

자율주행 자동차를 위한 딥러닝 알고리즘

: 딥러닝 기반 ADAS 센서 고장 진단 알고리즘 개발

SW 중심 대학 사업 대학-대학원 연구과제 - 1차년도

단국대학교 응용컴퓨터공학과
기계학습 및 패턴 분석 연구실

과제 개요 (연구원모집요강)

과제 내용

- 학부생과 대학원생이 공동으로 R&D 프로젝트 수행

과제책임자

- 최상일 교수 (응용컴퓨터공학과)

참여 연구원

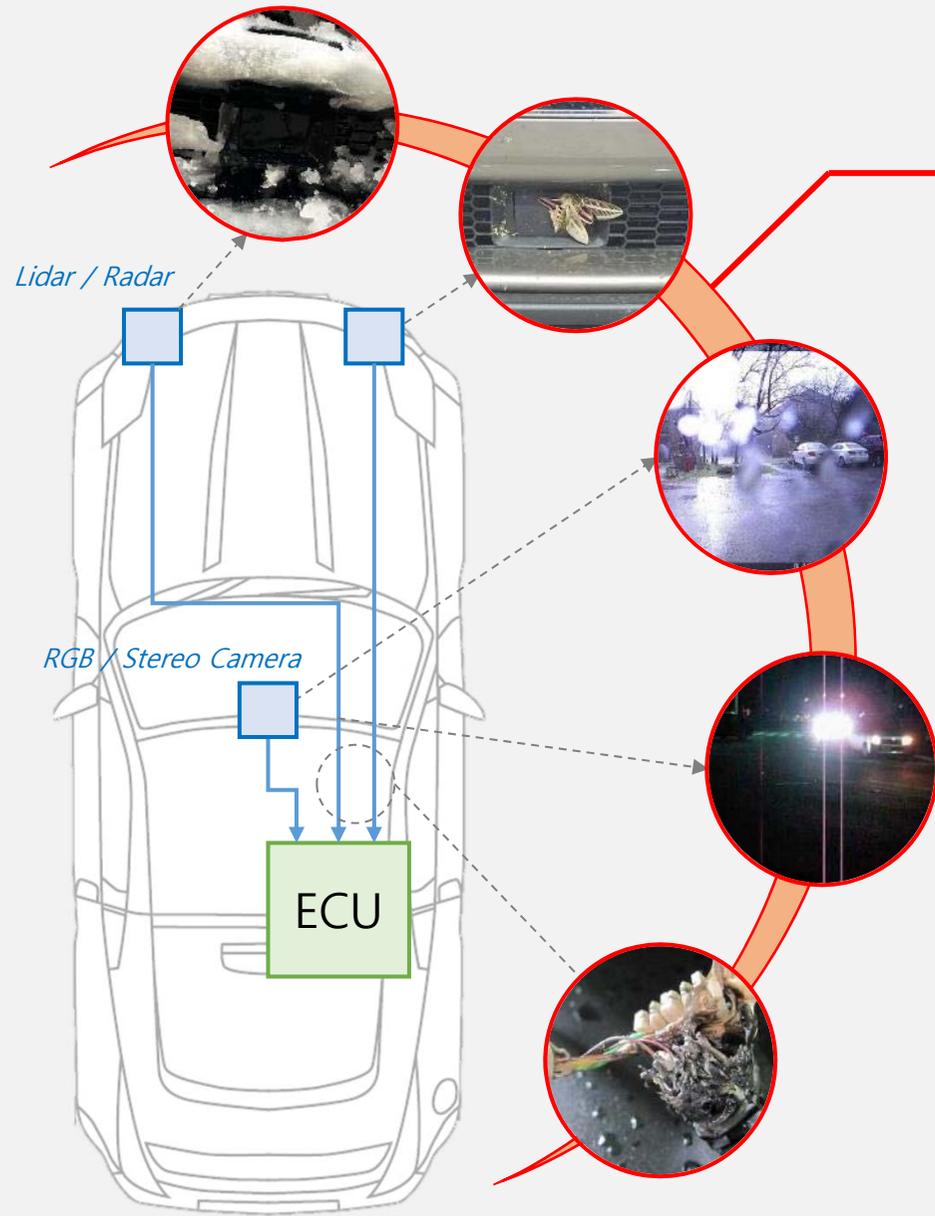
- 기계학습 및 패턴분석 연구실 연구원 1~2인
- 단국대학교 응용컴퓨터공학과 학부생 1인 **(모집)**

학부생 연구원 모집 요강

- 모집기간 : 6월 중
- 연구기간 : 2017년 6월~11월
- 특전
 - ✓ 연구기간 동안 대학원 연구실(525호 또는 503호) PC 및 책상 제공
 - ✓ 연구기간 동안 장학금 지원
 - ✓ 대학원 진학 시 등록금 전액 지원
 - ✓ 최신 연구 기술에 관한 실무 지식, 경험 배양 (세미나 참석, 연구지도)
- 선발 기준
 - ✓ 자격 : 응용컴퓨터공학과, 소프트웨어학과 3~4학년
 - ✓ 딥러닝, 인공지능, 컴퓨터비전 **연구에 관심 있는** 학생
 - ✓ 복수 지원 시, MLPA Lab. 자체 연구원 선발 기준에 따름
 - ✓ 학-석 연계과정 신청자, 대학원 진학 희망자 우선 선발
- 문의 : 2공 506호, 525호

목표 기술 예시

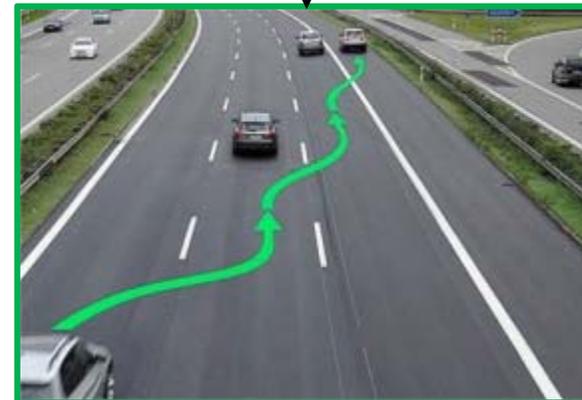
목표 기술 범위



고장 진단

허용 주행 가능 범위 산출

차량 안전 조치



혁신성과 차별성

■ 기술적 혁신성

- 기존에 존재하지 않는 방식의 센서 고장 진단 시스템
 - ✓ 센서 간 공유 정보 활용률 최초로 활용
 - ✓ 다중 모달 심층 오토인코더 최초로 적용
- 비교사 학습 도입
 - ✓ 무한에 가까운 비정상 상황에 대해 대응 가능
 - ✓ 네트워크 추가 학습에 소모되는 작업 최소화

■ 연구적 차별성

- 실용 가능 원천기술
 - ✓ 국내 완성차 업체에서 제안 기술의 타당성 검증에 많은 관심 표명
 - ✓ 제안 단계에서 완성차 업체와의 사전 미팅을 통해 업계의 필요 요건 반영
 - ➔ **기술 이전, 산학 후속연구 가능성 높음**
- 높은 확장성
 - ✓ 다양한 분야로의 확장이 가능한 핵심 원천 기술에 관한 선행 연구
 - ➔ 생체 인식(biometric)의 고신뢰 인증, 차량 간 통신 검증, 다중 센서 장착 로봇 등

혁신성과 차별성

■ 기술적 혁신성

- 기존에 존재하지 않는 방식의 센서 고장 진단 시스템
 - ✓ 센서 간 공유 정보 활용률 최초로 활용
 - ✓ 다중 모달 심층 오토인코더 최초로 적용
- 비교사 학습 도입
 - ✓ 무한에 가까운 비정상 상황에 대해 대응 가능
 - ✓ 네트워크 추가 학습에 소모되는 작업 최소화

