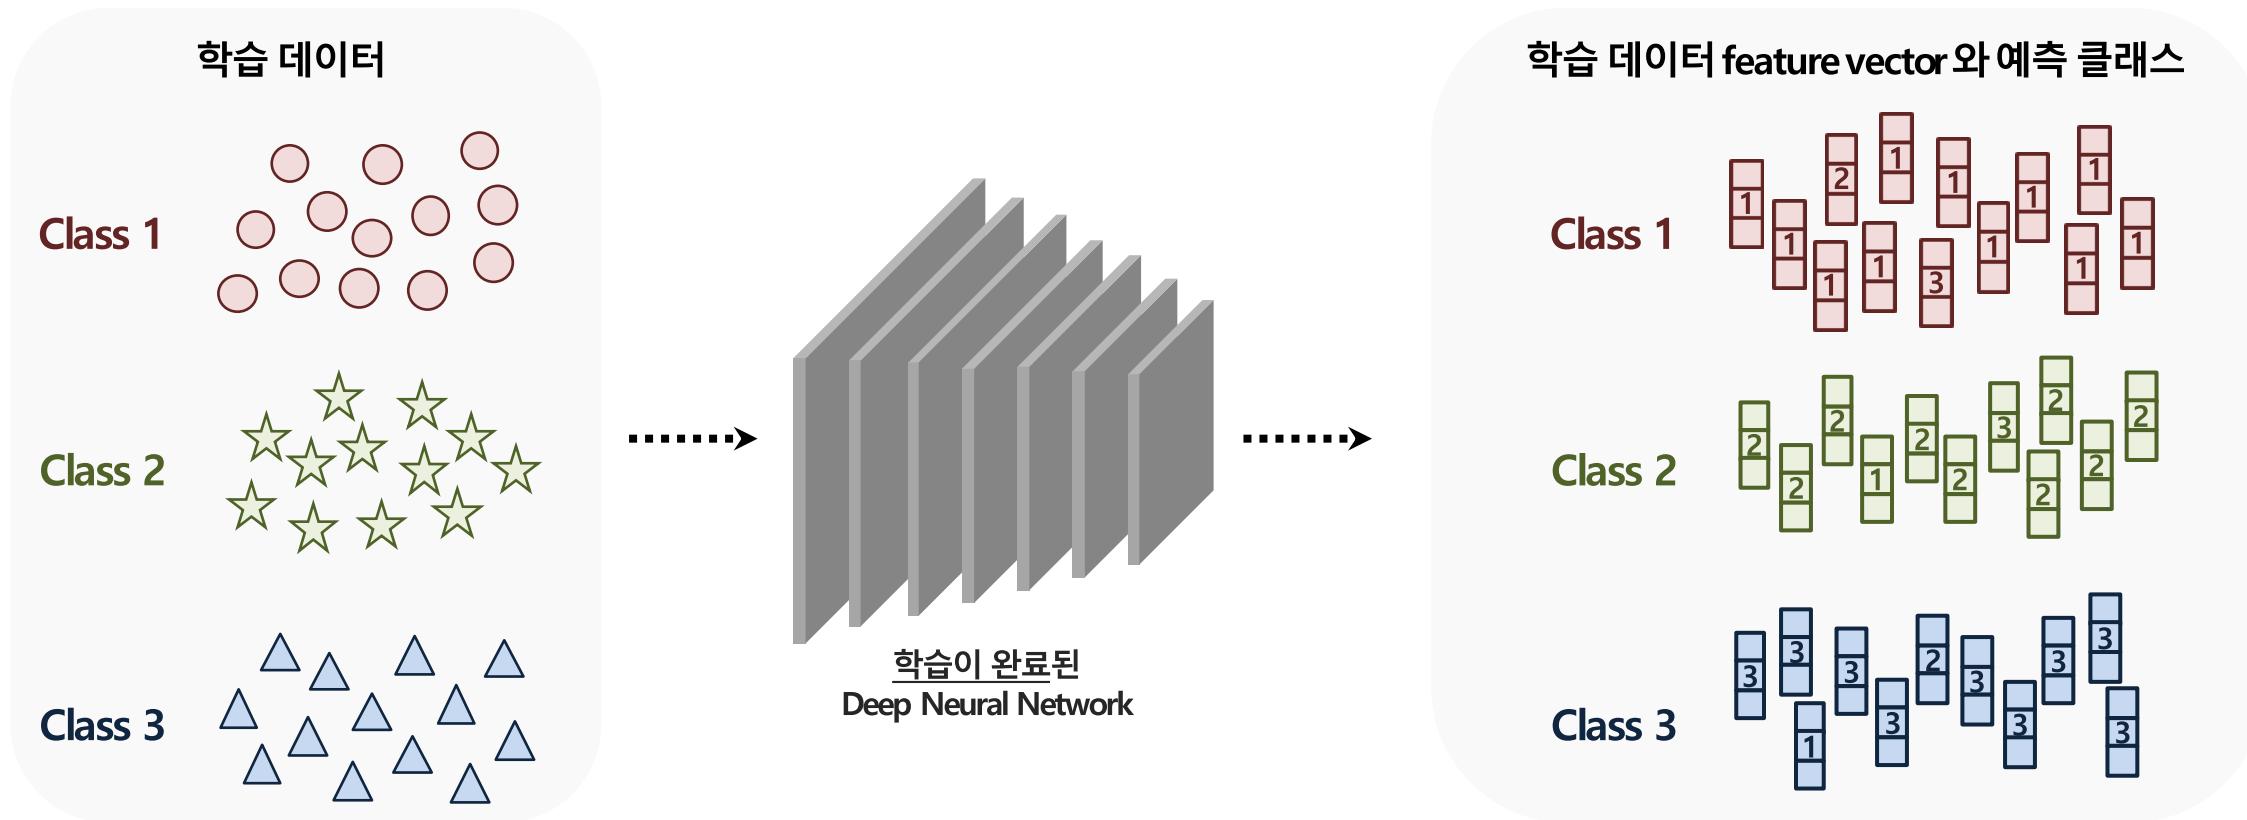


# DNN-Based Open-set Recognition Algorithms

# OpenMax

## ❖ Unknown 탐지 방법

1. 학습이 완료된 모델에 학습 데이터를 입력하여 전체 학습 데이터 샘플의 feature vector와 예측 클래스 구하기

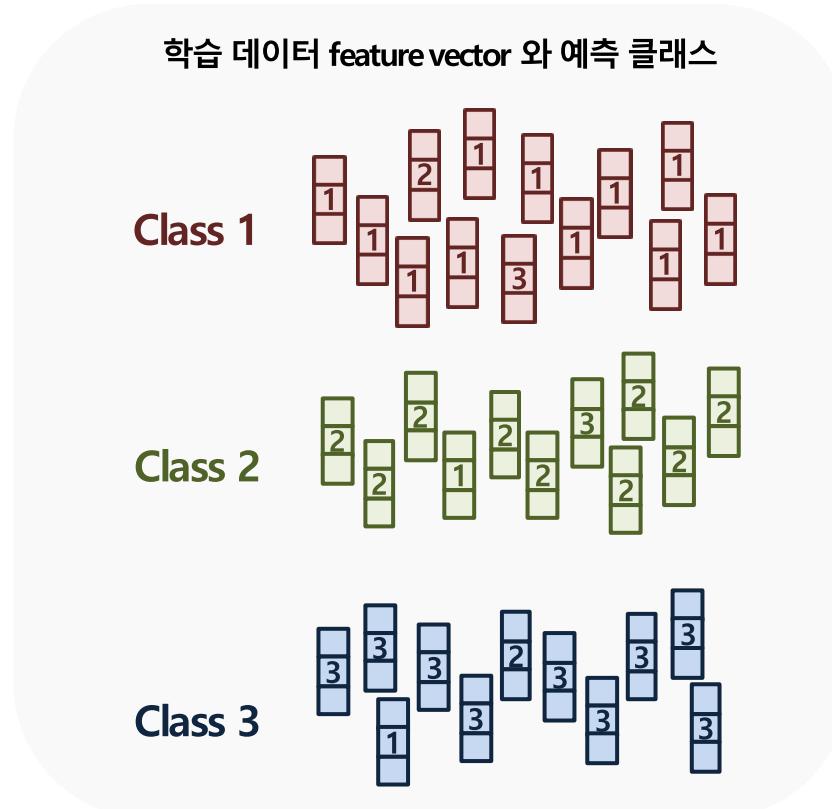


# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

2. 정답 클래스로 잘 예측된 학습 데이터 샘플들의 feature vector로 각 클래스별 평균 feature vector 구하기

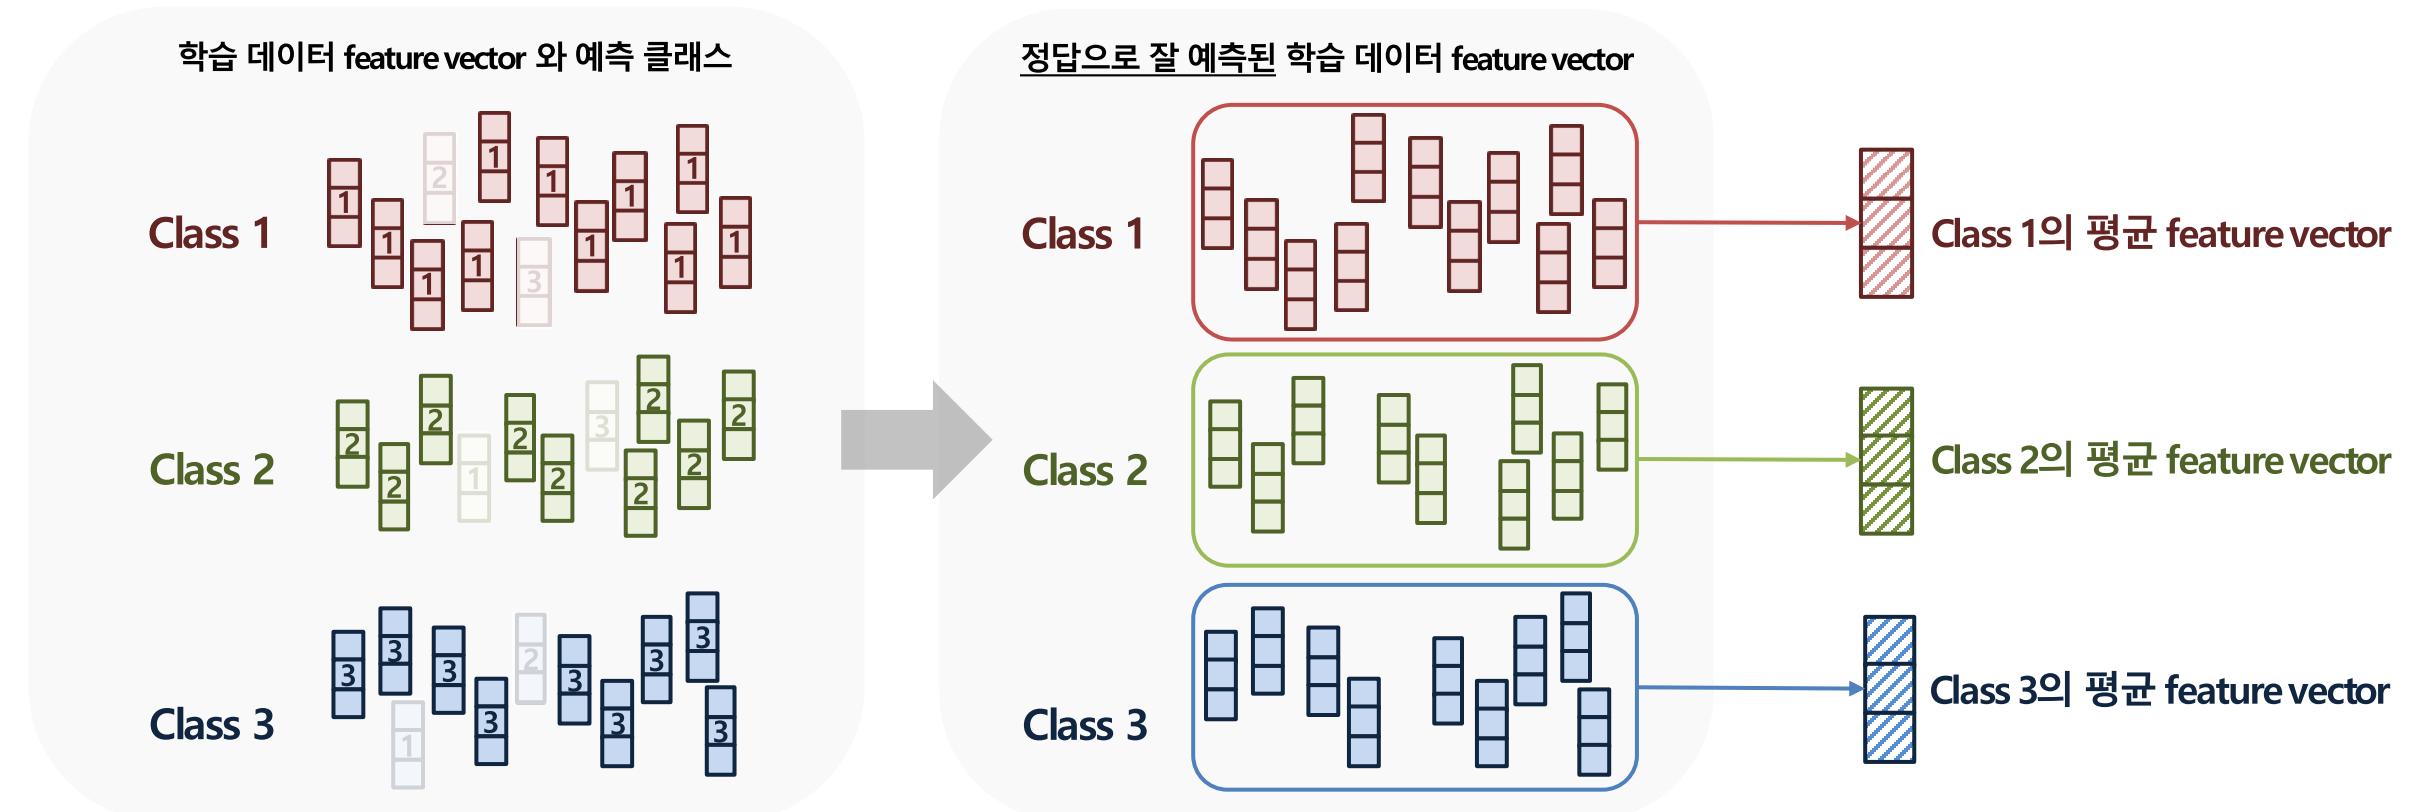


# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

2. 정답 클래스로 잘 예측된 학습 데이터 샘플들의 feature vector로 각 클래스별 평균 feature vector 구하기

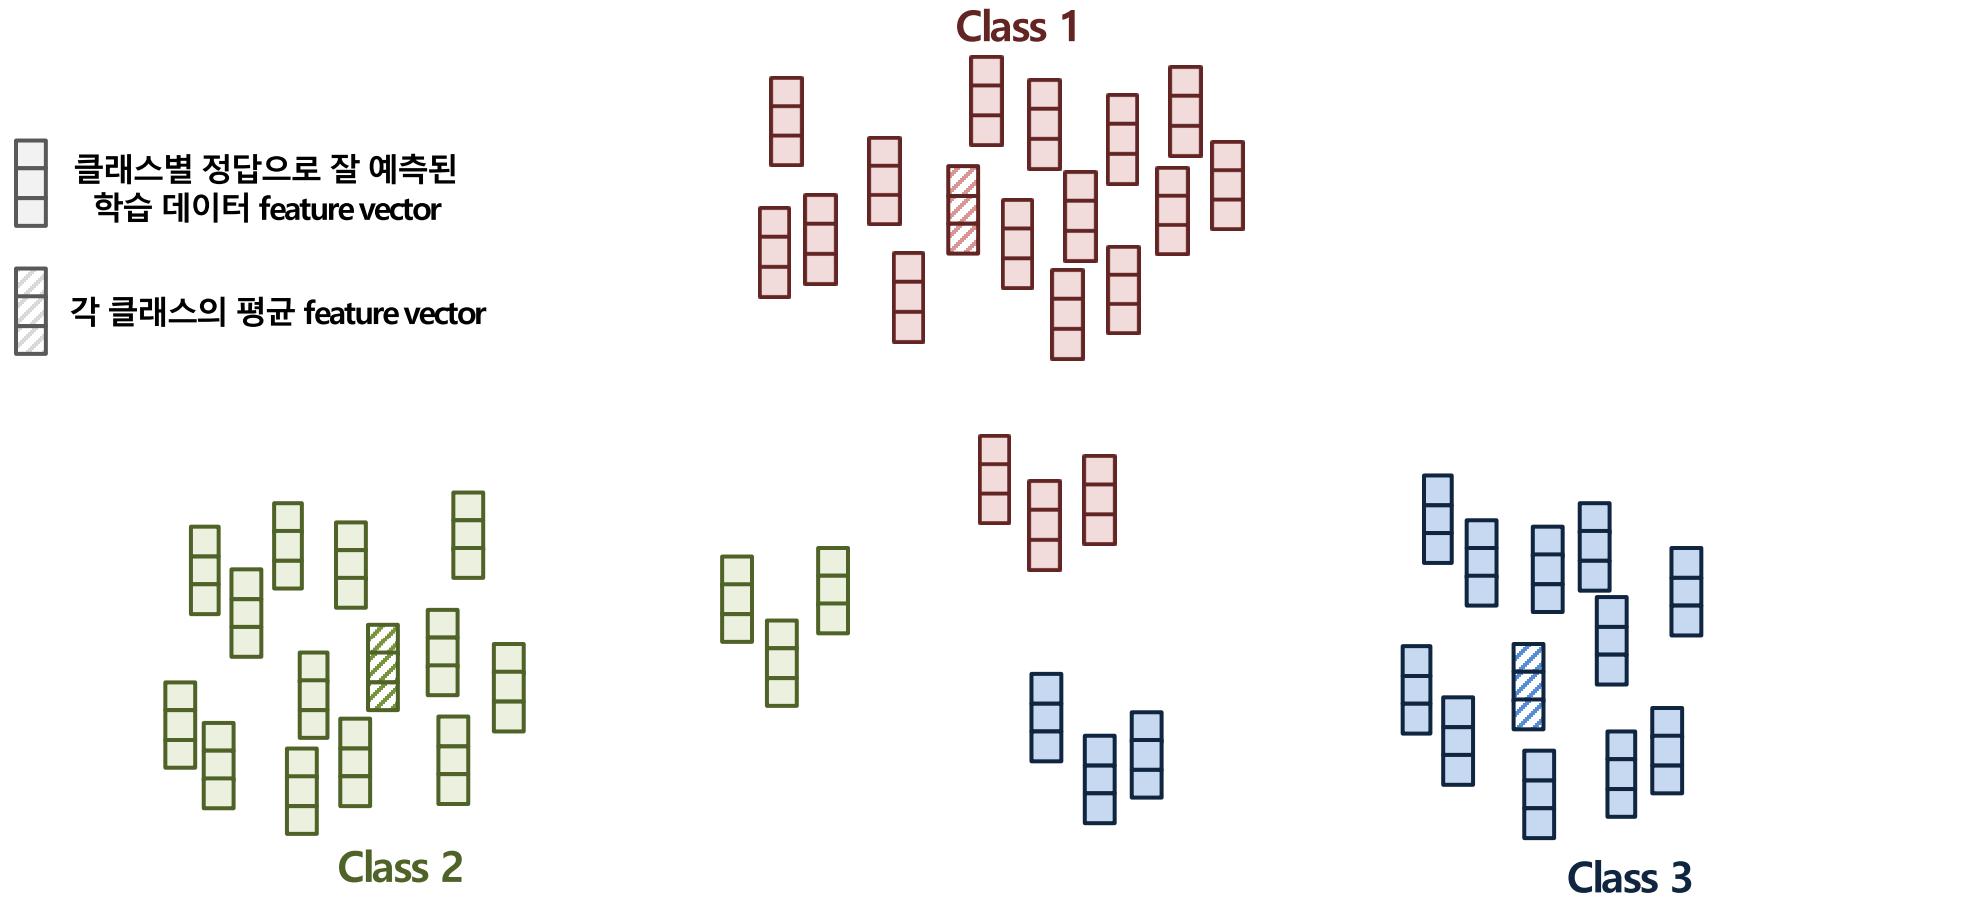


# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