■ 연구적 차별성

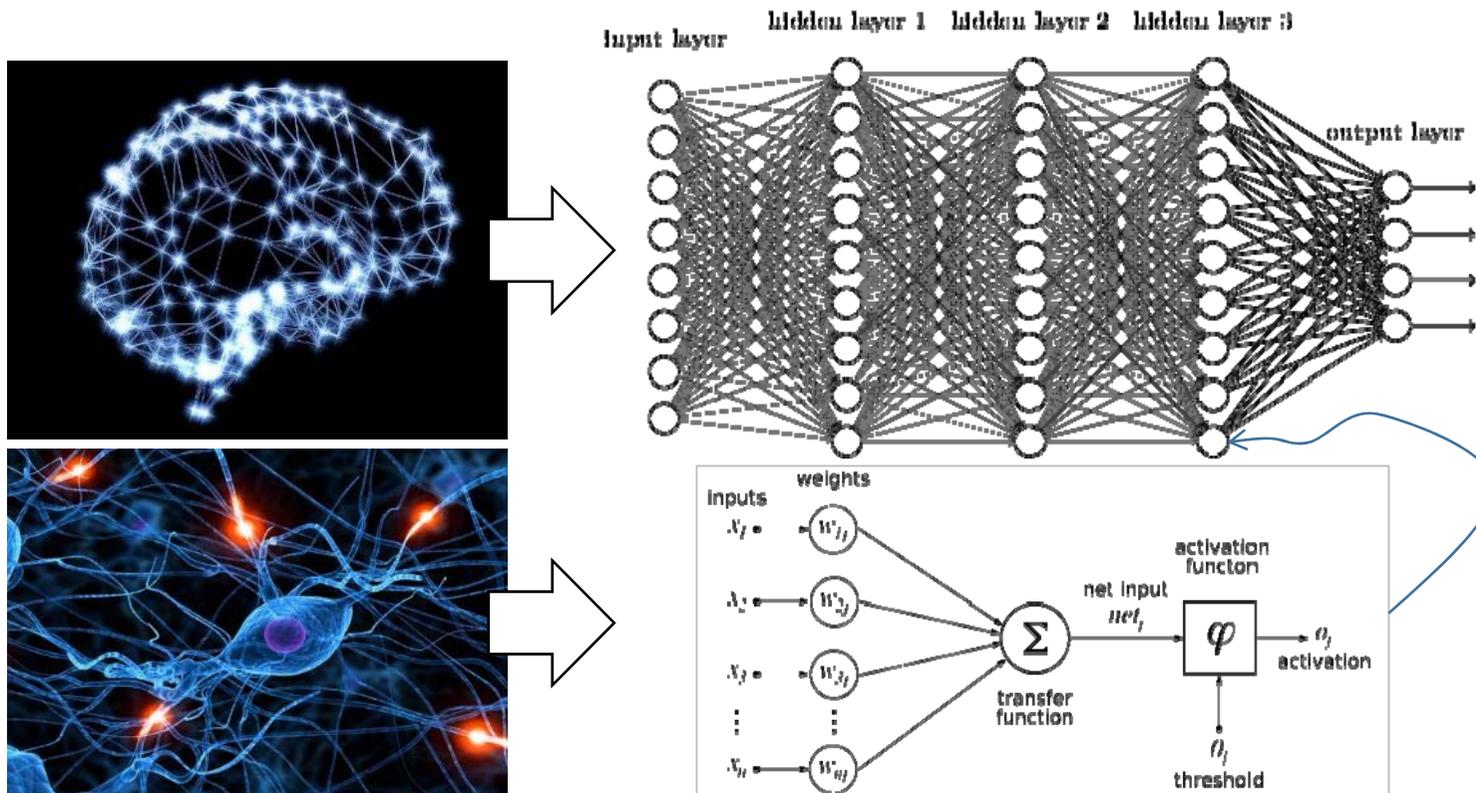
- 실용 가능 원천기술
 - ✓ 국내 완성차 업체에서 제안 기술의 타당성 검증에 많은 관심 표명
 - ✓ 제안 단계에서 완성차 업체와의 사전 미팅을 통해 업계의 필요 요건 반영
 - ➔ **기술 이전, 산학 후속연구 가능성 높음**
- 높은 확장성
 - ✓ 다양한 분야로의 확장이 가능한 핵심 원천 기술에 관한 선행 연구
 - ➔ 생체 인식(biometric)의 고신뢰 인증, 차량 간 통신 검증, 다중 센서 장착 로봇 등

01 기반 기술

Deep Learning

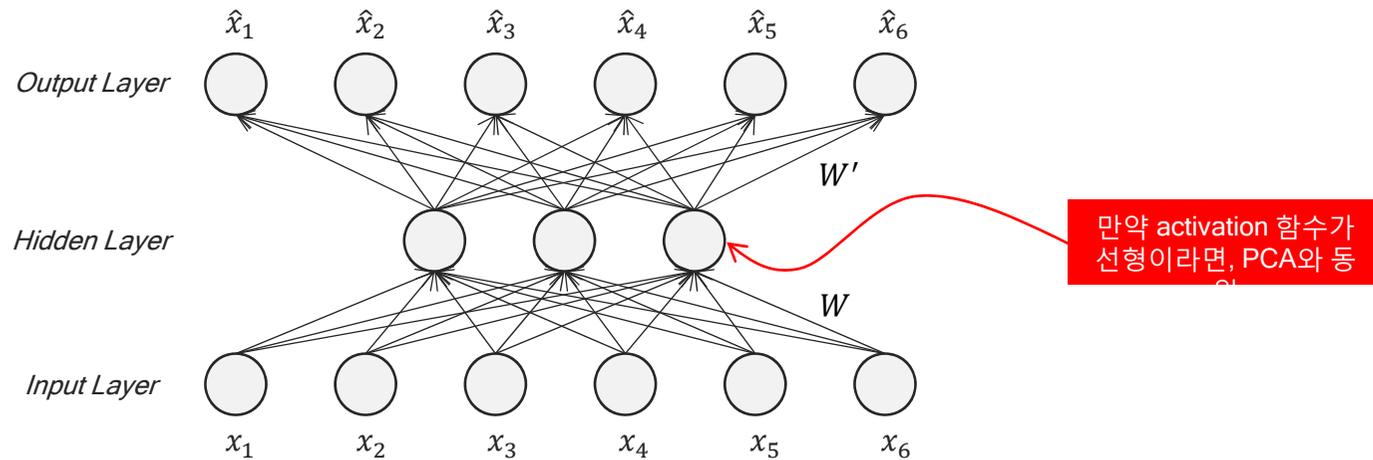
간략하고 알기쉬운 정의

- Machine learning 알고리즘 중
- 심층 인공 신경망(Deep neural network)을 활용한 것들의 집합
 - ✓ 심층: Hidden layer 몇 개부터 심층인지에 대한 명확한 정의는 없으나 통상 2개 이상부터 심층으로 간주



Auto-Encoder

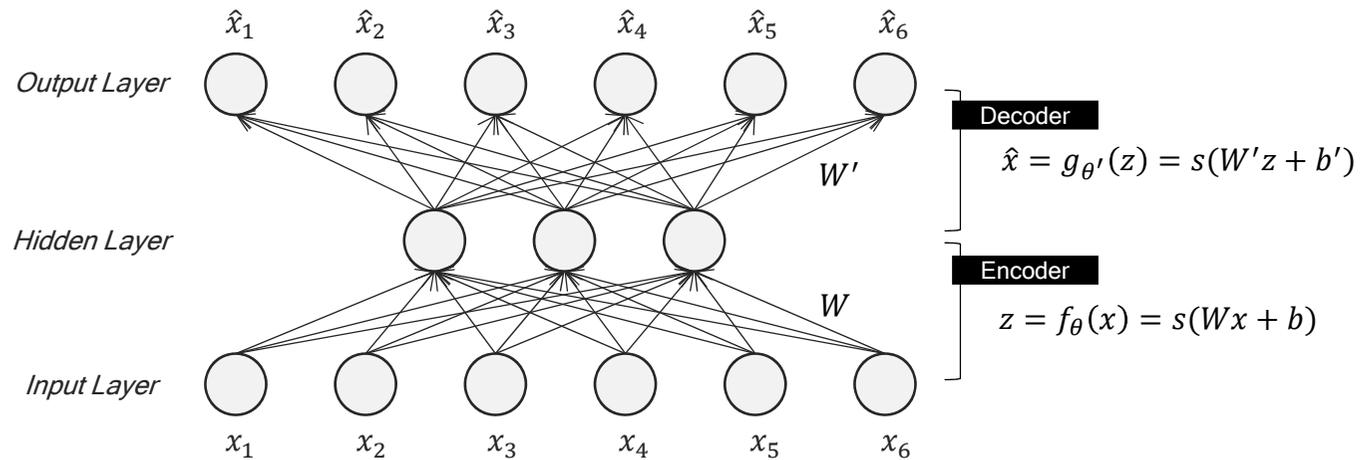
■ 기본 구조



- Input vector x 에 가까운 \hat{x} 을 출력하도록 network 학습
 - ✓ 항등 함수의 approximation
- Non-trivial mapping
 - ✓ 입력이 그대로 hidden layer를 거쳐 출력되는 것(trivial mapping)을 막기 위해
 - ✓ Hidden layer의 neuron 개수를 적게(narrow bottleneck)하거나
 - ✓ 입력에 noise를 섞는다

Auto-Encoder

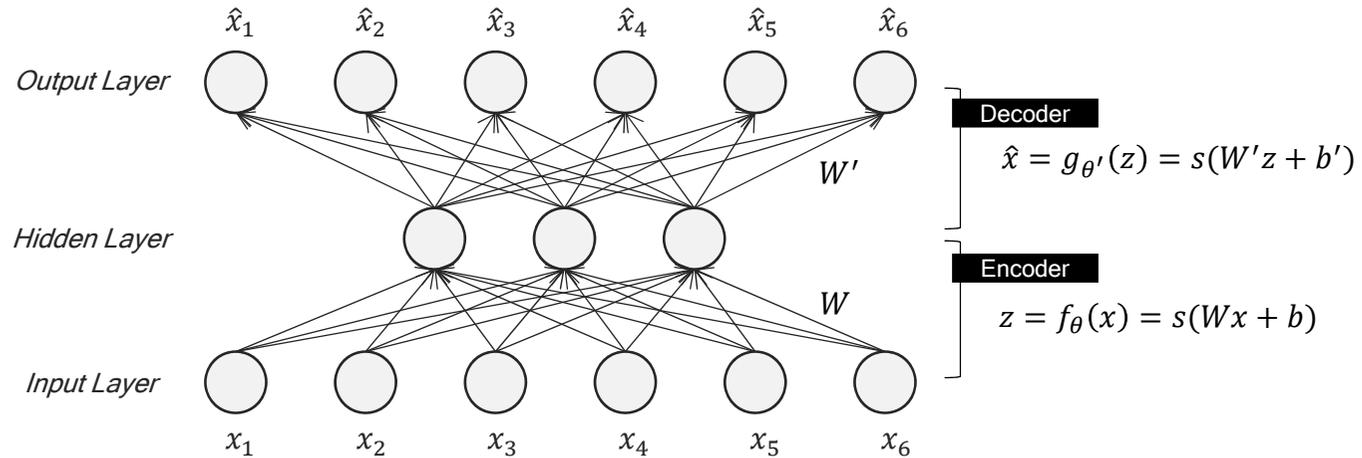
기본 구조



- Encoder
 - ✓ Input vector x 로부터 저차원의 hidden representation $z = f_{\theta}(x)$ 를 추출
- Decoder
 - ✓ Hidden representation으로부터 input vector와 같은 차원의 reconstructed vector $\hat{x} = g_{\theta'}(z)$ 을 도출

Auto-Encoder

▪ 학습 방법 (비교사 학습)



- N개의 Input vector $\{x^{(i)}\}$ 와 reconstructed vector $\{\hat{x}^{(i)}\}$ 의 오차를 이용
- 학습 Objective :

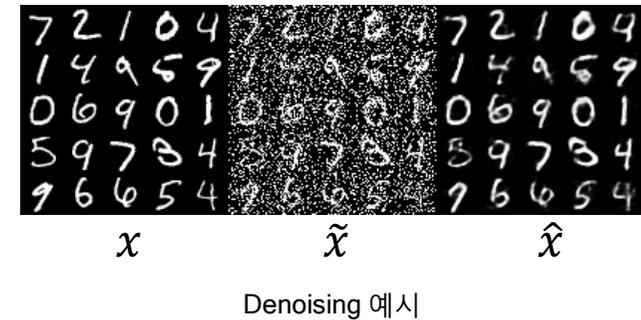
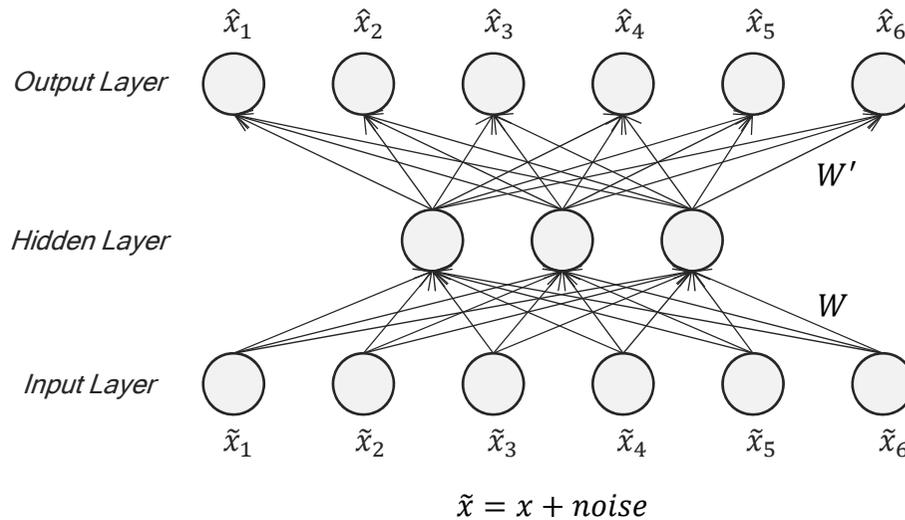
$$[W; b; W'; b'] = [\theta, \theta'] = \arg \min_{\theta, \theta'} \frac{1}{N} \sum_{i=1}^N L(x^{(i)}, \hat{x}^{(i)})$$

L2-norm 혹은 cross entropy 등을 사용

- Back propagation + stochastic gradient descent (SGD) 사용

Auto-Encoder

▪ Denoising Auto-Encoder*

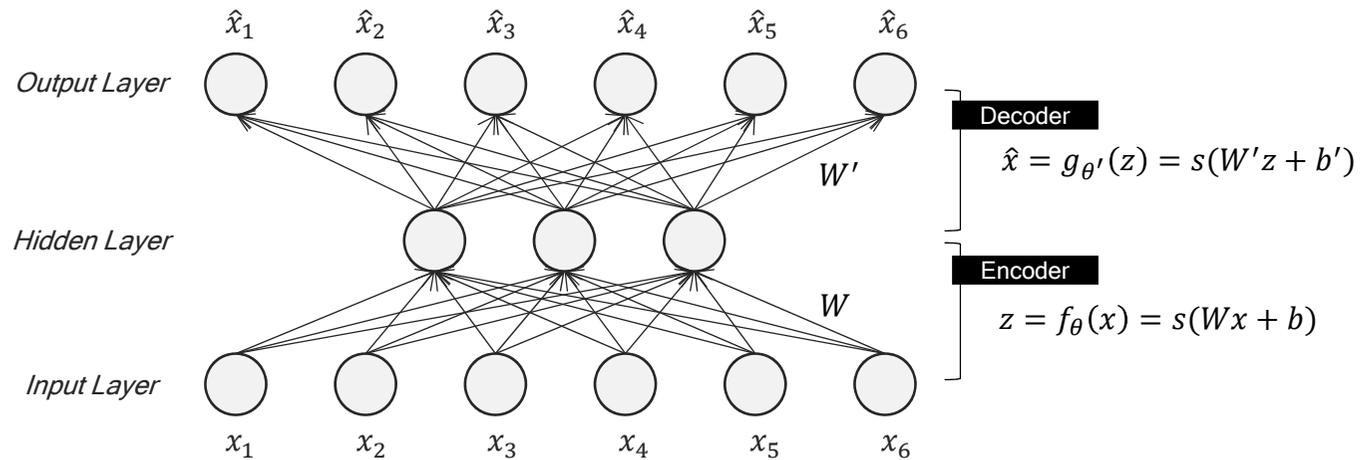


- 데이터에 존재하는 noise를 제거하기 위한 목적
 - ✓ Training 시 입력 데이터에 임의의 noise 추가 (노이즈 제거)
 - ✓ Training 시 입력 데이터의 일부를 0으로 set (occlusion과 같은 정보 누락 대응)
- Hidden representation을 통해 noise에 robust한 feature가 추출될 것을 기대

* [2008, ICML] Extracting and composing robust features with denoising autoencoders

Auto-Encoder

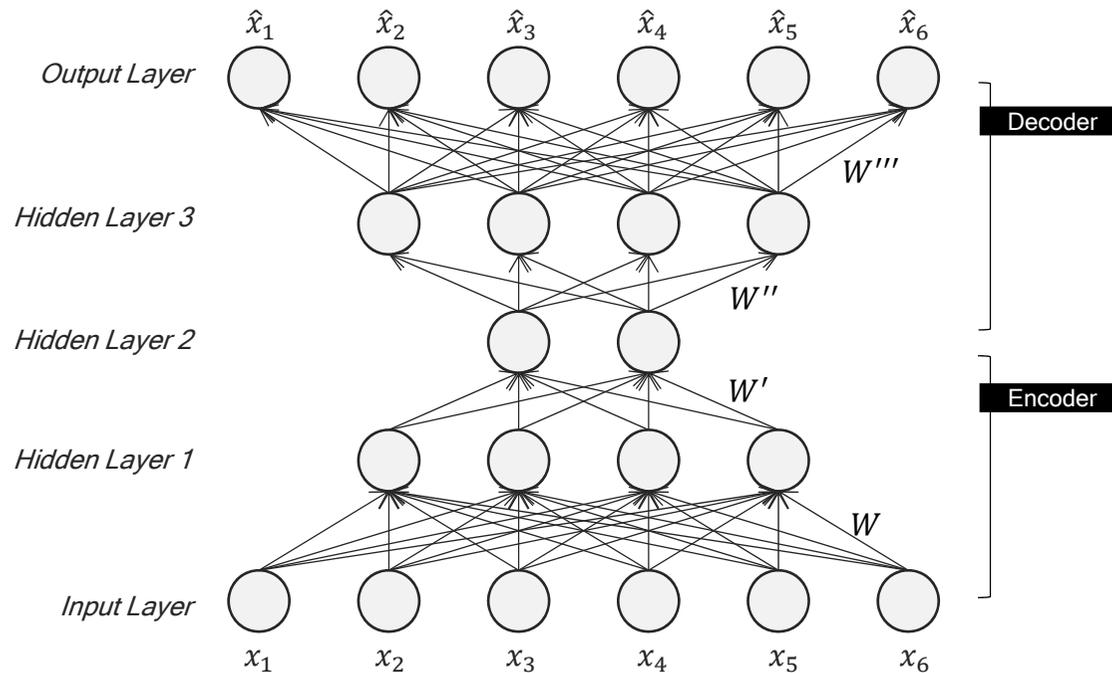
한계점



- Fully connected layer
 - ✓ 학습 시간이 매우 길다
- Hidden layer가 한 층
 - ✓ 이미지와 같이 복잡한 pattern을 담고 있는 데이터에 대해 성능이 제약적