3. 각 클래스별로 평균 feature vector와 정답 클래스로 잘 예측된 학습 데이터 샘플들의 feature vector 사이의 거리 구하기

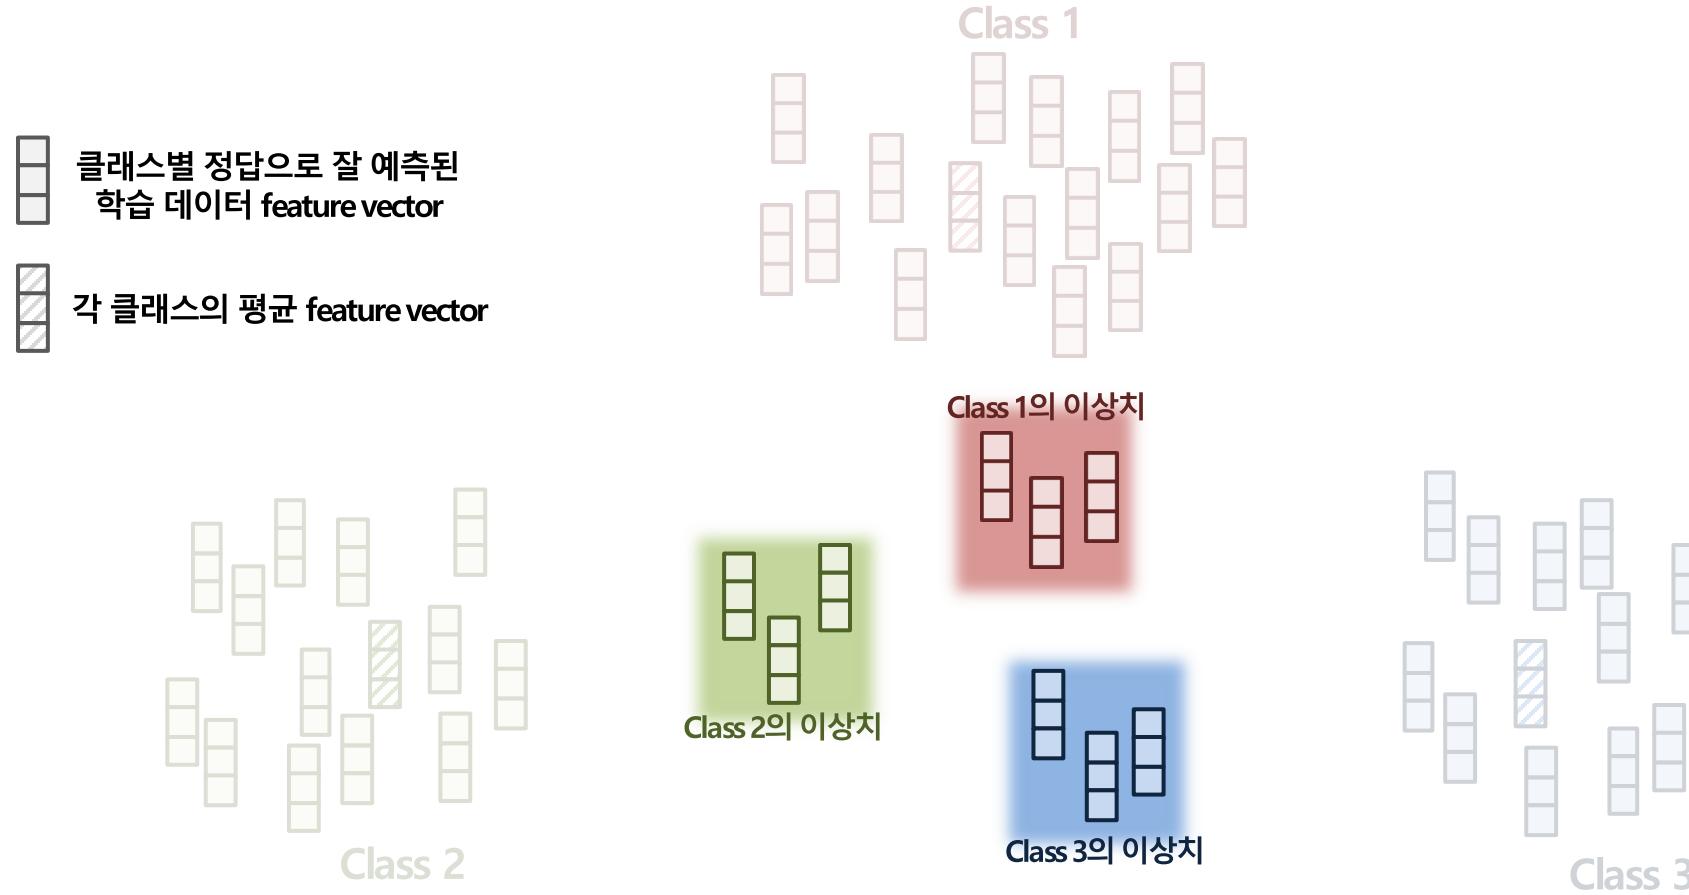


# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

4. 각 클래스별로 평균 feature vector와 가장 멀리 있는 feature vector들을 해당 클래스의 이상치로 정의

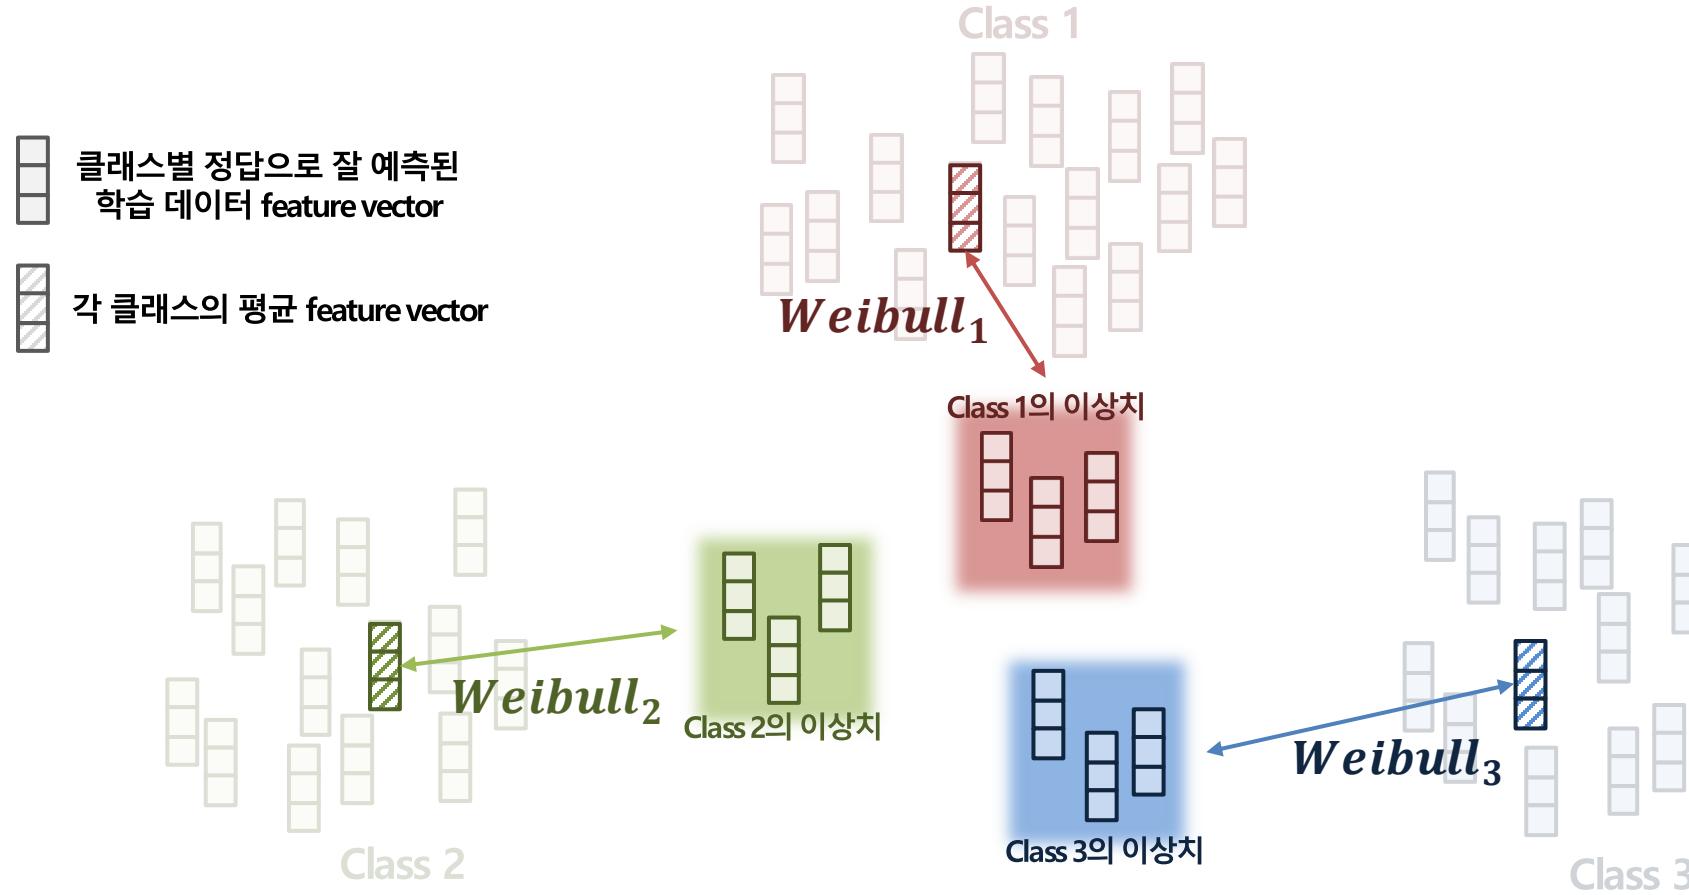


# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

5. 각 클래스별로 이상치로 정의된 feature vector들과 평균 feature vector 사이의 거리로 극단 분포(Weibull 분포) 추정

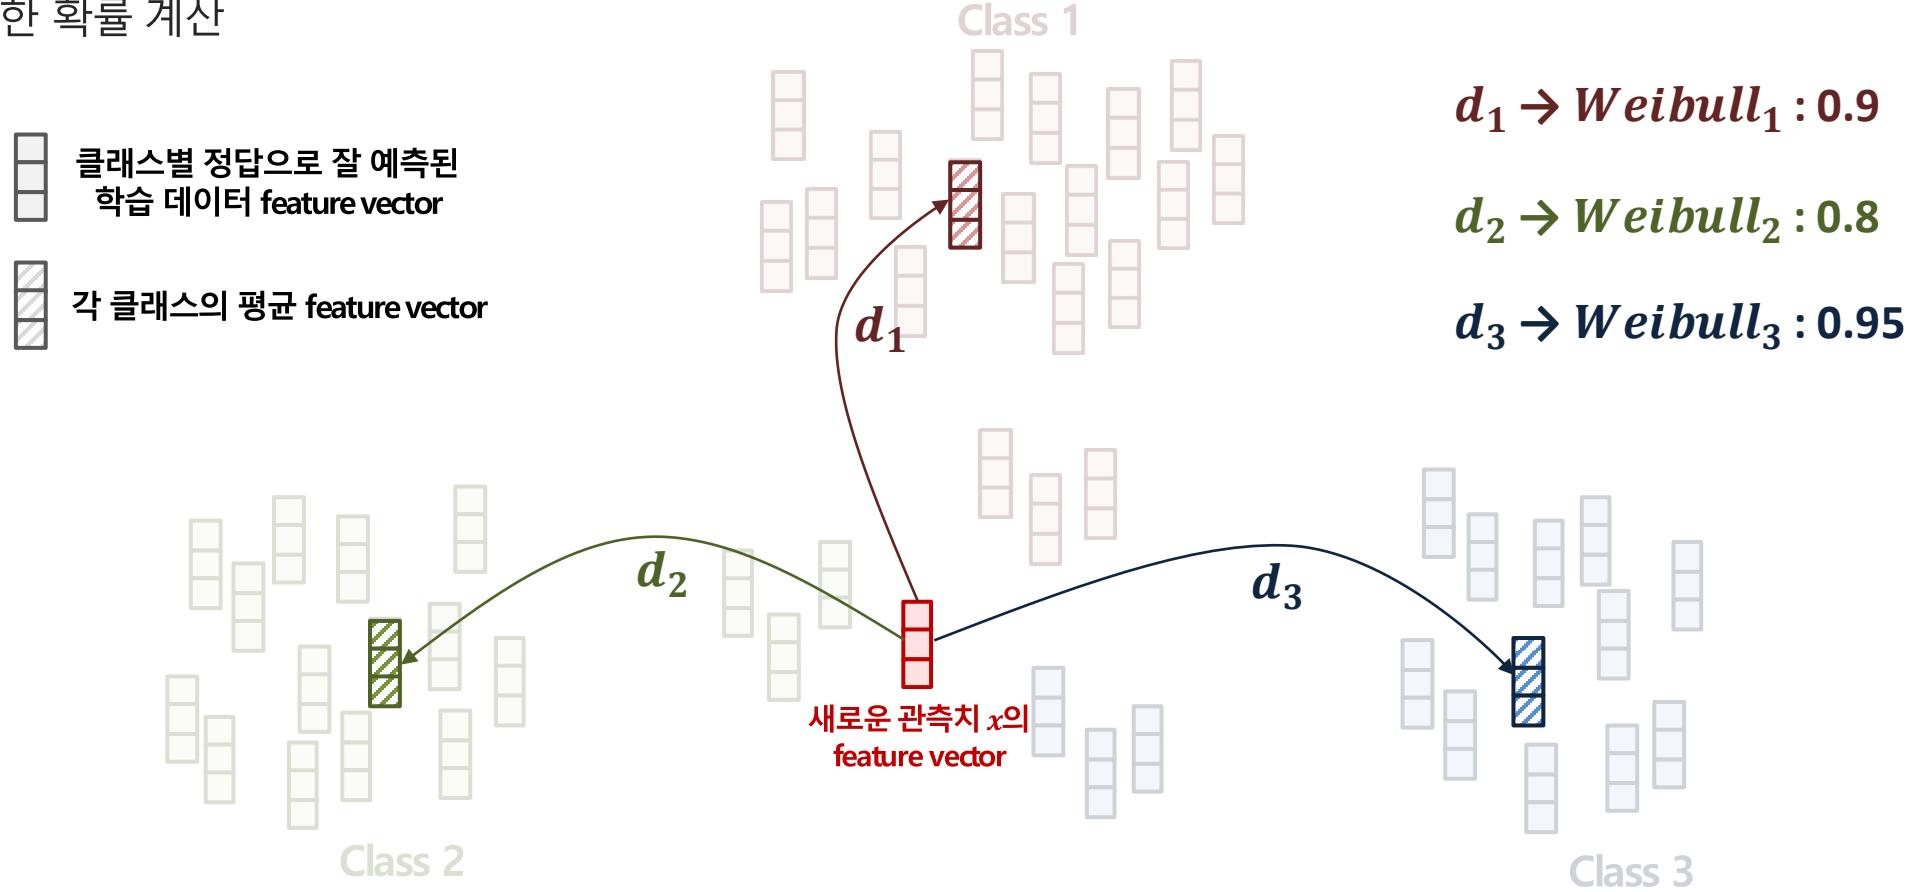


# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

6. 새로운 관측치가 들어오면 각 클래스의 평균 feature vector와의 거리를 계산하여 각 클래스의 극단 분포(Weibull 분포)에 대한 확률 계산



# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

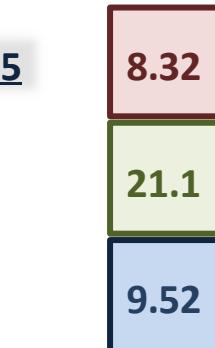
- 계산된 확률값을 통해 feature vector 업데이트하여 unknown에 해당하는 값 생성 후 클래스 분류 및 unknown 탐지 수행

각 클래스에 대한 outlier score  
(= 각 클래스에 속하지 않을 확률)

$$d_1 \rightarrow Weibull_1 : 0.9$$

$$d_2 \rightarrow Weibull_2 : 0.8$$

$$d_3 \rightarrow Weibull_3 : 0.95$$



새로운 관측치  $x$ 의  
feature vector

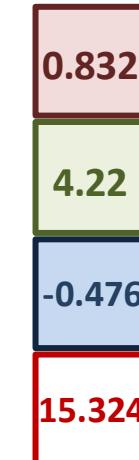


$$\text{Class1} : 8.32(1-0.9)=0.832$$

$$\text{Class2} : 21.1(1-0.8)=4.22$$

$$\text{Class3} : -9.52(1-0.95)=-0.476$$

$$\text{Unknown} : 8.32 \times 0.9 + 21.1 \times 0.8 + (-9.52) \times 0.95 = 15.324$$



새로운 관측치  $x$ 의  
업데이트된 feature vector



# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ Unknown 탐지 방법

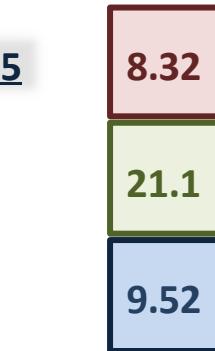
- 계산된 확률값을 통해 feature vector 업데이트하여 unknown에 해당하는 값 생성 후 클래스 분류 및 unknown 탐지 수행

각 클래스에 대한 outlier score  
(= 각 클래스에 속하지 않을 확률)

$$d_1 \rightarrow Weibull_1 : 0.9$$

$$d_2 \rightarrow Weibull_2 : 0.8$$

$$d_3 \rightarrow Weibull_3 : 0.95$$



새로운 관측치  $x$ 의  
feature vector

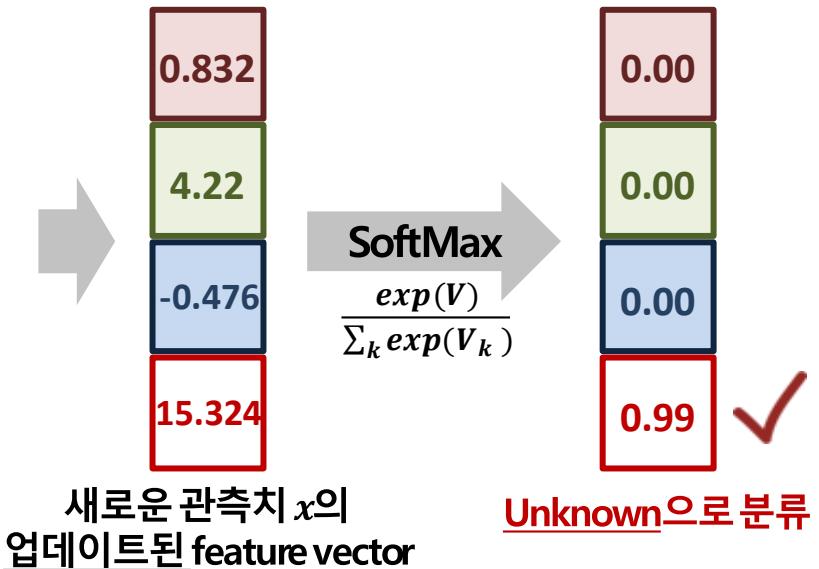


$$\text{Class1} : 8.32(1-0.9)=0.832$$

$$\text{Class2} : 21.1(1-0.8)=4.22$$

$$\text{Class3} : -9.52(1-0.95)=-0.476$$

$$\text{Unknown} : 8.32 \times 0.9 + 21.1 \times 0.8 + (-9.52) \times 0.95 = 15.324$$



# DNN-Based Open-set Recognition Algorithms

## OpenMax

### ❖ 실험 결과

- 실험을 통해 SoftMax + threshold와 OpenMax의 성능 비교
- 학습 데이터에 포함된 클래스(known class)에 대한 분류 성능은 SoftMax+threshold와 OpenMax 간 큰 차이 없음
- 학습 데이터에 포함되지 않은 클래스(unknown class)의 경우 SoftMax+threshold보다 OpenMax가 우수한 성능으로 unknown 탐지 수행

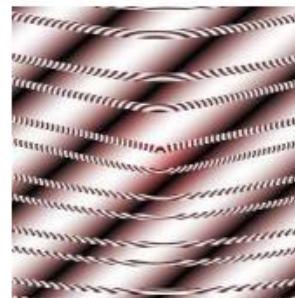
학습 데이터에 포함된 클래스

*Baseball*



Real: SM 0.94 OM 0.94

학습 데이터에 포함되지 않은 클래스

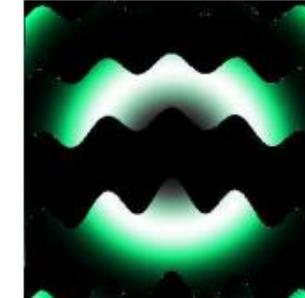


Fooling: SM 1.0, OM 0.00

*Hammerhead*



Real: SM 0.57, OM 0.58



Fooling: SM 0.98, OM 0.00

## **2.2 CROSR**

**(Classification-Reconstruction learning  
for Open-Set Recognition)**

# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ Classification-reconstruction learning for open-set recognition

- Yoshihashi, R., Shao, W., Kawakami, R., You, S., Iida, M., & Naemura, T. (2019). Classification-reconstruction learning for open-set recognition. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (pp. 4016-4025).
- 2022년 7월 21일 기준 166회 인용
- Unknown 탐지에 효과적인 feature vector를 학습하기 위해 **reconstruction 구조를 활용한 CROSR 제안**



This CVPR paper is the Open Access version, provided by the Computer Vision Foundation.  
Except for this watermark, it is identical to the accepted version;  
the final published version of the proceedings is available on IEEE Xplore.

## Classification-Reconstruction Learning for Open-Set Recognition

Ryota Yoshihashi<sup>1</sup>

Shaodi You<sup>2</sup>

<sup>1</sup>The University of Tokyo

Wen Shao<sup>1</sup>

Makoto Iida<sup>1</sup>

<sup>2</sup>Data61-CSIRO

Rei Kawakami<sup>1</sup>

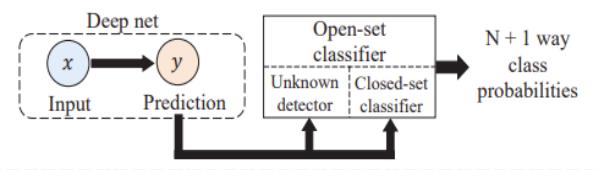
Takeshi Naemura<sup>1</sup>

{yoshi, shao, rei, naemura}@nae-lab.org, Shaodi.You@data61.csiro.au, iida@ilab.eco.rcast.u-tokyo.ac.jp

### Abstract

*Open-set classification is a problem of handling ‘unknown’ classes that are not contained in the training dataset, whereas traditional classifiers assume that only known classes appear in the test environment. Existing open-set classifiers rely on deep networks trained in*

#### a) Existing deep open-set classifiers (Openmax, G-Openmax, DOC)

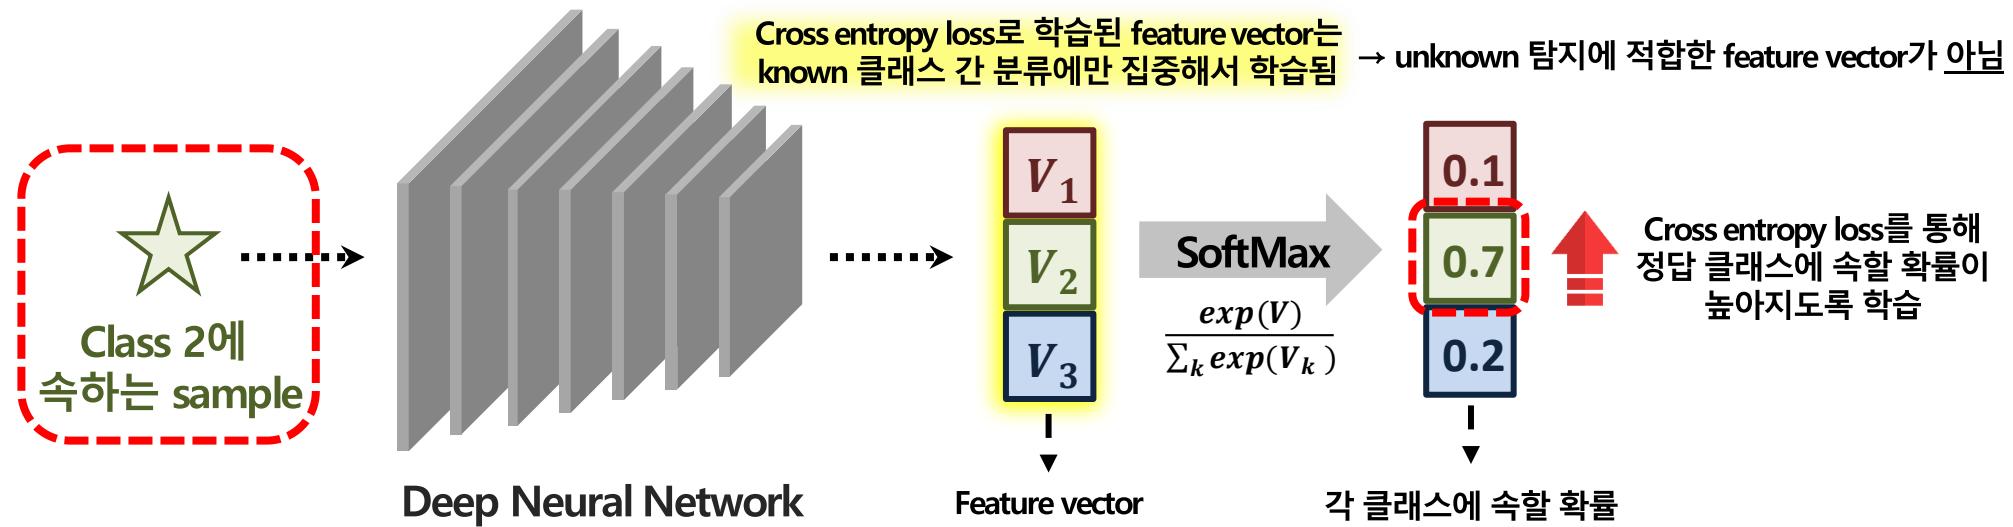


# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ 모델 학습 방법

- CROSR은 open-set 조건에서의 cross-entropy loss 단점을 극복하기 위해 reconstruction error를 함께 사용하여 모델 학습
- Reconstruction을 수행하며 latent feature 생성
- Unknown 탐지 수행 시 모델의 feature vector와 함께 latent feature도 활용

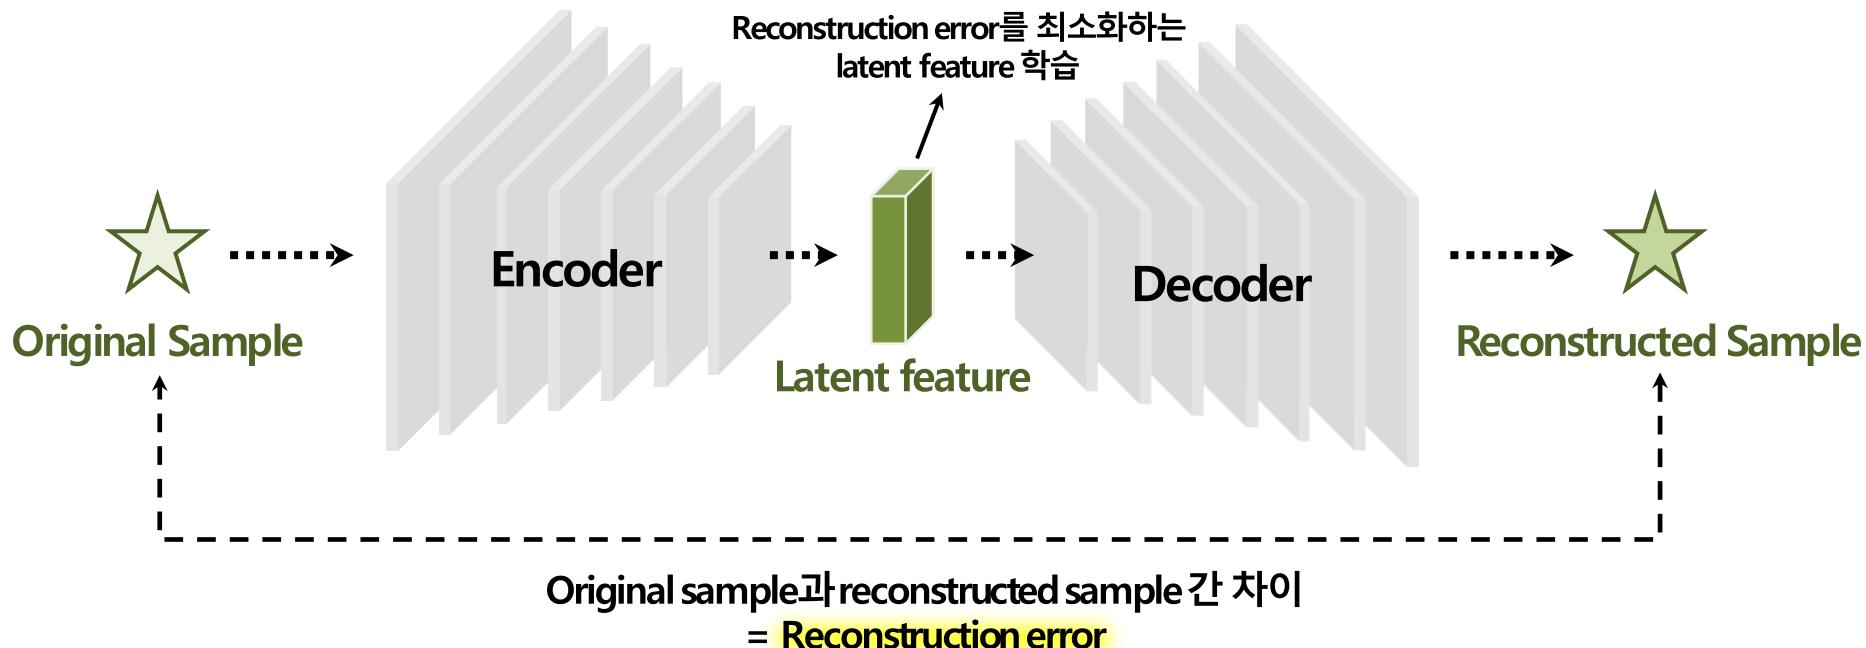


# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ 모델 학습 방법

- CROSR은 open-set 조건에서의 cross-entropy loss 단점을 극복하기 위해 reconstruction error를 함께 사용하여 모델 학습
- Reconstruction을 수행하며 latent feature 생성
- Unknown 탐지 수행 시 모델의 feature vector와 함께 latent feature도 활용