Deep Auto-Encoder

Deep Auto-Encoder (Stacked Auto-Encoder)



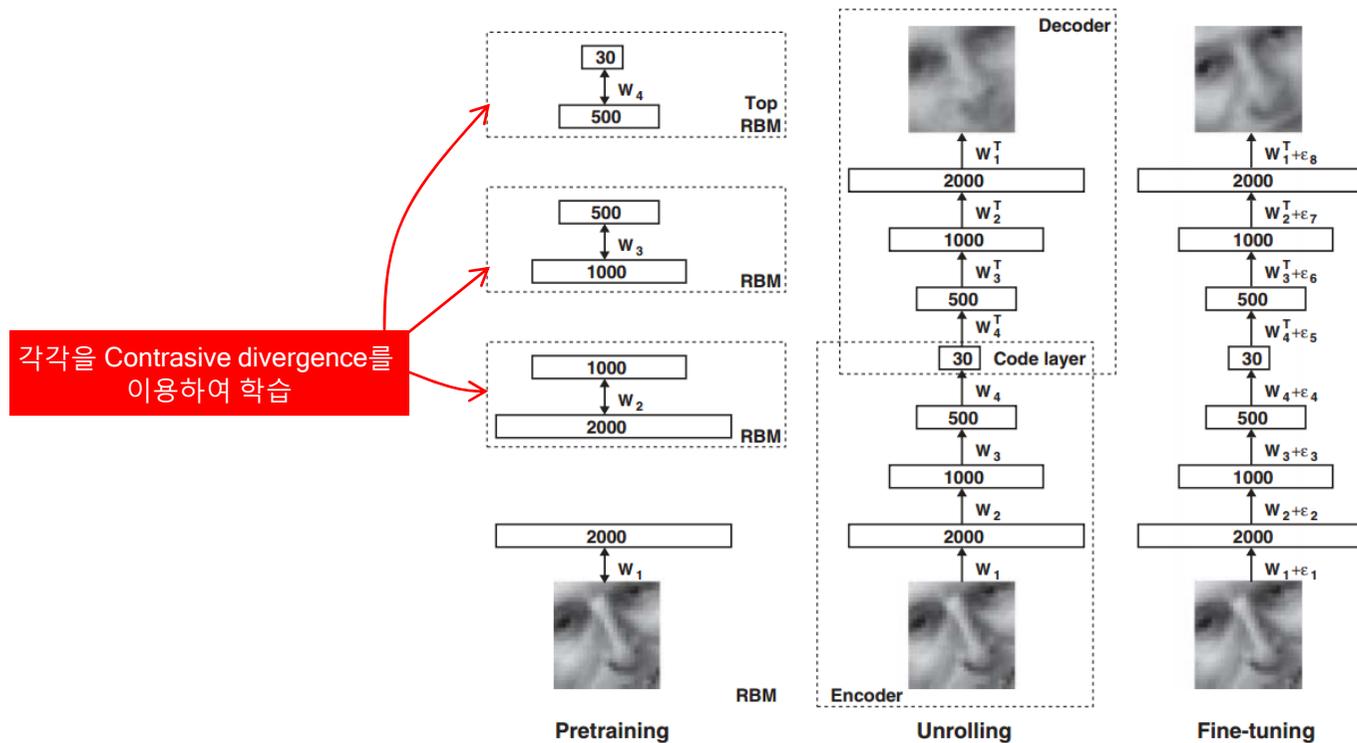
- 여러개의 hidden layer
 - ✓ 보다 powerful한 representation 학습
 - ✓ Greedy Layer-Wise Training으로 학습*

* [2006, NIPS] Greedy Layer-Wise Training of Deep Networks

Deep Auto-Encoder

Deep Auto-Encoder (Stacked Auto-Encoder)

- Greedy layer-wise training*

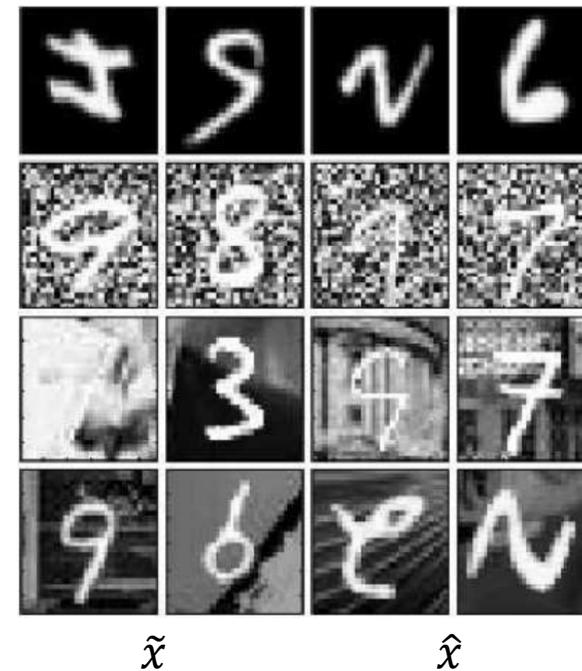
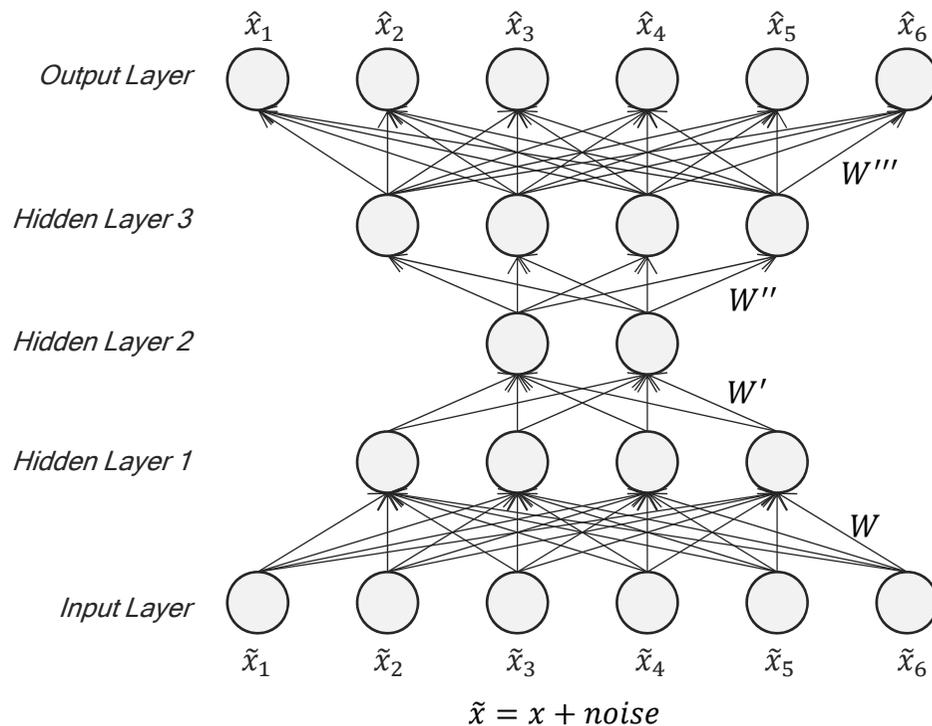


Greedy layer-wise training을 이용한 deep auto-encoder 학습의 개요

Deep Auto-Encoder

Stacked Denoising Auto-Encoder

- Deep Auto-Encoder를 denoising에 사용



“Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion”에서 처리한 noise의 종류

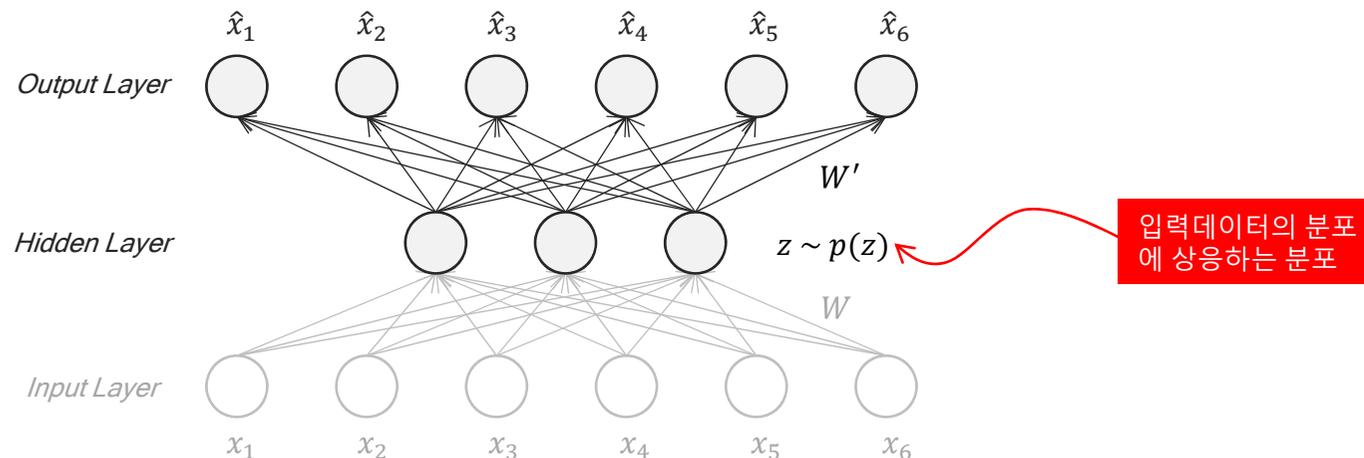
Deep Auto-Encoder

■ 일반적인 Auto-Encoder

- 비슷한 입력에 대해 비슷한 feature 생성을 보장
- 하지만 feature의 각 element가 어떠한 의미를 갖고 있진 않다.

■ Variational Auto-Encoder

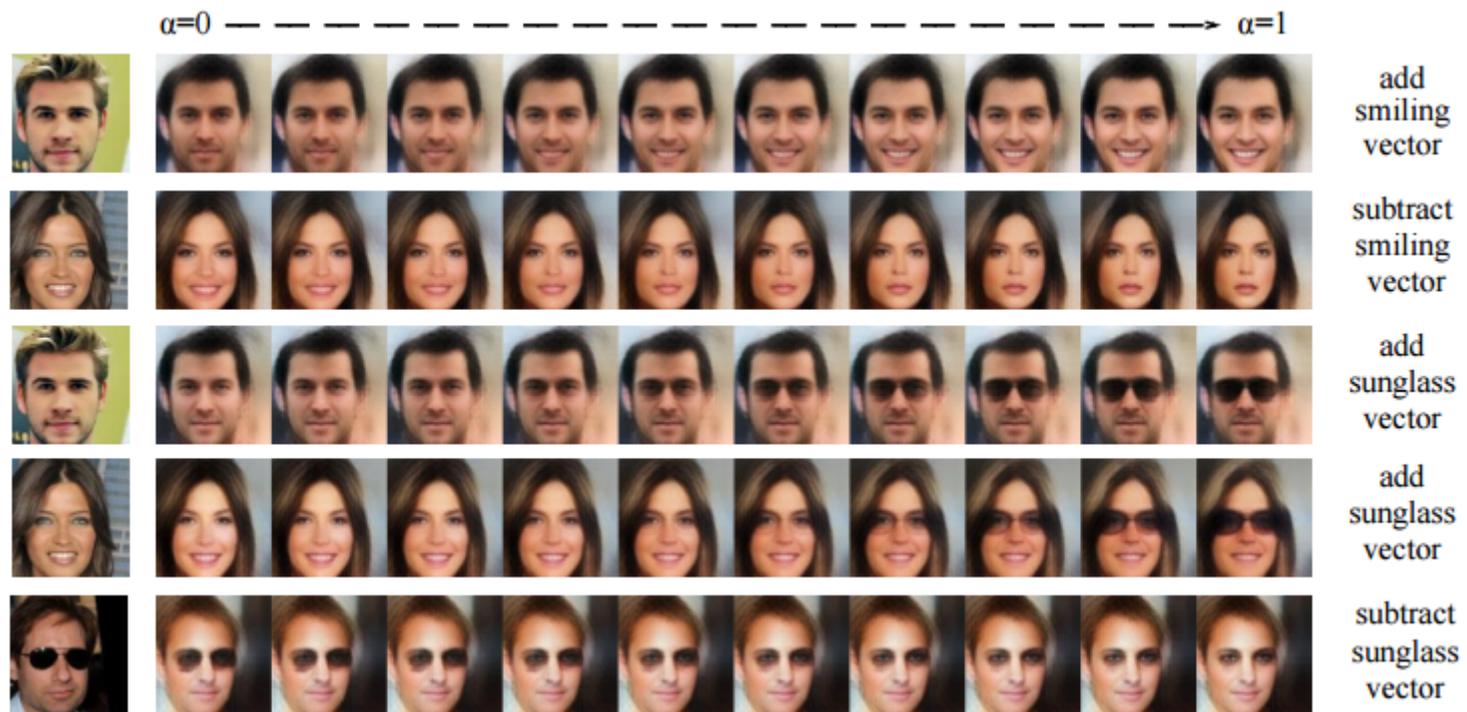
- Hidden representation에 distribution이 존재하도록 학습
- Hidden representation을 조절하여 입력 데이터에 특정한 성질이 강조되거나 삭제된 데이터를 생성
 ✓ Ex) 얼굴 이미지에 안경을 씌우거나, 안경 쓴걸 지우거나 등



Auto-Encoder

Variational Auto-Encoder

- 관련 최신 연구: Deep Feature Consistent Variational Autoencoder



Hidden representation을 조작하여 생성한 이미지들. 가장 좌측을 제외한 모든 이미지들은 알고리즘이 그린 이미지

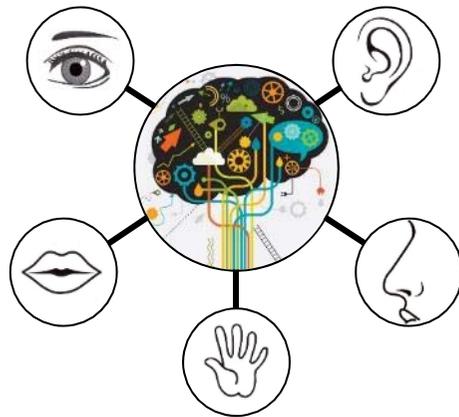
Multi-Modal Deep Auto-Encoder

Modality

- 입력 domain (차량에서는 sensor domain)에서의 양상
- 동종의 sensor라 하더라도 측방이 다르면 다른 domain으로 간주

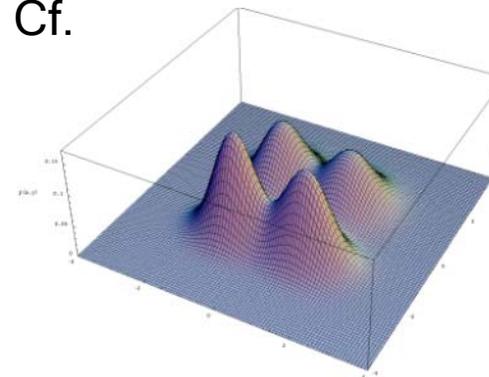
Multi-Modality

- 특정 대상에 대해 다양한 domain으로부터 취득된 입력 데이터
- 각 domain 데이터의 양상 뿐 아니라, domain간의 양상도 modeling



사람의 perception은 기본적으로 multi-modal

Cf.

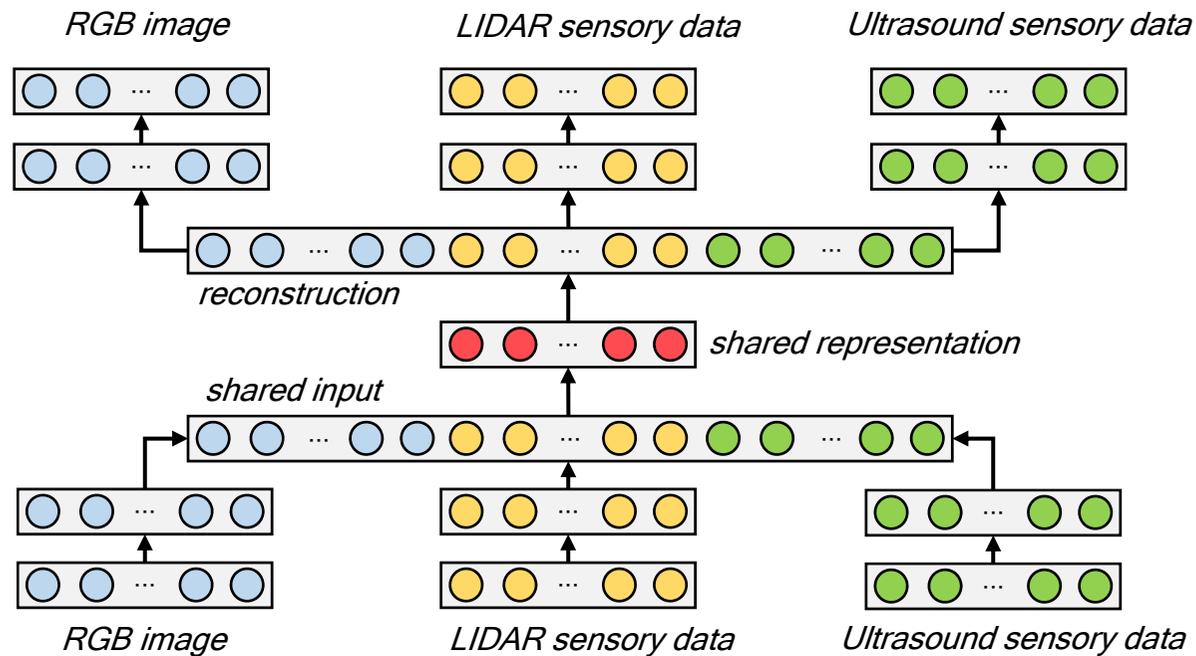


Multimodal distribution. MMDAE에서의 multi-modal은 이거 아닙니다.