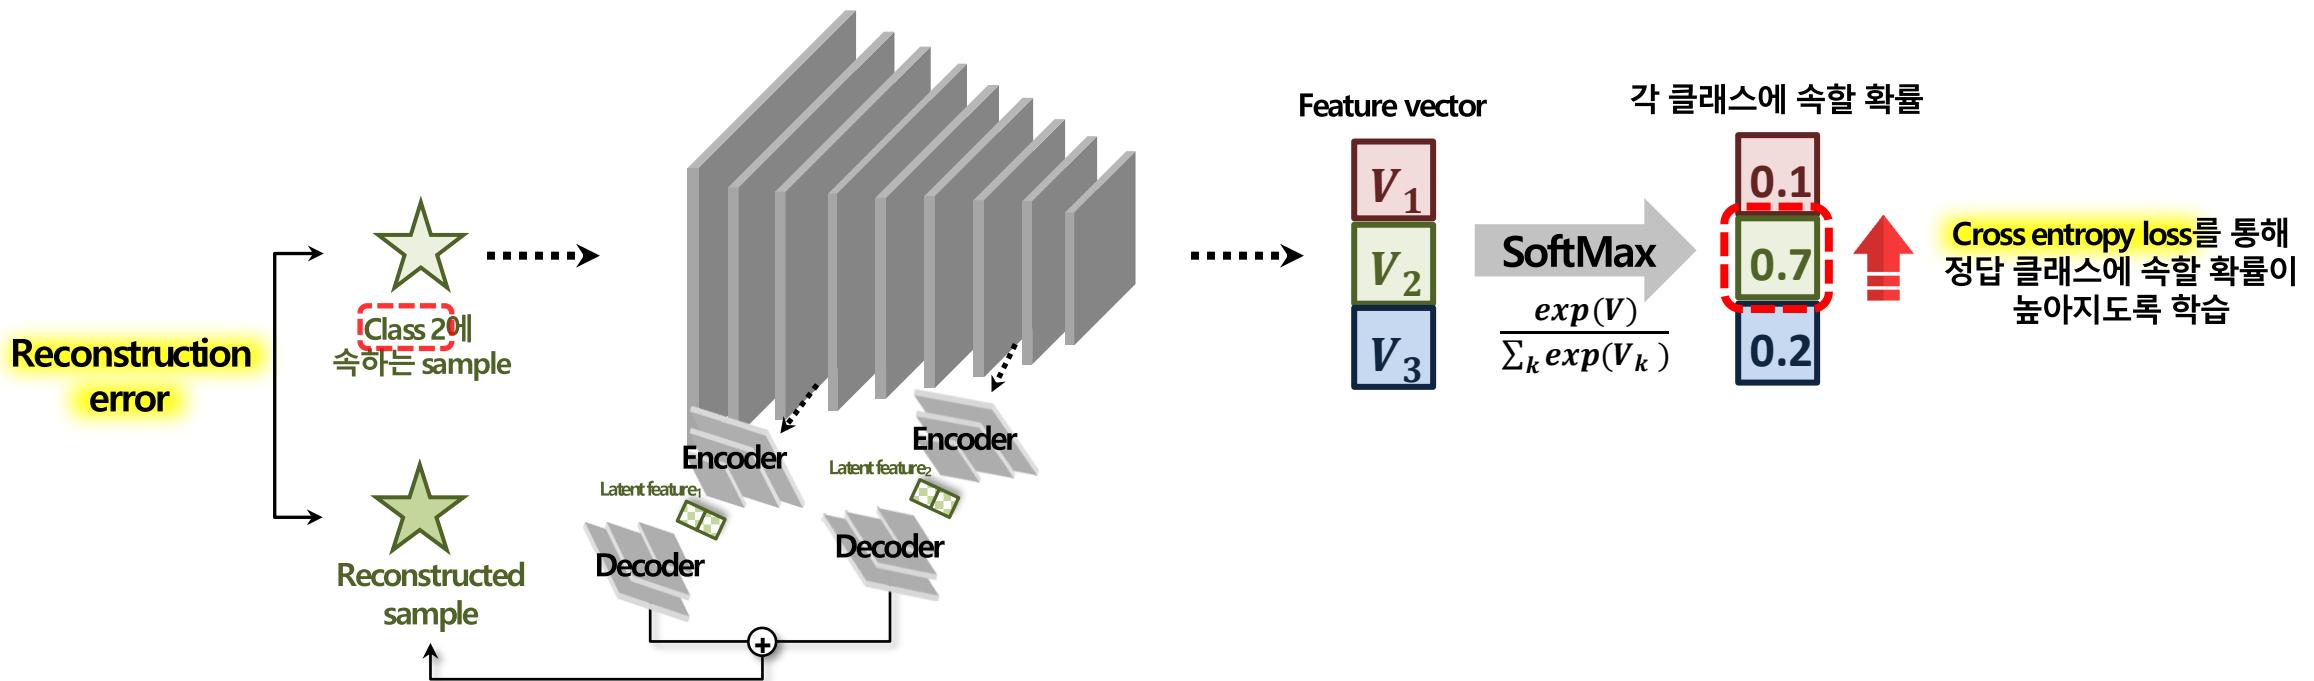


# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ 모델 학습 방법

- CROSR은 open-set 조건에서의 cross-entropy loss 단점을 극복하기 위해 reconstruction error를 함께 사용하여 모델 학습
- Reconstruction을 수행하며 latent feature 생성
- Unknown 탐지 수행 시 모델의 feature vector와 함께 latent feature도 활용

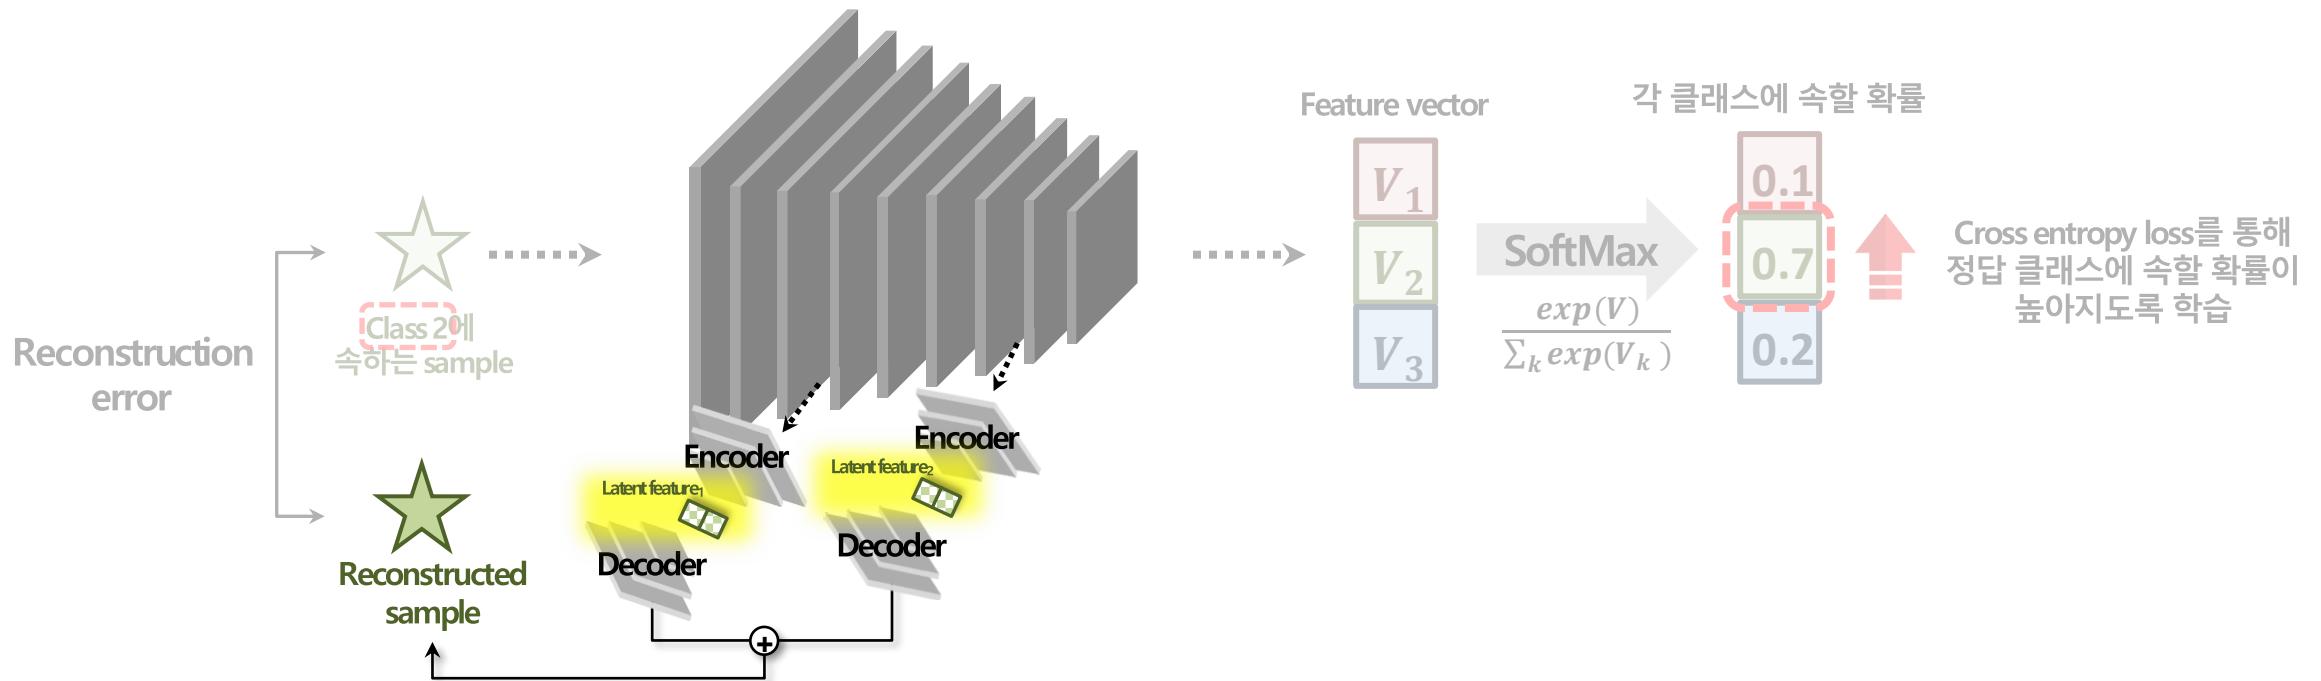


# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ 모델 학습 방법

- CROSR은 open-set 조건에서의 cross-entropy loss 단점을 극복하기 위해 reconstruction error를 함께 사용하여 모델 학습
- Reconstruction을 수행하며 latent feature 생성
- Unknown 탐지 수행 시 모델의 feature vector와 함께 latent feature도 활용

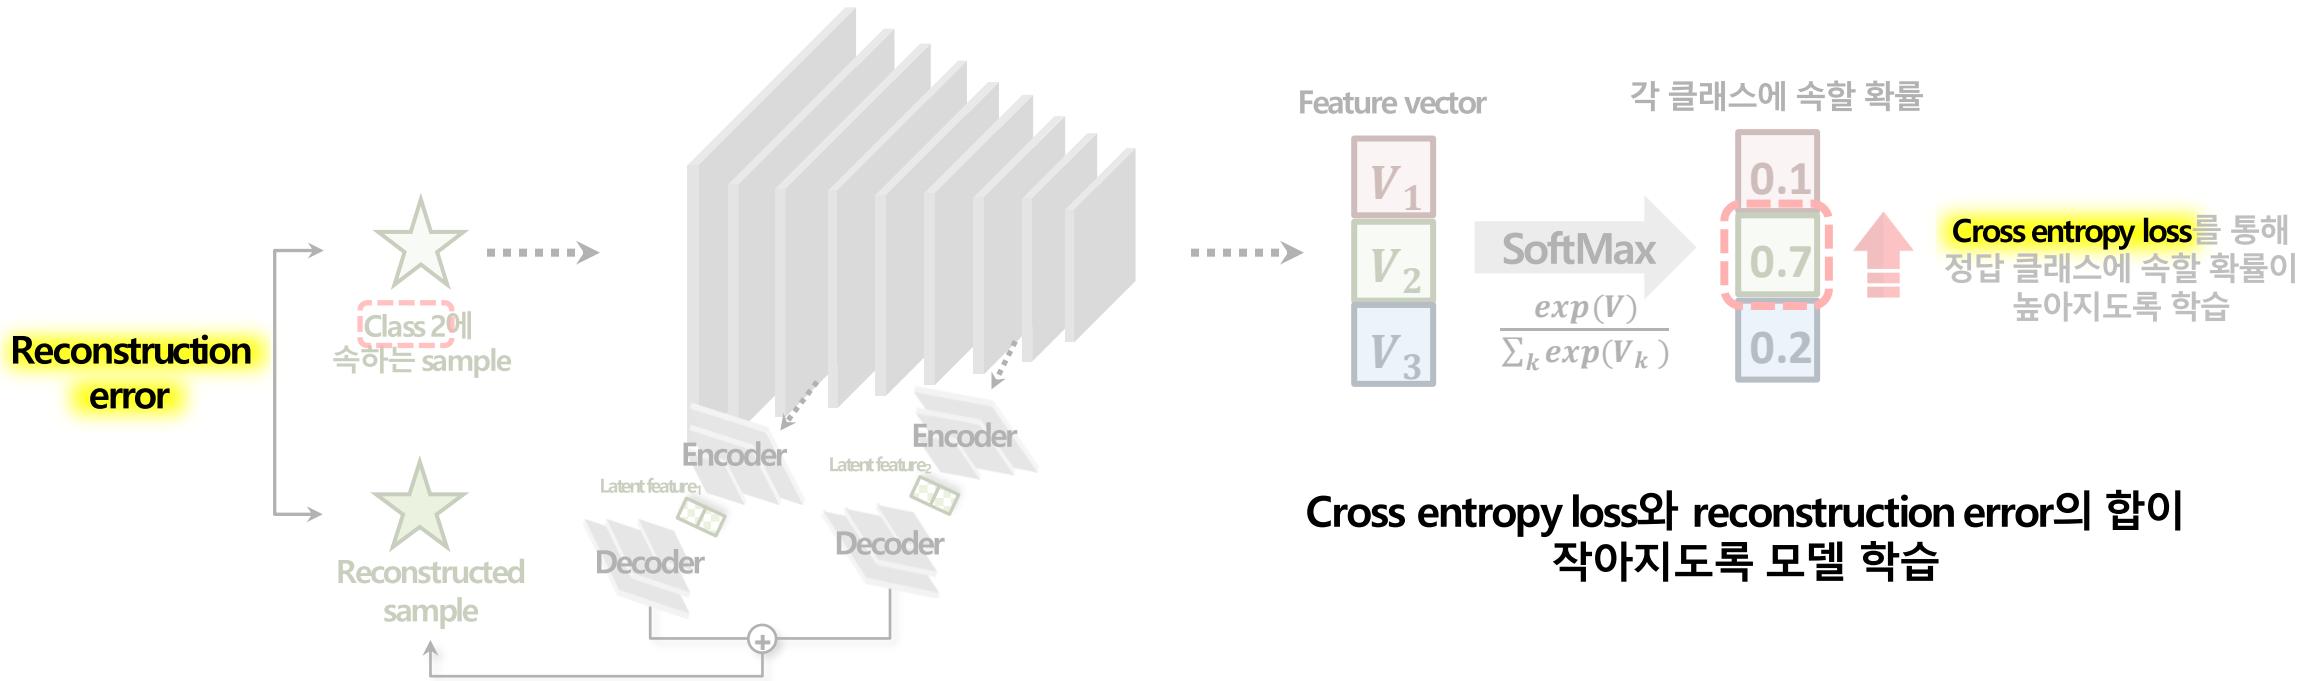


# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ 모델 학습 방법

- CROSR은 open-set 조건에서의 cross-entropy loss 단점을 극복하기 위해 reconstruction error를 함께 사용하여 모델 학습
- Reconstruction을 수행하며 latent feature 생성
- Unknown 탐지 수행 시 모델의 feature vector와 함께 latent feature도 활용