Multi-Modal Deep Auto-Encoder

■ 기본 구조

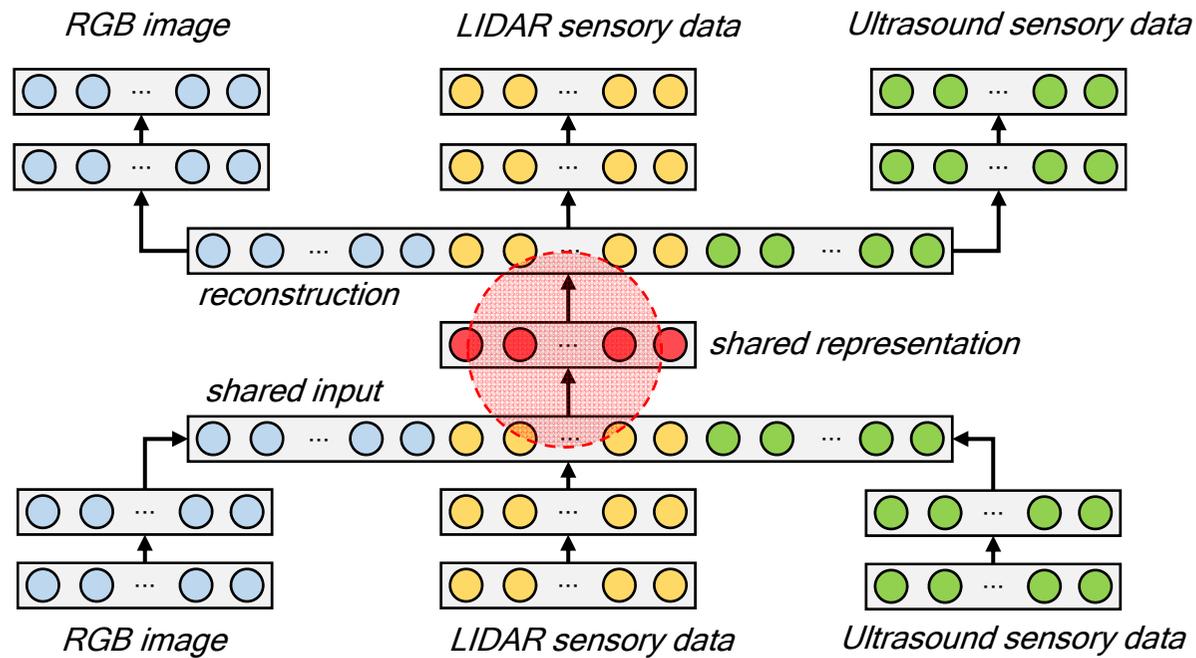
- 입력
 - ✓ 같은 대상에 대해 각기 다른 domain에서 측정된 데이터
- 목적
 - ✓ 서로 다른 modal의 데이터 사이에 존재하는 공통의 정보를 shared representation으로 추출



Multi-Modal Deep Auto-Encoder

Shared representation의 특성

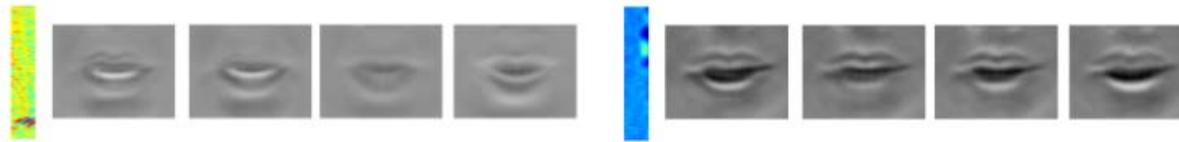
- 단일 Auto-Encoder의 hidden representation에 비해
- 여러 modal의 데이터로 학습하였기 때문에 보다 informative함



Multi-Modal Deep Auto-Encoder

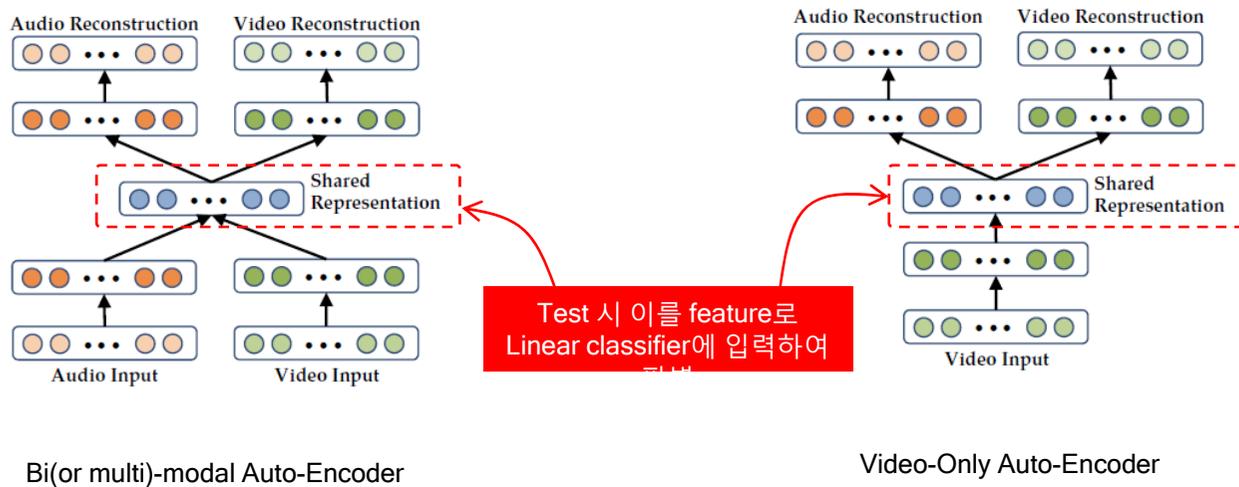
■ 관련연구: Multimodal Deep Learning (ICML, 2011)

- 두 개의 Modal: 음성 데이터 + 입모양 영상



음성데이터(각 왼쪽)와 입모양 영상 데이터(각 오른쪽)

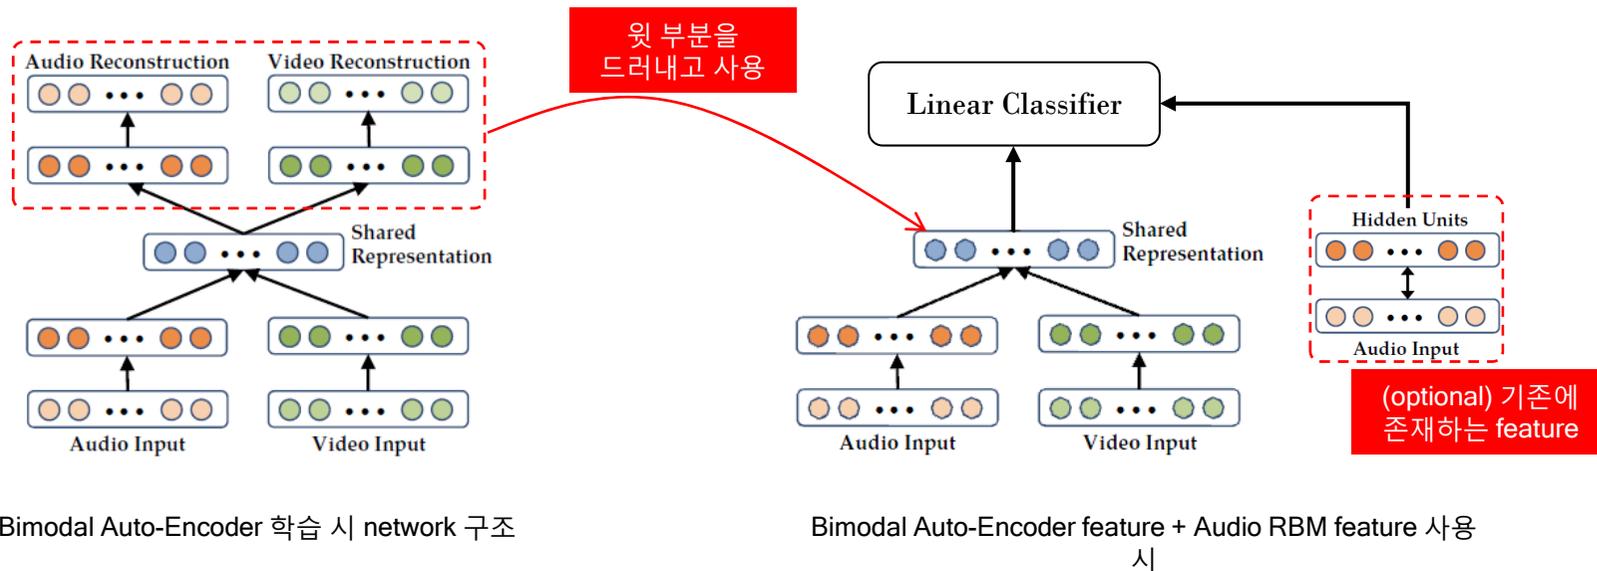
- Multi-Modal Auto-Encoder (MMAE)를 이용하여 음운 인식
 ✓ Ex. "가", "카", "파" 등



Multi-Modal Deep Auto-Encoder

■ 관련연구: Multimodal Deep Learning (ICML, 2011)

- Shared representation을 feature로 간주, linear classification 수행
- 혹은, 기존에 존재하는 feature를 섞어서 사용



Bimodal Auto-Encoder 학습 시 network 구조

Bimodal Auto-Encoder feature + Audio RBM feature 사용 시

Multi-Modal Deep Auto-Encoder

- **관련연구: Multimodal Deep Learning (ICML, 2011)**
 - Audio 신호에 noise를 인가한 경우의 판독률 변화 추이