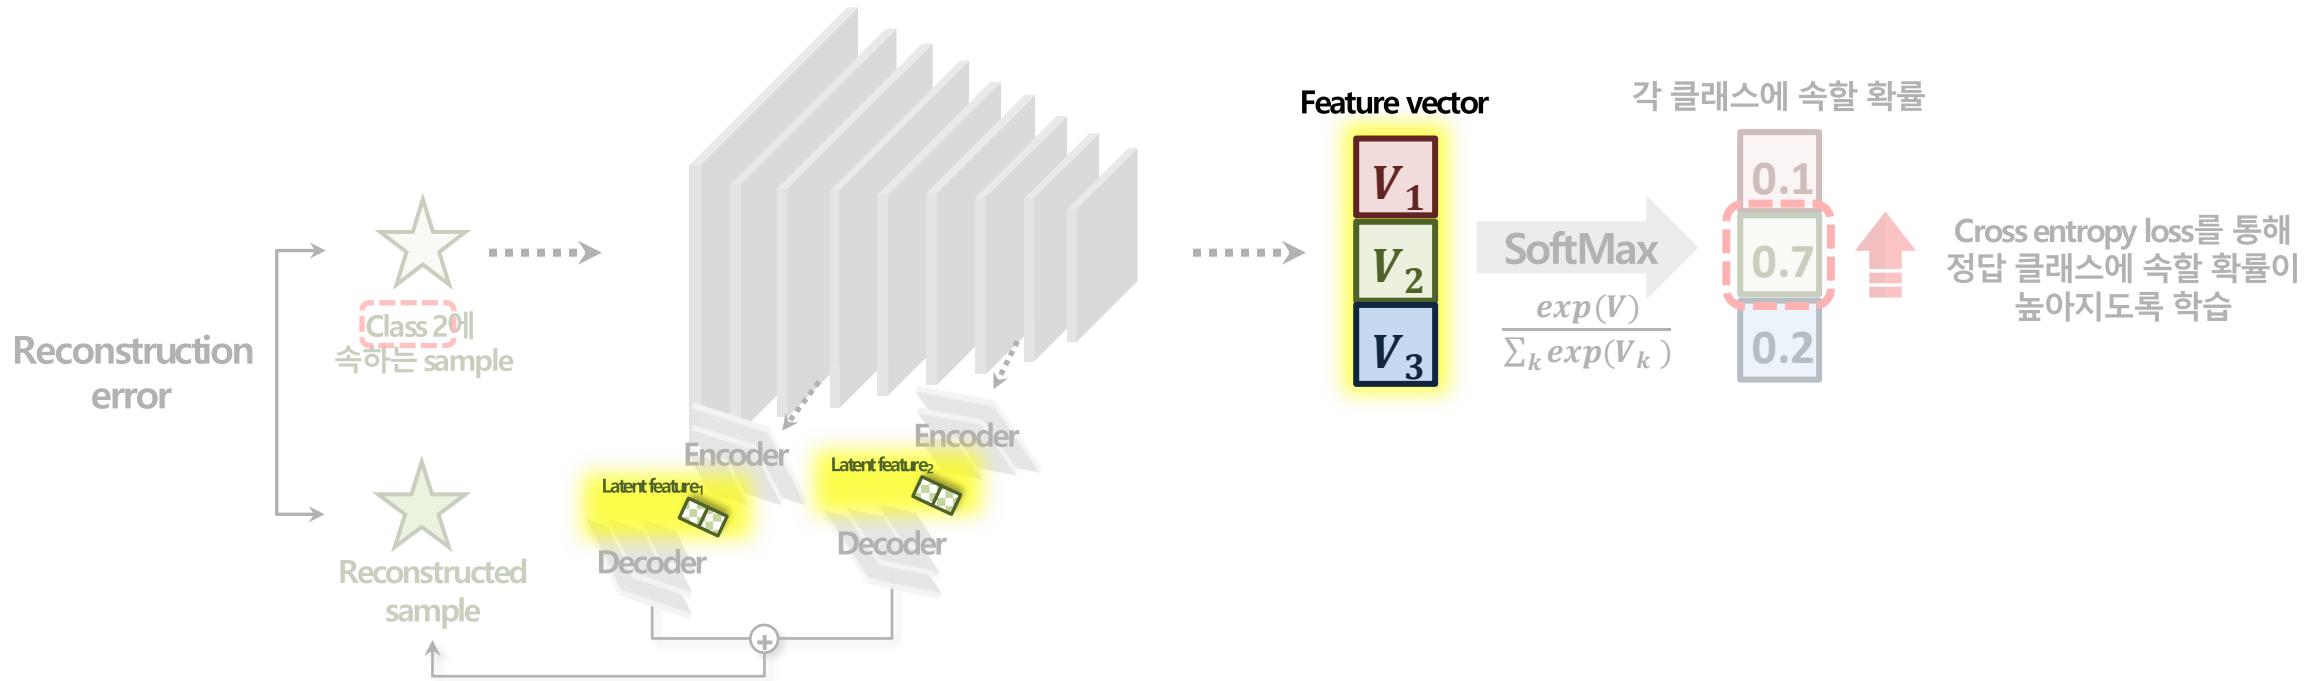


# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ 모델 학습 방법

- CROSR은 open-set 조건에서의 cross-entropy loss 단점을 극복하기 위해 reconstruction error를 함께 사용하여 모델 학습
- Reconstruction을 수행하며 latent feature 생성
- Unknown 탐지 수행 시 모델의 feature vector와 함께 latent feature도 활용

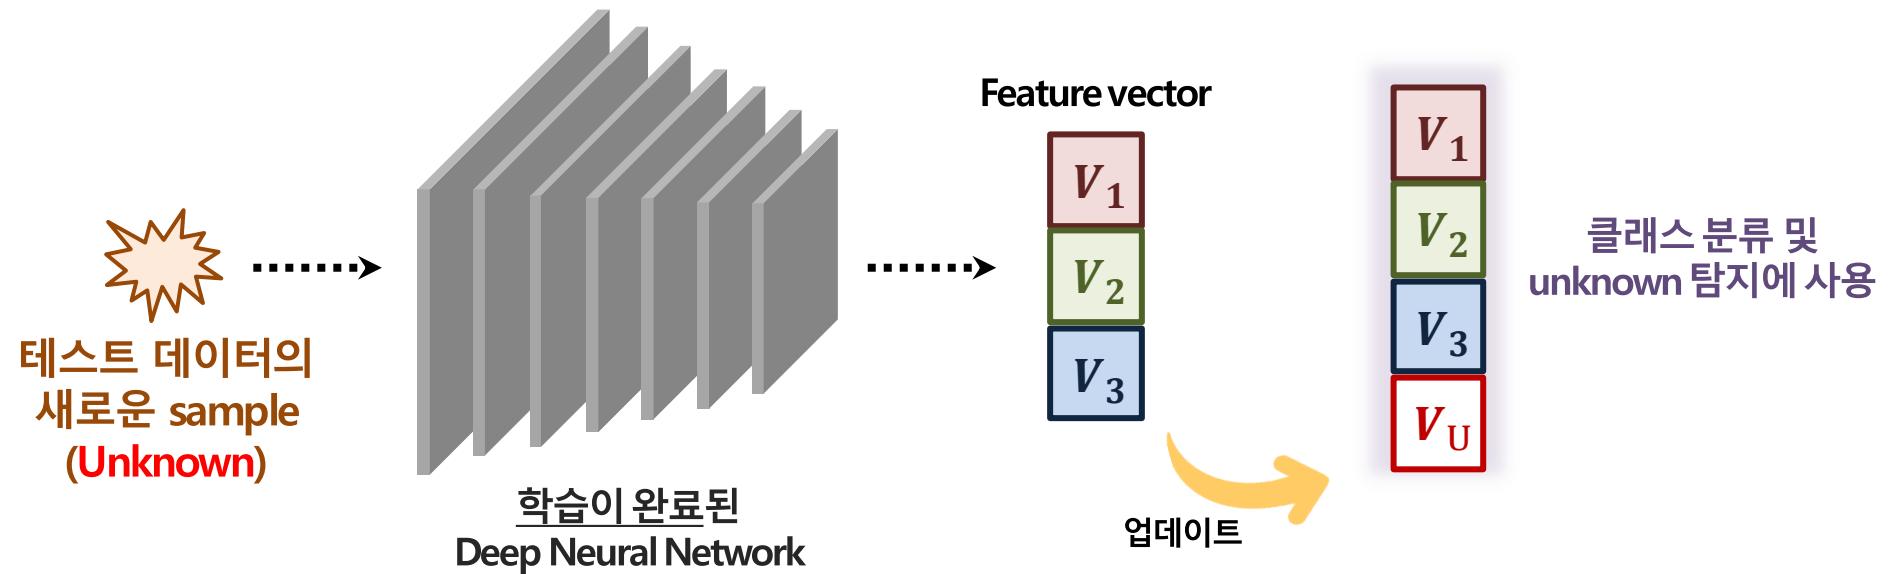


# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ Unknown 탐지 방법

- OpenMax와 동일한 방식으로 Unknown 탐지가 수행됨 → 학습 데이터로부터 추정한 극단 분포(Weibull 분포)를 통해 feature vector 업데이트
- OpenMax와의 차이점 : 극단 분포(Weibull 분포) 추정 시 feature vector와 latent feature를 같이 활용

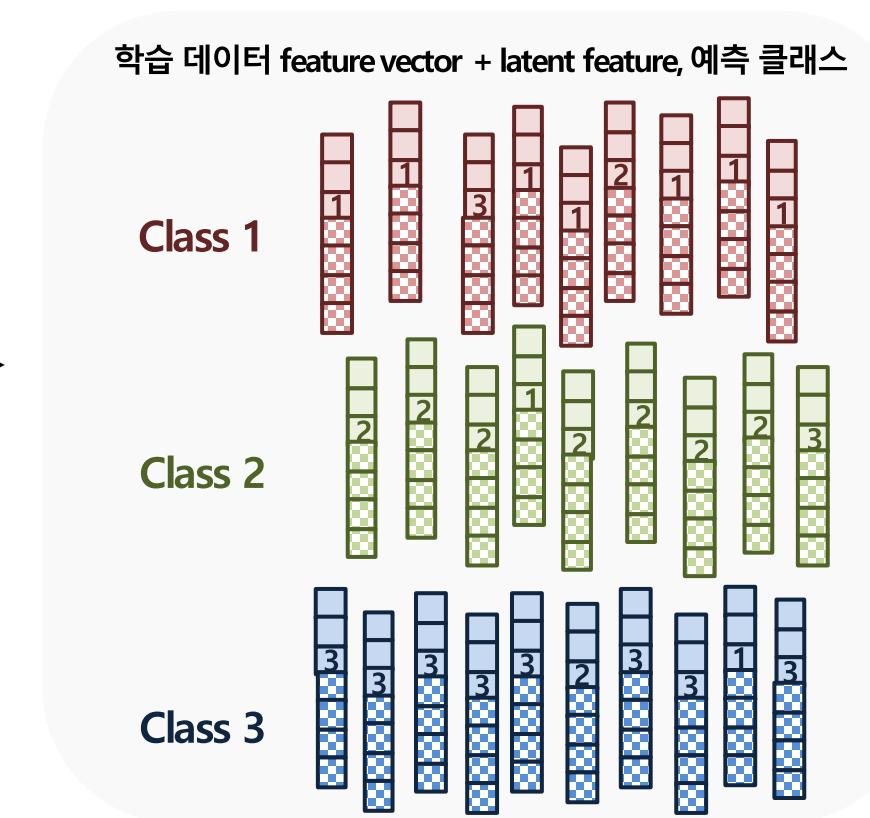
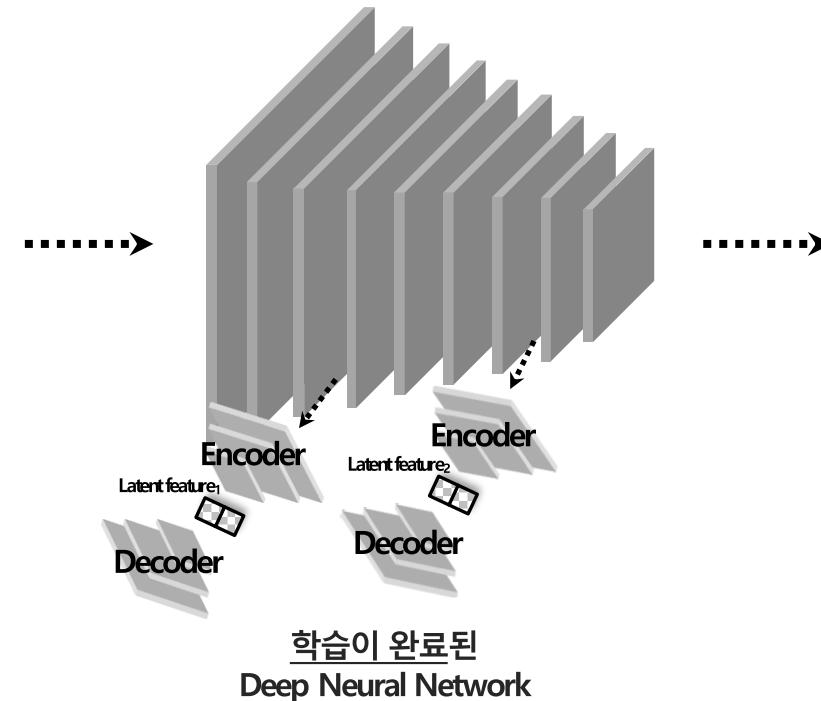
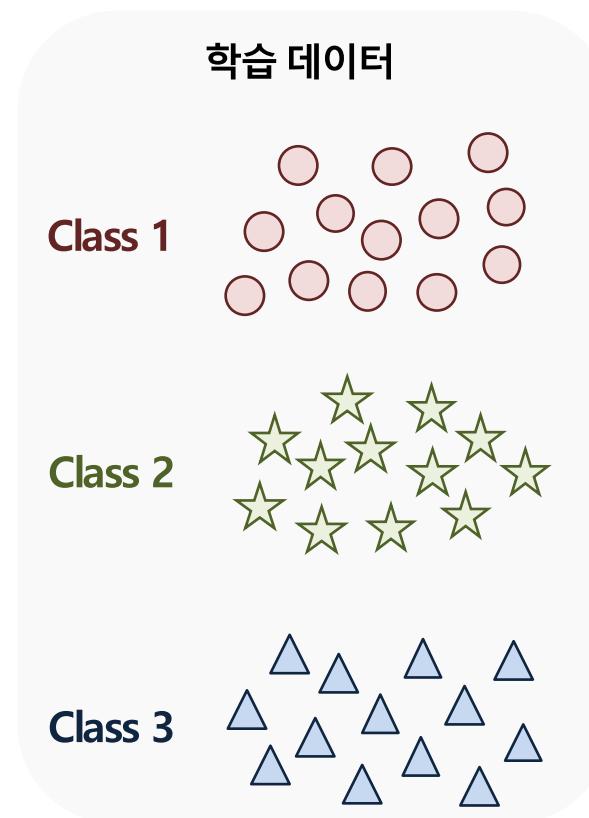


# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ Unknown 탐지 방법

1. 학습이 완료된 모델에 학습 데이터를 입력하여 전체 학습 데이터 샘플의 feature vector와 latent feature, 예측 클래스를 구한 후, feature vector와 latent feature 결합



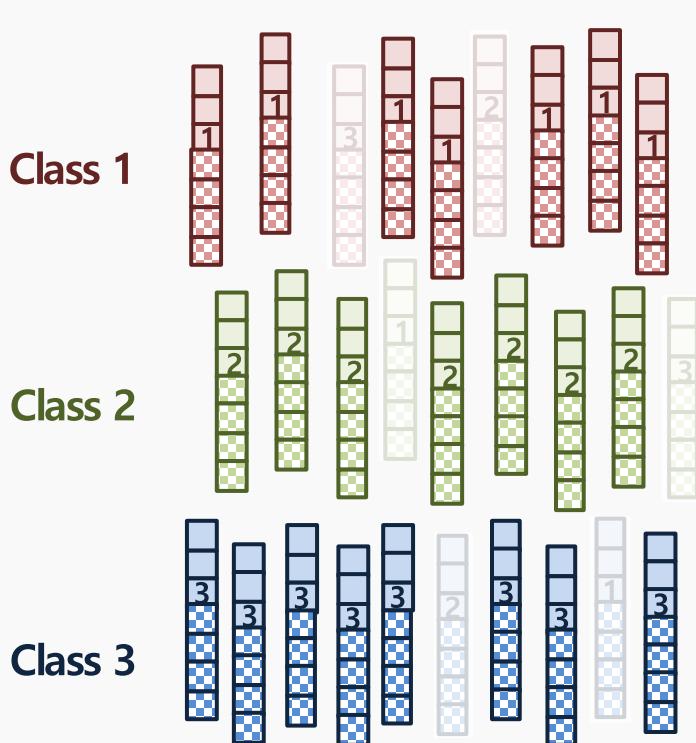
# DNN-Based Open-set Recognition Algorithms