Feature Representation	Accuracy (Clean Audio)	Accuracy (Noisy Audio)
(a) Audio RBM (Figure 2a)	95.8%	75.8% ± 2.0%
(b) Video-only Deep Autoencoder (Figure 3a)	68.7%	68.7%
(c) Bimodal Deep Autoencoder (Figure 3b)	90.0%	77.3% ± 1.4%
(d) Bimodal + Audio RBM	94.4%	82.2% ± 1.2%
(e) Video-only Deep AE + Audio-RBM	87.0%	76.6% ± 0.8%

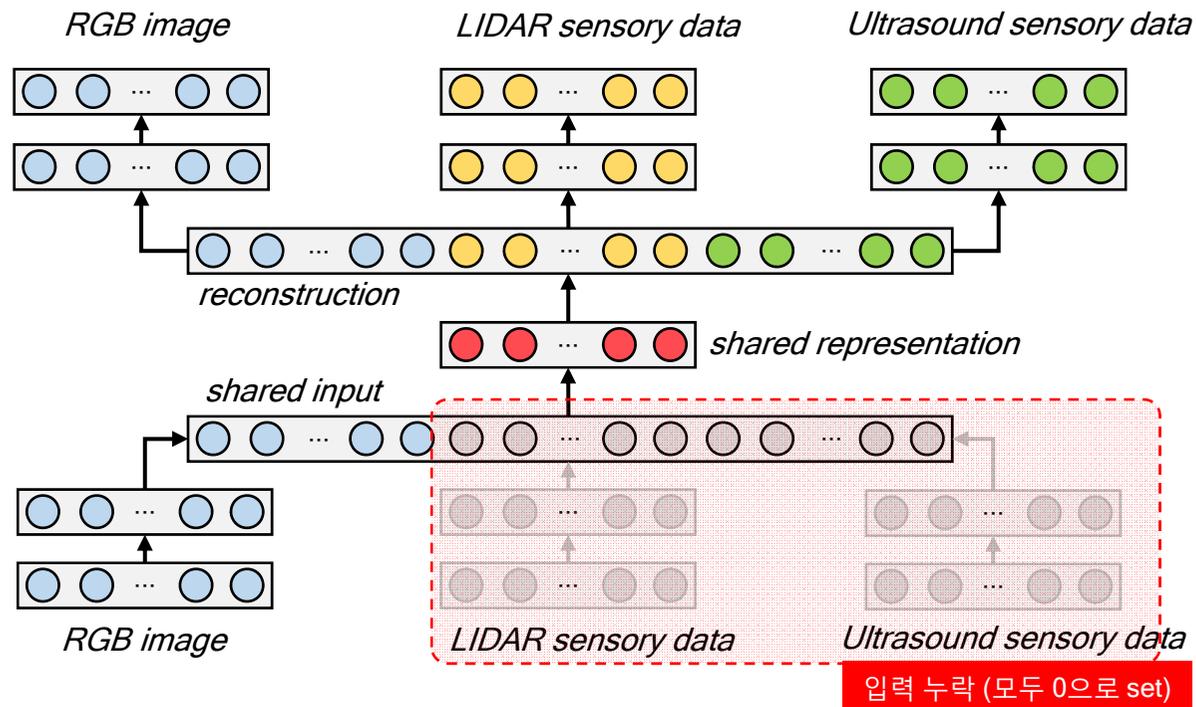
Feature 구성 별 audio 신호 noise 첨가로 인한 성능 변화 비교

- (e)와 비교하였을 시, corrupt된 audio 신호라도 입력으로 받는 것이 성능에 더 긍정적임을 확인

Multi-Modal Deep Auto-Encoder

▪ Denoising의 활용

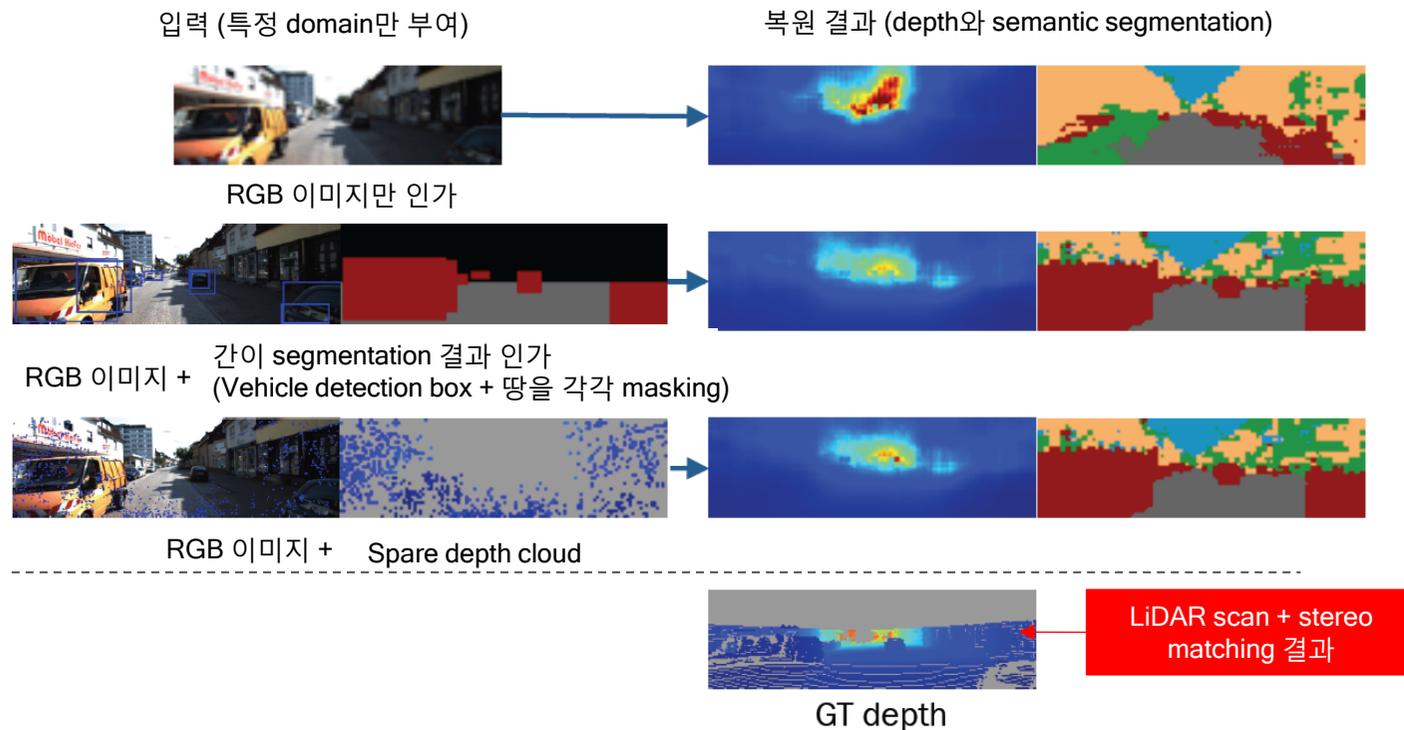
- 특정 modal의 데이터가 누락되었을 시
- 다른 modal 데이터들로 생성한 shared representation을 기반으로 하여 해당 데이터 추론 (reconstruction) 가능



Multi-Modal Deep Auto-Encoder

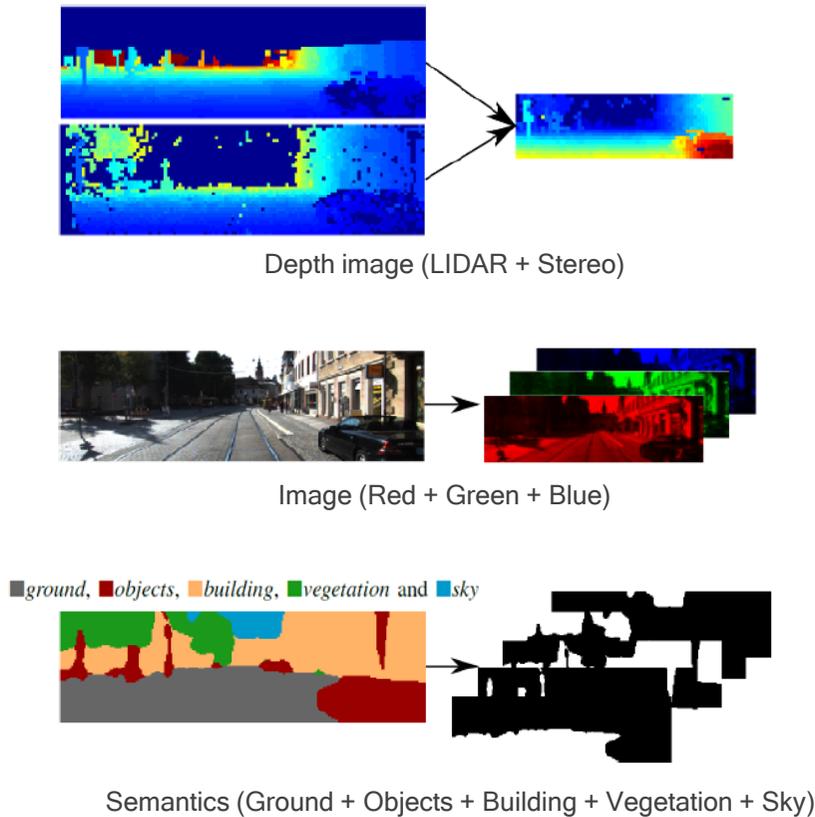
■ 관련연구: Multi-modal Auto-Encoders as Joint Estimators for Robotics Scene Understanding (ArXiv, 2016)