CROSR

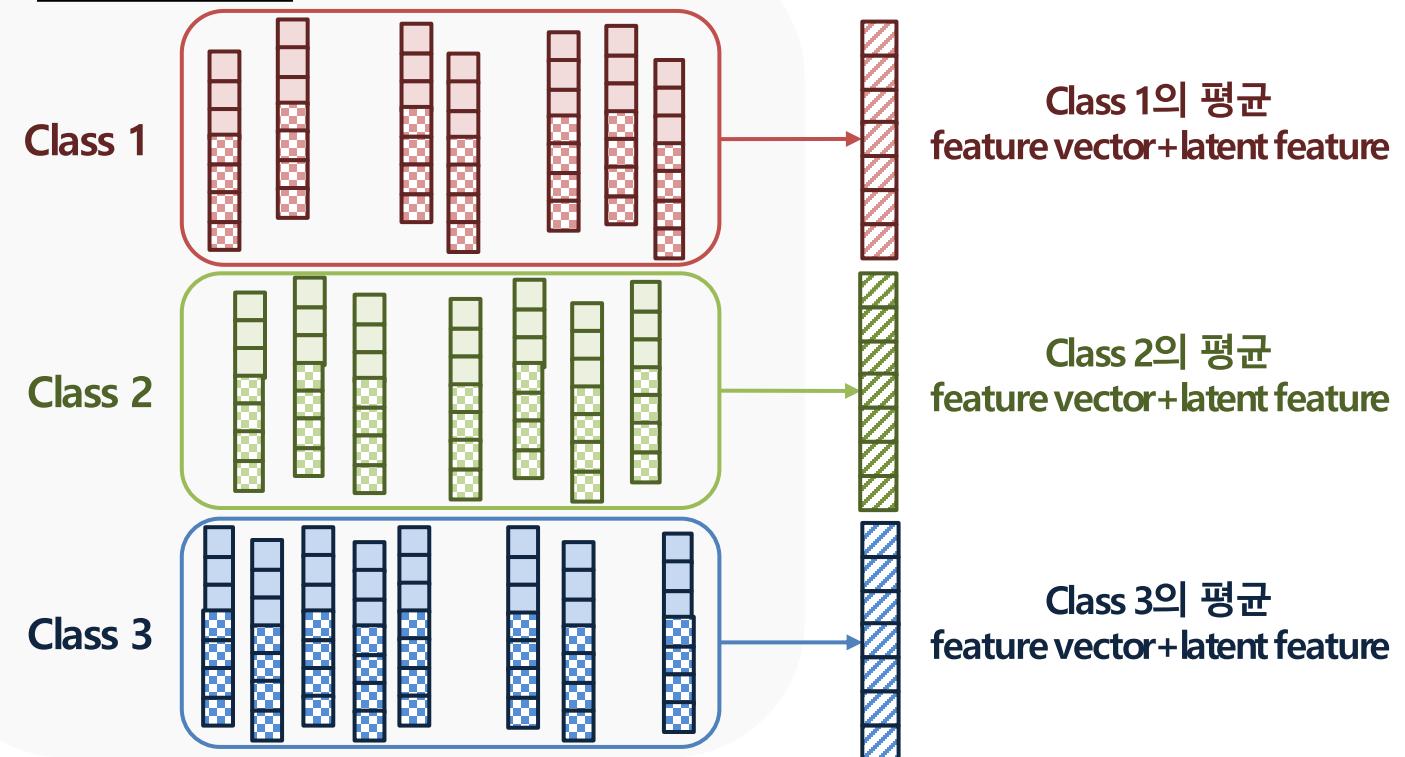
## ❖ Unknown 탐지 방법

2. 정답 클래스로 잘 예측된 학습 데이터 샘플들의 feature vector+latent feature로 클래스별 평균 feature vector+latent feature 구하기

학습 데이터 feature vector + latent feature, 예측 클래스



정답으로 잘 예측된 feature vector + latent feature



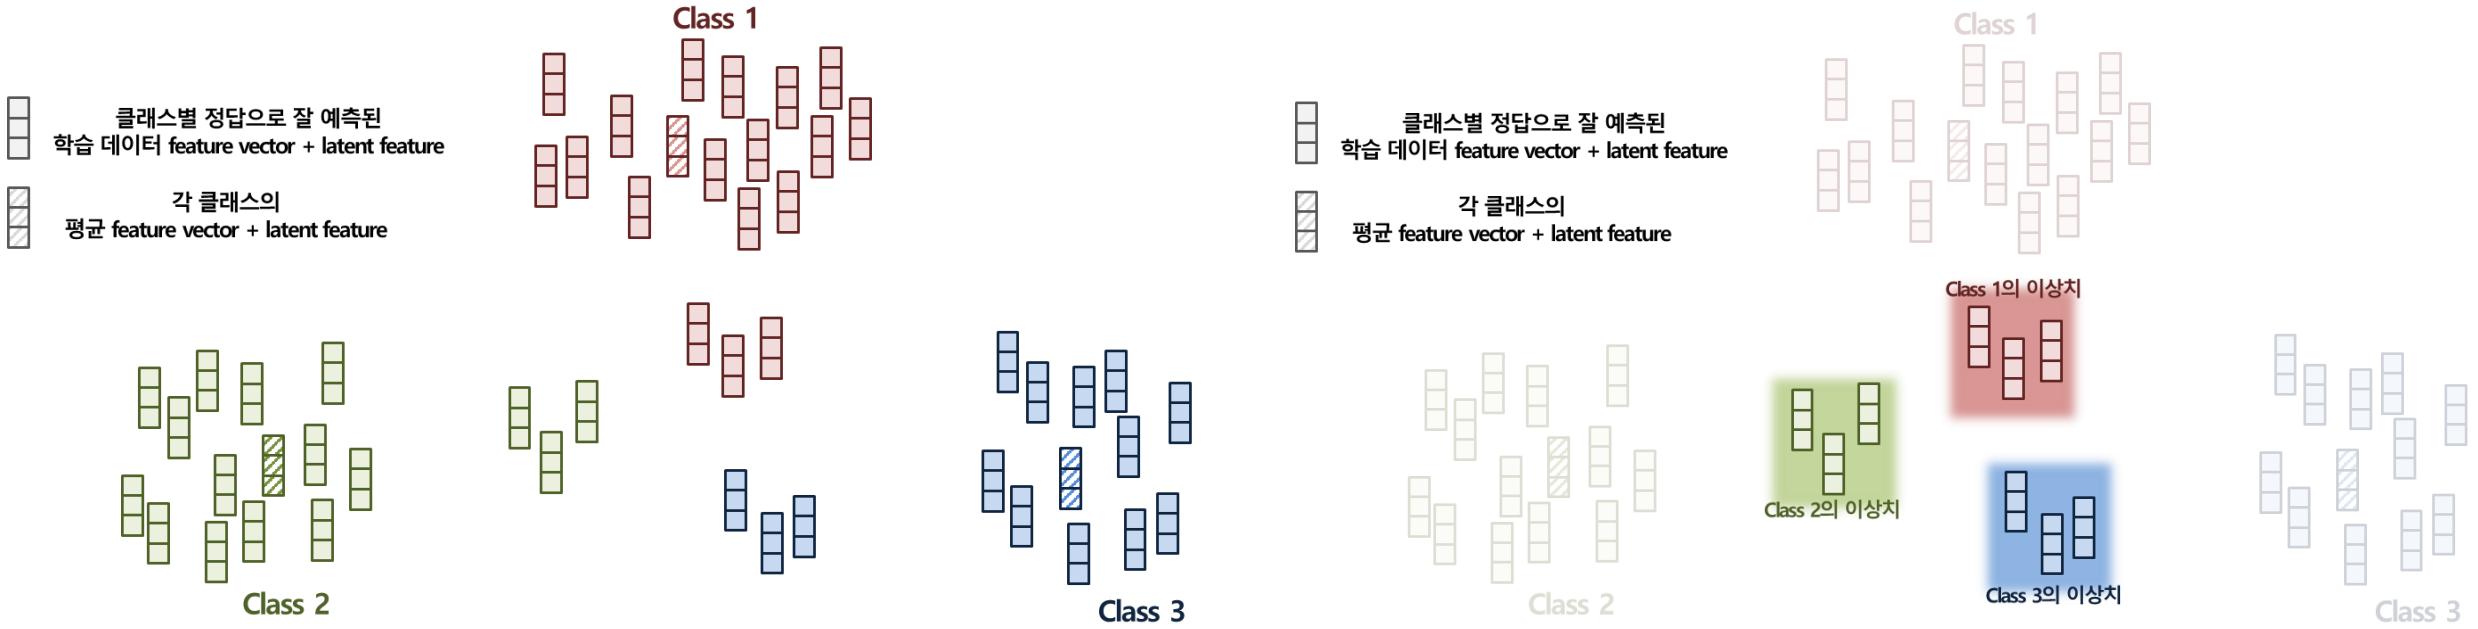
# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ Unknown 탐지 방법

3. 각 클래스별로 평균 feature vector+latent feature 와 정답 클래스로 잘 예측된 학습 데이터 샘플들의 feature vector+latent feature 사이의 거리 구하기

4. 각 클래스별로 평균 feature vector+latent feature와 가장 멀리 있는 feature vector+latent feature 들을 해당 클래스의 이상치로 정의



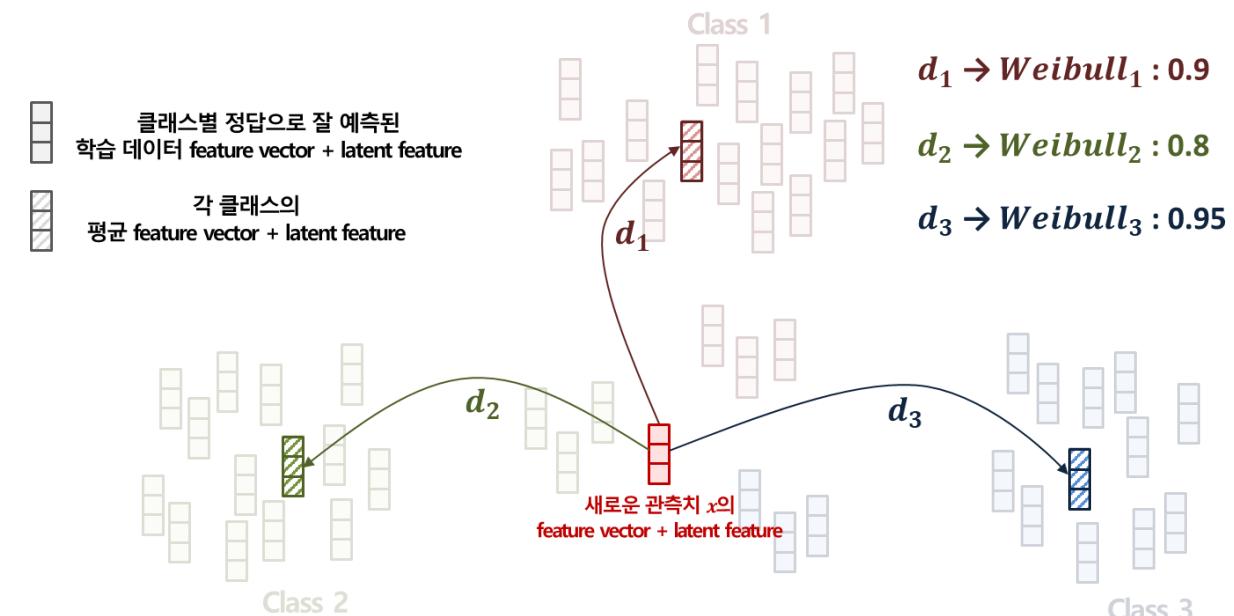
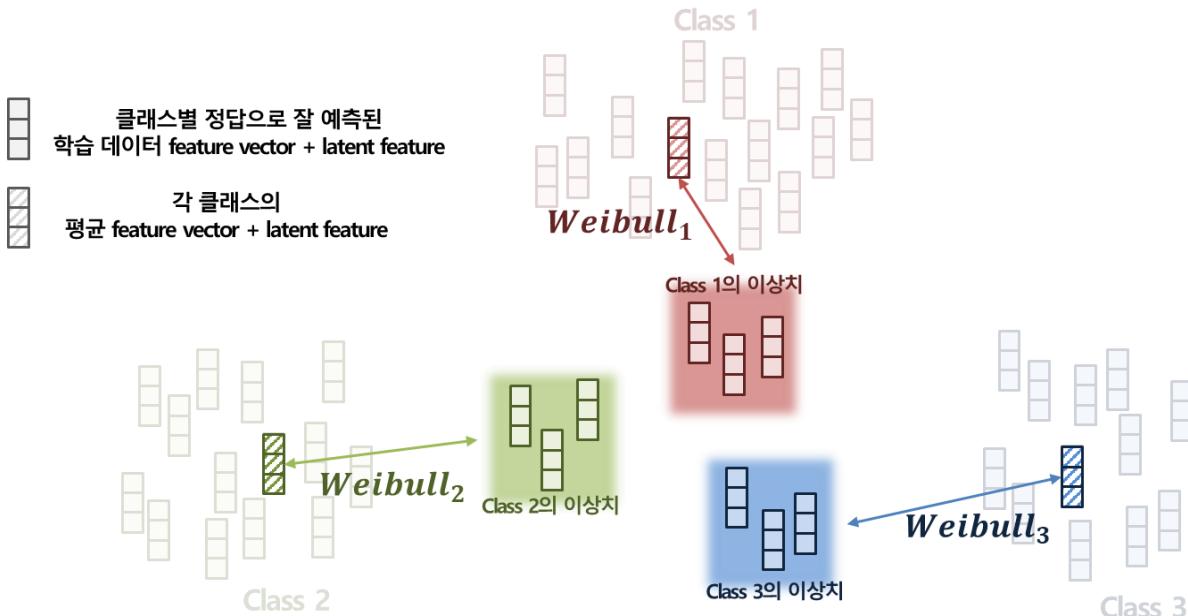
# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ Unknown 탐지 방법

5. 각 클래스별로 이상치로 정의된 feature vector+latent feature들과 평균 feature vector+latent feature 사이의 거리로 극단 분포(Weibull 분포) 추정

6. 새로운 관측치가 들어오면 각 클래스의 평균 정의된 feature vector+latent feature 와의 거리를 계산하여 각 클래스의 극단 분포(Weibull 분포)에 대한 확률 계산



# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ Unknown 탐지 방법

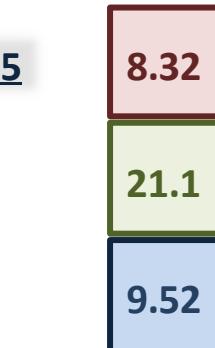
- 계산된 확률값을 통해 feature vector 업데이트하여 unknown에 해당하는 값 생성 후 클래스 분류 및 unknown 탐지 수행

각 클래스에 대한 outlier score  
(= 각 클래스에 속하지 않을 확률)

$$d_1 \rightarrow Weibull_1 : 0.9$$

$$d_2 \rightarrow Weibull_2 : 0.8$$

$$d_3 \rightarrow Weibull_3 : 0.95$$



새로운 관측치  $x$ 의  
feature vector

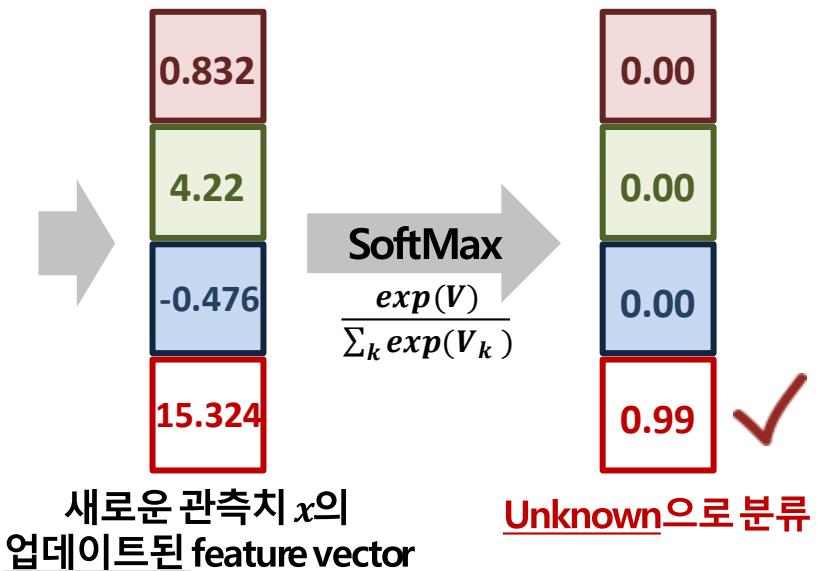


$$\text{Class1} : 8.32(1-0.9)=0.832$$

$$\text{Class2} : 21.1(1-0.8)=4.22$$

$$\text{Class3} : -9.52(1-0.95)=-0.476$$

$$\text{Unknown} : 8.32 \times 0.9 + 21.1 \times 0.8 + (-9.52) \times 0.95 = 15.324$$



새로운 관측치  $x$ 의  
업데이트된 feature vector

Unknown으로 분류

# DNN-Based Open-set Recognition Algorithms

CROSR

## ❖ 실험 결과

- CIFAR-10 데이터셋(클래스 10개, 5만개) 학습 후 ImageNet 등 다른 이미지 데이터셋을 unknown으로 설정
- 실험을 통해 다른 unknown 탐지 알고리즘들(OpenMax 등)과 CROSR의 성능 비교
- Unknown으로 설정된 데이터셋 종류와 상관 없이 **CROSR이 가장 우수한 성능을 보임**

		Unknown으로 설정된 데이터셋				
Backbone network	Training method	UNK detector	ImageNet-crop	ImageNet-resize	LSUN-crop	LSUN-resize
Plain CNN	Counterfactual [28]		0.636	0.635	0.650	0.648
Plain CNN	Supervised only	Softmax	0.639	0.653	0.642	0.647
		Openmax	0.660	0.684	0.657	0.668
		Softmax	0.640	0.646	0.644	0.647
		Openmax	0.653	0.670	0.652	0.659
		CROSR	0.621	0.631	0.629	0.630
	DHRNet (ours)	Softmax	0.645	0.649	0.650	0.649
		Openmax	0.655	0.675	0.656	0.664
		CROSR (ours)	<b>0.721</b>	<b>0.735</b>	<b>0.720</b>	<b>0.749</b>
	DenseNet	Softmax	0.693	0.685	0.697	0.722
		Openmax	0.696	0.688	0.700	0.726
		Softmax	0.691	0.726	0.688	0.700
		Openmax	0.729	0.760	0.712	0.728
		CROSR (ours)	<b>0.733</b>	<b>0.763</b>	<b>0.714</b>	<b>0.731</b>

Unknown으로 설정된 데이터셋에 따른 F1-score 비교

## 2.3 ii-loss

# DNN-Based Open-set Recognition Algorithms

ii-loss

## ❖ Learning a neural-network-based representation for open set recognition

- Hassen, M., & Chan, P. K. (2020). Learning a neural-network-based representation for open set recognition. In Proceedings of the 2020 SIAM International Conference on Data Mining (pp. 154-162). Society for Industrial and Applied Mathematics.
- 2022년 7월 21일 기준 66회 인용
- 효과적인 거리 기반 unknown 탐지를 위해 ii-loss를 제안

## Learning a Neural-network-based Representation for Open Set Recognition

Mehadi Hassen\* Philip K. Chan†

February 7, 2020

### Abstract

In this paper, we present a neural network based representation for the Open Set Recognition problem. In this representation instances from the same class are close to each other while instances from different classes are further apart. When used for Open Set Recognition tasks, evaluated on three datasets from two different domains, the proposed approach results in a statistically significant improvement compared to other approaches.

**Keywords**— Open Set Recognition, Representation Learning, Malware Defense

world problems? Various real-world applications operate in an open set scenario. For example, Ortiz and Becker [18] point to the problem of face recognition. One such use case is automatic labeling of friends in social media posts, “where the system must determine if the query face exists in the known gallery, and, if so, the most probable identity.” Another domain is in malware classification, where training data usually is incomplete because of novel malware families/classes that emerge regularly. As a result, malware classification systems operate in an open set scenario.

# DNN-Based Open-set Recognition Algorithms

## ii-loss

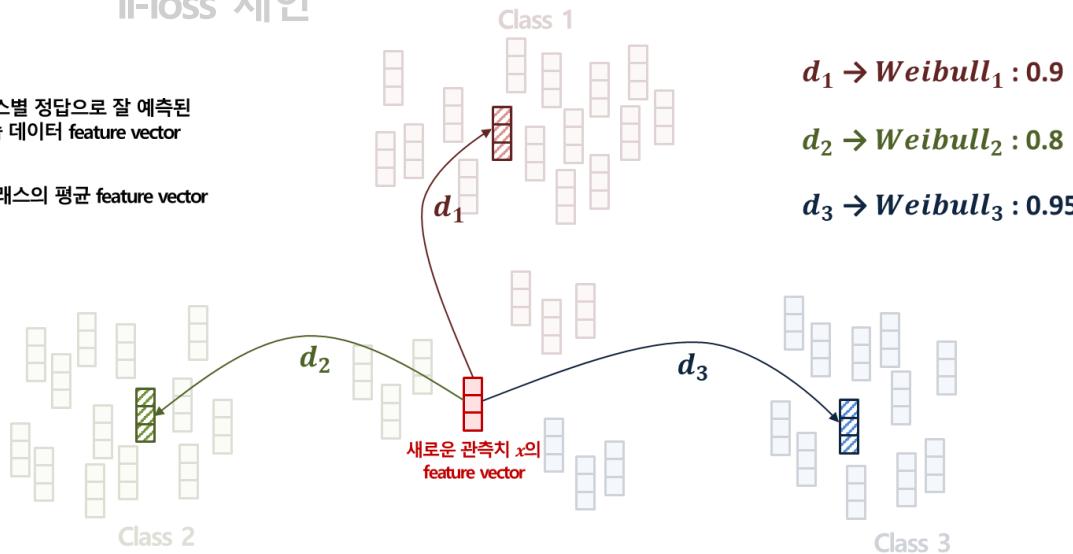
### ❖ 모델 학습 방법

- OpenMax는 unknown 탐지를 위해 거리 기반 outlier score(feature vector 간 거리로 추정된 극단 분포 확률 값)를 사용하지만 cross-entropy loss로 학습된 feature vector는 거리 기반 unknown 탐지에 적합하지 않음
- 효과적인 거리 기반 unknown 탐지를 위해서는 거리 기반으로 학습된 feature vector 필요
- 같은 클래스에 속하는 샘플들은 가까워지도록, 다른 클래스에 속하는 샘플들은 멀어지도록 학습된 feature vector를 위해

### ii-loss 제안

■ 클래스별 정답으로 잘 예측된 학습 데이터 feature vector

■ 각 클래스의 평균 feature vector



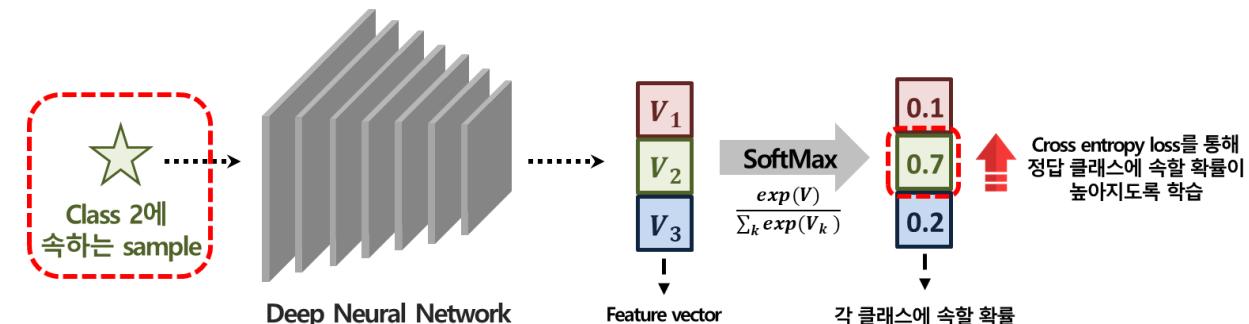
$d_1 \rightarrow Weibull_1 : 0.9$

$d_2 \rightarrow Weibull_2 : 0.8$

$d_3 \rightarrow Weibull_3 : 0.95$

새로운 관측치  $x$ 의  
feature vector

OpenMax의 outlier score 계산 과정



Cross-entropy loss 학습 과정

# DNN-Based Open-set Recognition Algorithms

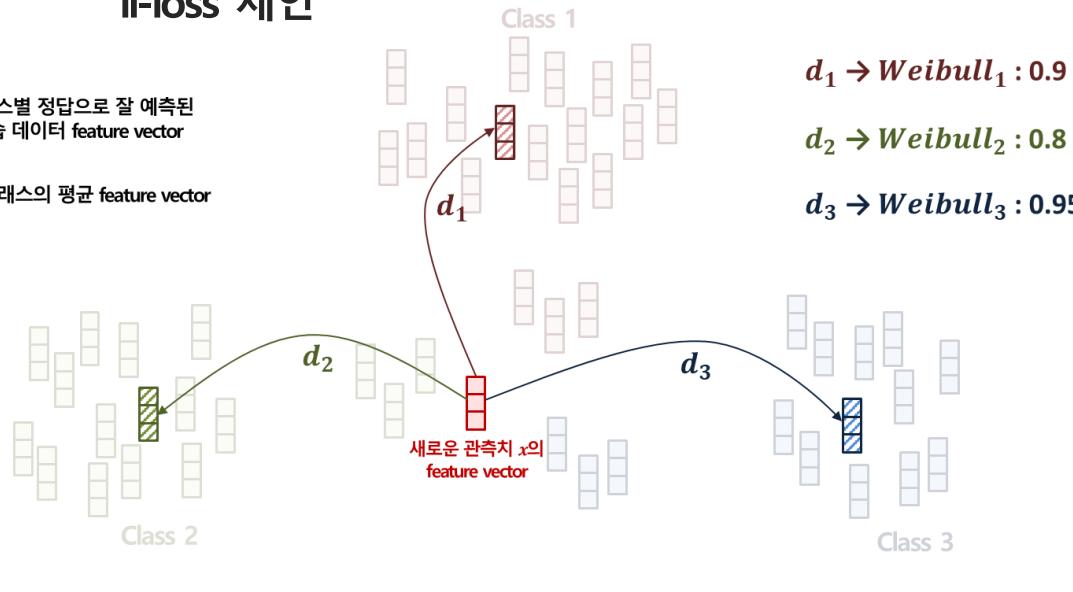
## ii-loss

### ❖ 모델 학습 방법

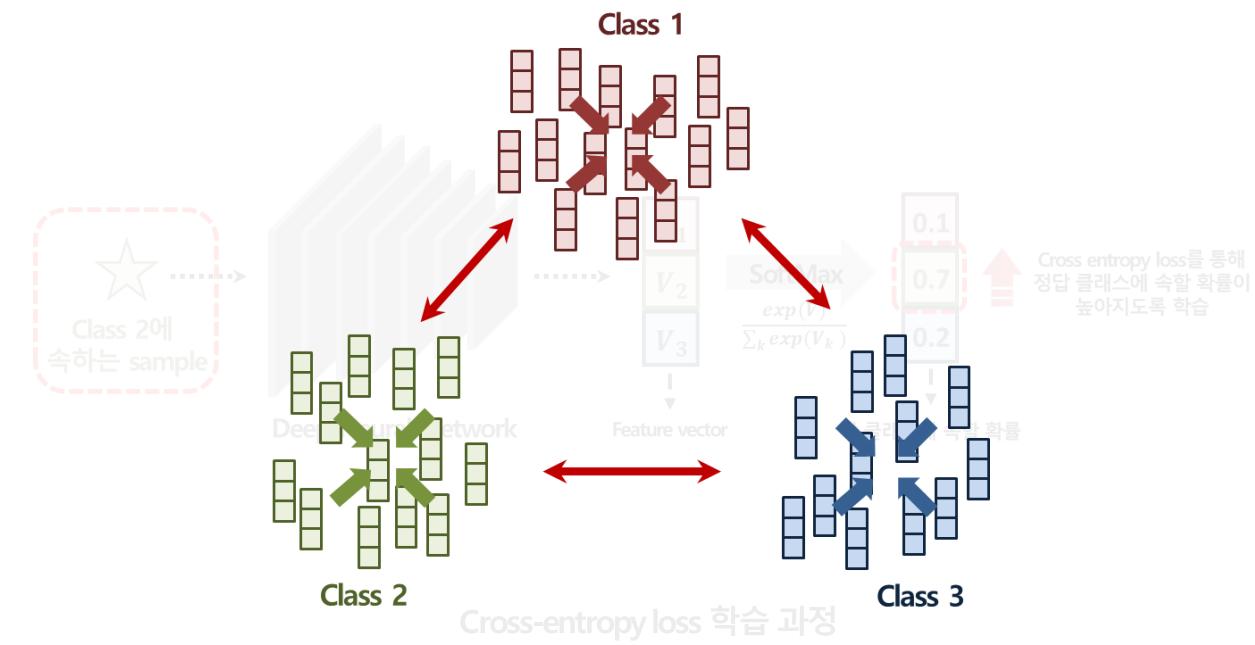
- OpenMax는 unknown 탐지를 위해 거리 기반 outlier score(feature vector 간 거리로 추정된 극단 분포 확률 값)를 사용하지만 cross-entropy loss로 학습된 feature vector는 거리 기반 unknown 탐지에 적합하지 않음
- 효과적인 거리 기반 unknown 탐지를 위해서는 거리 기반으로 학습된 feature vector 필요
- 같은 클래스에 속하는 샘플들은 가까워지도록, 다른 클래스에 속하는 샘플들은 멀어지도록 학습된 feature vector를 위해

### ii-loss 제안

- 클래스별 정답으로 잘 예측된 학습 데이터 feature vector
- 각 클래스의 평균 feature vector



OpenMax의 outlier score 계산 과정



# DNN-Based Open-set Recognition Algorithms

## ii-loss

### ❖ 모델 학습 방법

- 같은 클래스에 속하는 샘플들은 **가까워지도록**, 다른 클래스에 속하는 샘플들은 **멀어지도록** 학습된 feature vector를 위해

#### ii-loss 제안

학습 데이터의  
클래스(known 클래스) 개수

$C_j$ (클래스 j)에 속하는  
학습 데이터 샘플 개수

$$ii\text{-}loss = \left( \frac{1}{N} \sum_{j=1}^K \sum_{i=1}^{|C_j|} \|\vec{\mu}_j - \vec{z}_i\|_2^2 \right) - \left( \min_{\substack{1 \leq m \leq K \\ m+1 \leq n \leq K}} \|\vec{\mu}_m - \vec{\mu}_n\|_2^2 \right)$$

# DNN-Based Open-set Recognition Algorithms

## ii-loss

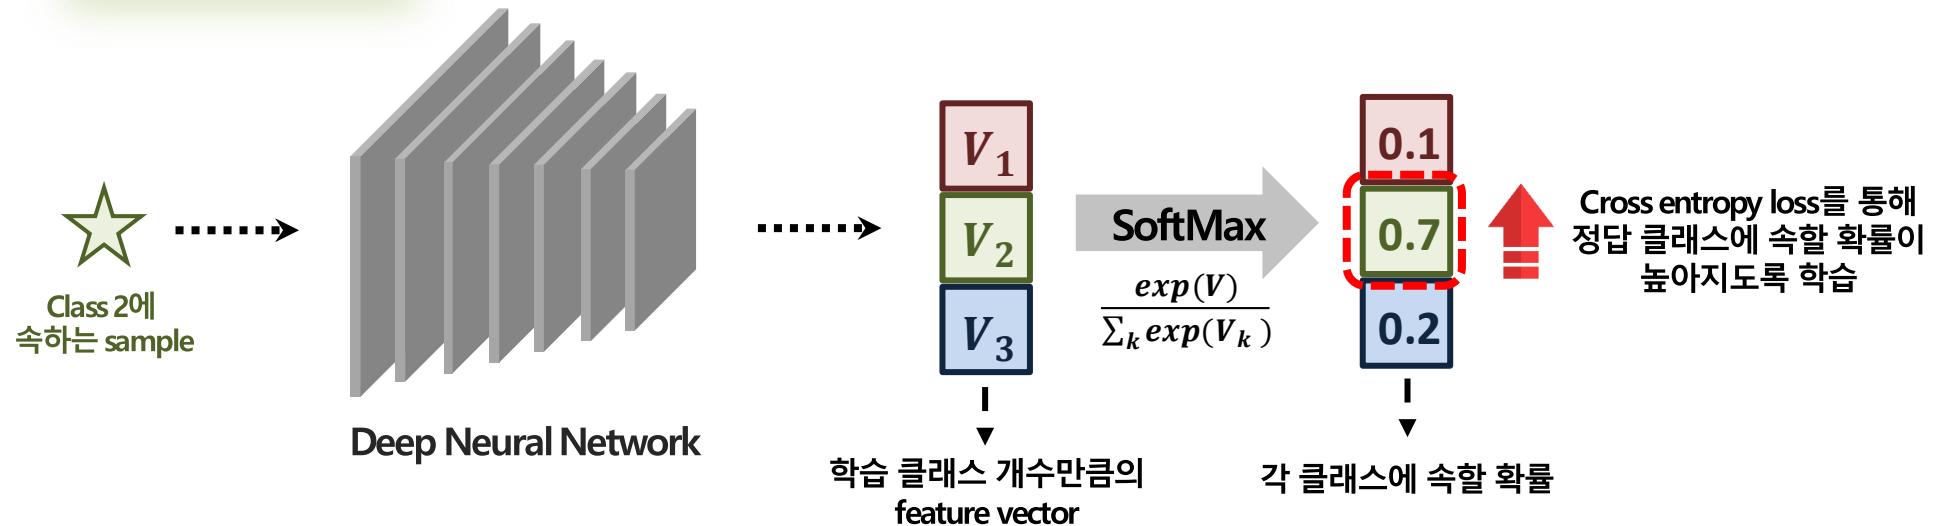
### ❖ 모델 학습 방법

- 같은 클래스에 속하는 샘플들은 가까워지도록, 다른 클래스에 속하는 샘플들은 멀어지도록 학습된 feature vector를 위해

#### ii-loss 제안

학습 데이터의  
클래스(known 클래스) 개수  
학습 데이터 샘플 개수

$$ii\text{-}loss = \left( \frac{1}{N} \sum_{j=1}^K \sum_{i=1}^{|C_j|} \|\vec{\mu}_j - \vec{z}_i\|_2^2 \right) - \left( \min_{\substack{1 \leq m \leq K \\ m+1 \leq n \leq K}} \|\vec{\mu}_m - \vec{\mu}_n\|_2^2 \right)$$



# DNN-Based Open-set Recognition Algorithms

## ii-loss

### ❖ 모델 학습 방법

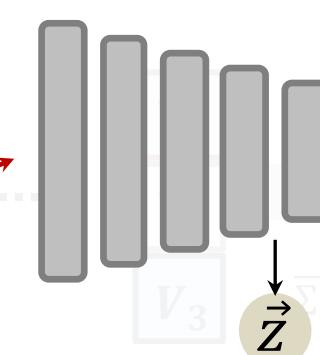
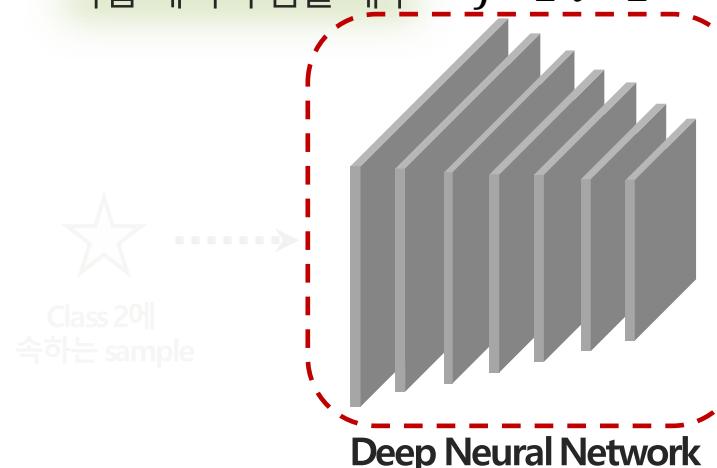
- 같은 클래스에 속하는 샘플들은 가까워지도록, 다른 클래스에 속하는 샘플들은 멀어지도록 학습된 feature vector를 위해

#### ii-loss 제안

학습 데이터의  
클래스(known 클래스) 개수

$C_j$ (클래스 j)에 속하는  
학습 데이터 샘플 개수

$$ii\text{-}loss = \left( \frac{1}{N} \sum_{j=1}^K \sum_{i=1}^{|C_j|} \|\vec{\mu}_j - \vec{z}_i\|_2^2 \right) - \left( \min_{\substack{1 \leq m \leq K \\ m+1 \leq n \leq K}} \|\vec{\mu}_m - \vec{\mu}_n\|_2^2 \right)$$



학습 클래스 개수만큼의  
feature vector

$\vec{\mu}_j = \frac{1}{|C_j|} \sum_{i=1}^{|C_j|} \vec{z}_i$  を通して  
各 클래스에 속할 확률  
 $c_j$ (클래스 j)에 속하는  
학습 데이터 샘플들의  $\vec{z}$  평균

# DNN-Based Open-set Recognition Algorithms

## ii-loss

### ❖ 모델 학습 방법

- 같은 클래스에 속하는 샘플들은 **가까워지도록**, 다른 클래스에 속하는 샘플들은 **멀어지도록** 학습된 feature vector를 위해  
**ii-loss** 제안

$$ii\text{-}loss = \left( \frac{1}{N} \sum_{j=1}^K \sum_{i=1}^{|C_j|} \|\vec{\mu}_j - \vec{z}_i\|_2^2 \right) - \left( \min_{\substack{1 \leq m \leq K \\ m+1 \leq n \leq K}} \|\vec{\mu}_m - \vec{\mu}_n\|_2^2 \right)$$

Intra-class spread  
(하나의 클래스 내 샘플들의 퍼짐 정도)

Inter-class separation  
(가장 가까운 두 클래스 간 떨어짐 정도)

# DNN-Based Open-set Recognition Algorithms

## ii-loss

### ❖ 모델 학습 방법

- 같은 클래스에 속하는 샘플들은 **가까워지도록**, 다른 클래스에 속하는 샘플들은 **멀어지도록** 학습된 feature vector를 위해  
**ii-loss 제안**

$$\text{ii-loss} = \left( \frac{1}{N} \sum_{j=1}^K \sum_{i=1}^{|C_j|} \|\vec{\mu}_j - \vec{z}_i\|_2^2 \right) - \left( \min_{\substack{1 \leq m \leq K \\ m+1 \leq n \leq K}} \|\vec{\mu}_m - \vec{\mu}_n\|_2^2 \right)$$

Intra-class spread  
(하나의 클래스 내 샘플들의 퍼짐 정도)

Inter-class separation  
(가장 가까운 두 클래스 간 떨어짐 정도)

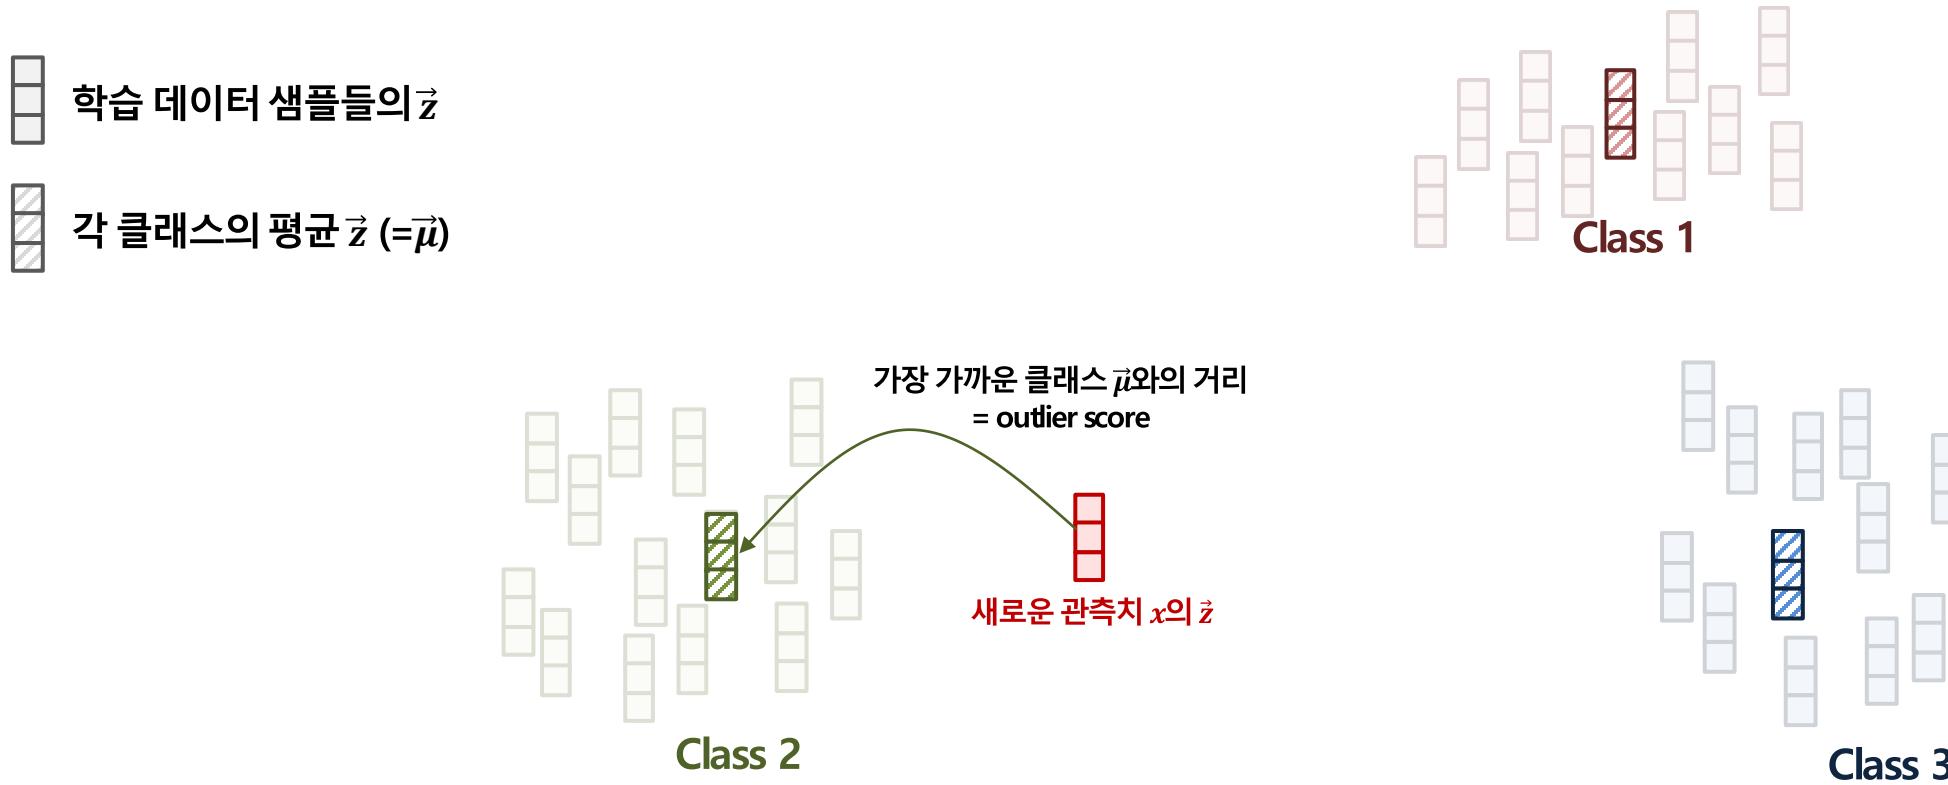


# DNN-Based Open-set Recognition Algorithms

ii-loss

## ❖ Unknown 탐지 방법

- 극단 분포(Weibull 분포)를 활용하는 OpenMax와 CROSR과는 다르게 **거리 기반으로 계산된 outlier score**를 통해 unknown 탐지
- 새로운 관측치의 outlier score = 가장 가까운 known 클래스의 평균 벡터( $\vec{\mu}$ )와의 거리

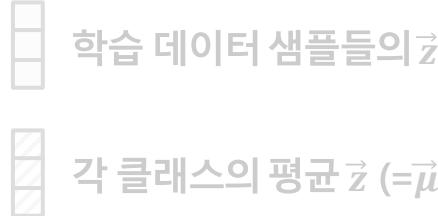


# DNN-Based Open-set Recognition Algorithms

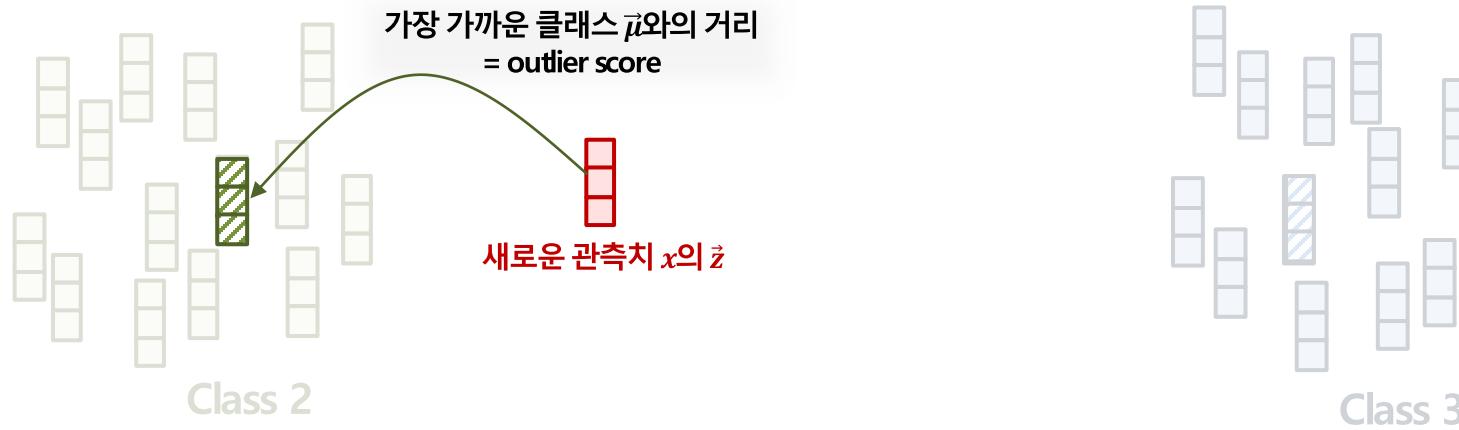
ii-loss

## ❖ Unknown 탐지 방법

- 극단 분포(Weibull 분포)를 활용하는 OpenMax와 CROSR과는 다르게 **거리 기반으로 계산된 outlier score**를 통해 unknown 탐지
- 새로운 관측치의 outlier score = 가장 가까운 known 클래스의 평균 벡터( $\vec{\mu}$ )와의 거리



**Outlier score가 얼마나 커야 unknown일까?**  
(= Known 클래스랑 얼마나 멀어야 unknown일까?)



# DNN-Based Open-set Recognition Algorithms

ii-loss

## ❖ Unknown 탐지 방법

- Unknown 탐지 기준으로 거리 기반 threshold를 설정
- 해당 threshold는 학습 데이터 샘플들의 outlier score를 산출하여 99 percentile에 해당하는 값으로 설정
- 새로운 관측치의 outlier score와 threshold를 비교하여 unknown 탐지 수행

1. 학습 데이터 전체 샘플의 outlier score 계산

2. 99 percentile에 해당하는 값을 threshold로 설정

3. 새로운 관측치의 outlier score와 threshold 비교

학습 데이터 샘플	Outlier score (가장 가까운 known 클래스 $\mu$ 와의 거리)
1	1.43
2	2.62
3	0.74
4	3.21
...	...
$N$	5.32

Outlier score의 99 percentile? 4.83

1) 새로운 관측치의 outlier score  $> \underline{4.83}$   
Unknown으로 분류

2) 새로운 관측치의 outlier score  $\leq \underline{4.83}$   
가장 가까운 known 클래스로 분류

# DNN-Based Open-set Recognition Algorithms

## ii-loss

### ❖ 실험 결과

- 3가지 데이터셋(MNIST 등)을 활용하여 실험이 수행되었으며 일부 클래스만 학습 → 학습에서 제외한 클래스들은 unknown으로 설정
- 실험을 통해 다른 알고리즘들과 성능 비교
  - 1) OpenMax
  - 2) ce : cross-entropy loss만 사용하여 모델 학습
  - 3) ceii : cross-entropy loss와 ii-loss 모두 사용하여 모델 학습
  - 4) ii : ii-loss만 사용하여 모델 학습
- 모델 학습에 ii-loss가 사용된 경우 우수한 성능을 보임

	Openmax	ce	ceii	ii
MNIST	0.88( $\pm 0.05$ )	0.74( $\pm 0.20$ )	<u>0.92</u> ( $\pm 0.02$ )	<b>0.93</b> ( $\pm 0.02$ )
MS	0.87( $\pm 0.01$ )	0.86( $\pm 0.04$ )	<u>0.89</u> ( $\pm 0.01$ )	<u>0.88</u> ( $\pm 0.01$ )
Android	0.30( $\pm 0.12$ )	0.46( $\pm 0.10$ )	<b>0.71</b> ( $\pm 0.17$ )	0.69( $\pm 0.15$ )

알고리즘과 데이터셋별 AUC 비교

# 3. Conclusions

# Conclusions

## ❖ Open-set Recognition

- 딥러닝 모델이 학습하지 않은 클래스를 학습한 클래스 중 하나로 오분류하는 문제 상황을 해결하기 위한 연구 분야
- 심층 신경망(DNN) 기반 알고리즘이 다양하게 연구됨

## ❖ DNN-Based Open-set Recognition Algorithms

- 심층 신경망에 open-set recognition을 처음 적용한 OpenMax를 시작으로 다양한 방법론 존재
- 심층 신경망 기반 알고리즘 3가지에 대해 모델 학습 방법과 unknown 탐지 방법을 비교
  - OpenMax: 클래스별 극단 분포를 추정하여 feature vector 업데이트
  - CROSR: unknown 탐지에 유용한 feature vector를 학습하기 위해 reconstruction 구조 활용
  - ii-loss : 거리 기반 학습 방법과 unknown 탐지 방법 제안
- 3가지 알고리즘 모두 unknown 탐지 과정에 학습 데이터가 필요하다는 공통점이 있음

# Thank you

# References

1. Geng, C., Huang, S. J., & Chen, S. (2020). Recent advances in open set recognition: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 43(10), 3614-3631.
2. Bendale, A., & Boult, T. E. (2016). Towards open set deep networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1563-1572).
3. Yoshihashi, R., Shao, W., Kawakami, R., You, S., Iida, M., & Naemura, T. (2019). Classification-reconstruction learning for open-set recognition. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4016-4025).
4. Hassen, M., & Chan, P. K. (2020). Learning a neural-network-based representation for open set recognition. In *Proceedings of the 2020 SIAM International Conference on Data Mining* (pp. 154-162). Society for Industrial and Applied Mathematics.
5. <http://dmqm.korea.ac.kr/activity/seminar/281>