- 판별을 위한 Feature (shared representation) 학습보다는,
- 특정 domain 입력 누락 시, 다른 domain 정보로 누락된 domain 데이터 복원이 목적

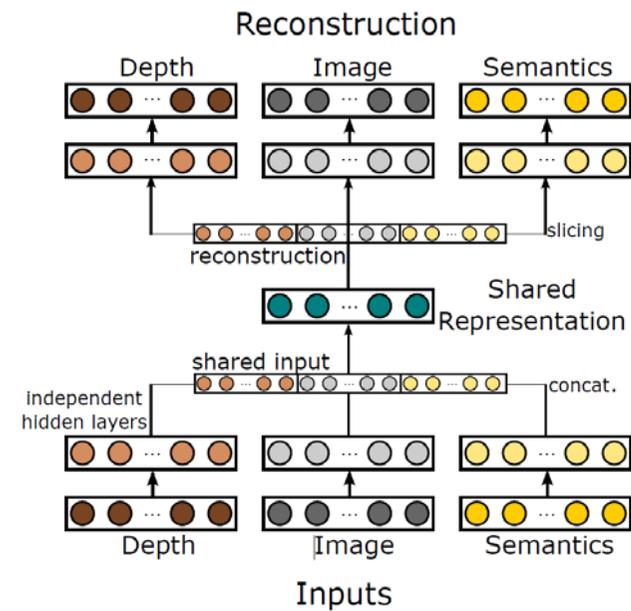


Multi-Modal Deep Auto-Encoder

- **관련연구: Multi-modal Auto-Encoders as Joint Estimators for Robotics Scene Understanding (ArXiv, 2016)**



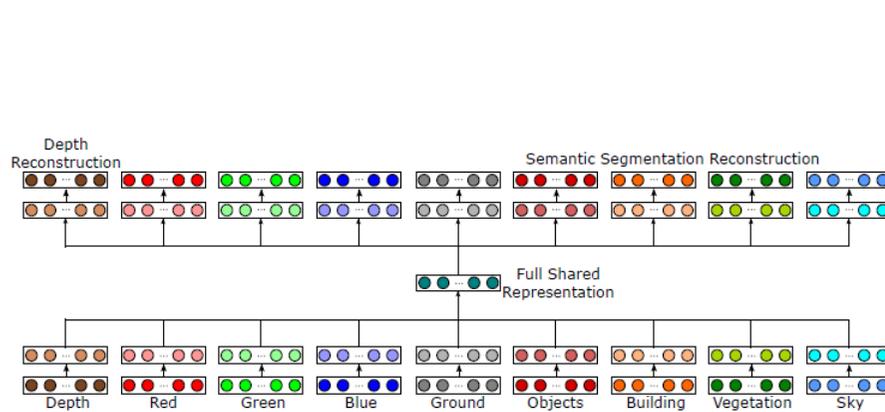
입력 (및 출력) 구성



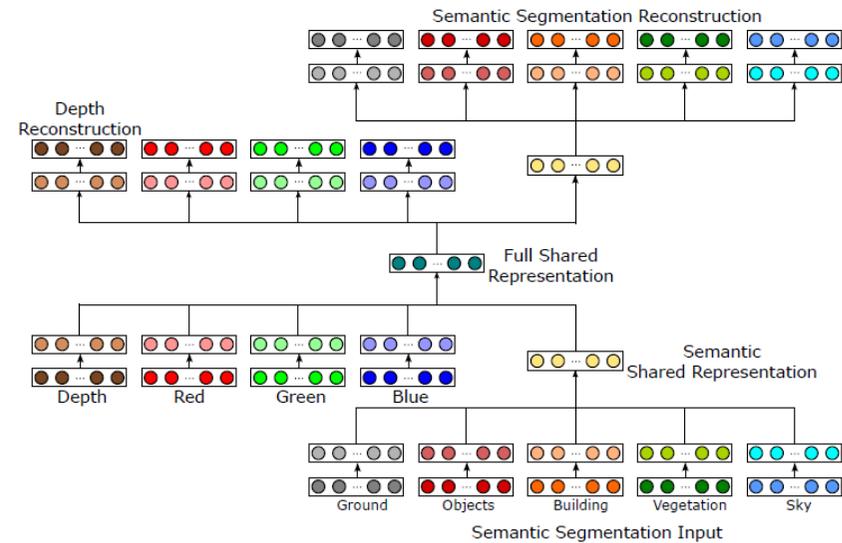
논문에서 사용한 MMDAE 구조 중 가장 기본적인 구조

Multi-Modal Deep Auto-Encoder

- **관련연구:** Multi-modal Auto-Encoders as Joint Estimators for Robotics Scene Understanding (ArXiv, 2016)



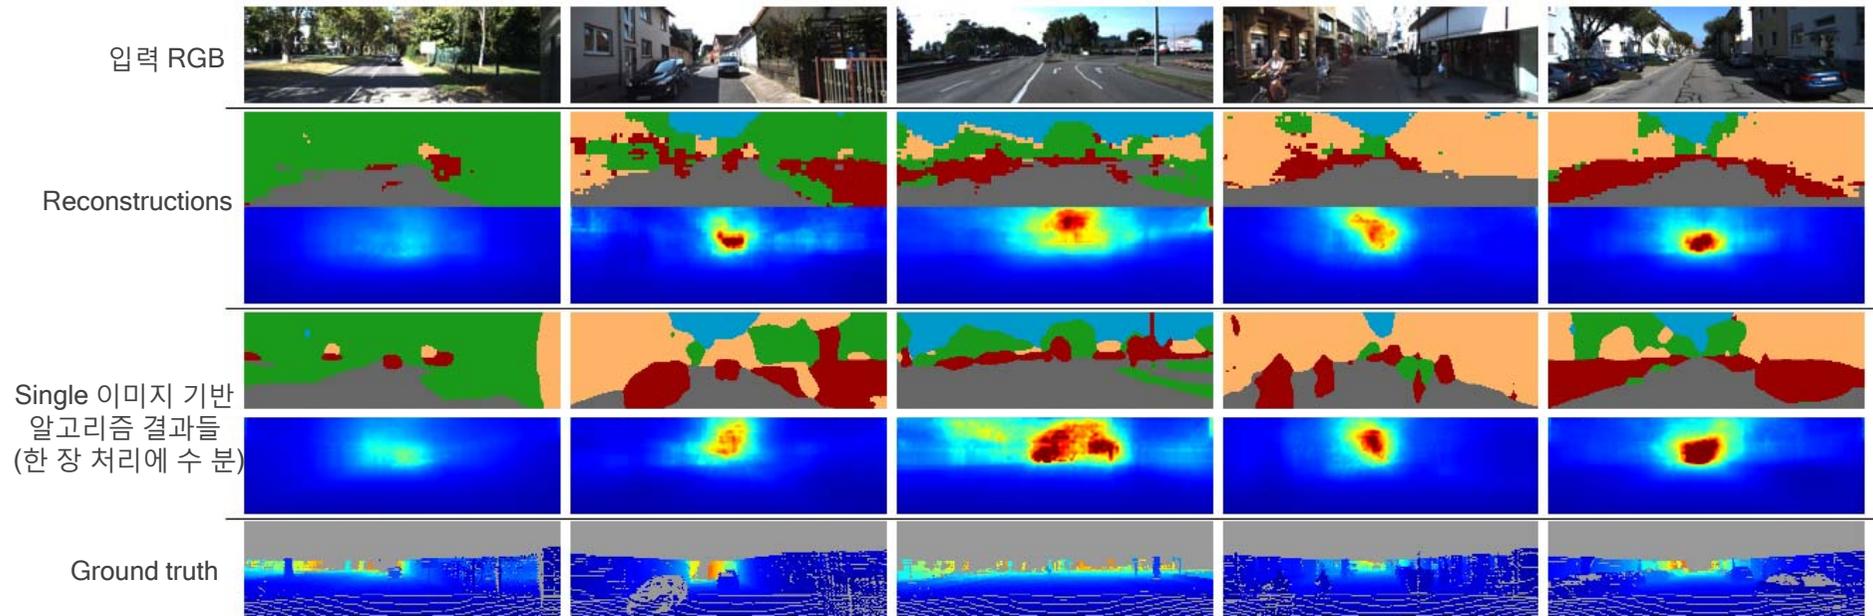
Full Flat MMAE



Full MMAE

Multi-Modal Deep Auto-Encoder

- **관련연구: Multi-modal Auto-Encoders as Joint Estimators for Robotics Scene Understanding (ArXiv, 2016)**
 - Full-MMAE vs. Single image 기반의 고성능, 고연산량 알고리즘



Full-MMAE 결과 vs. 고성능 고연산량 알고리즘 비교

02 연구목표 및 내용

MMDAE for Automotive

- 각 센서의 정상 동작 여부는 안정성과 직결

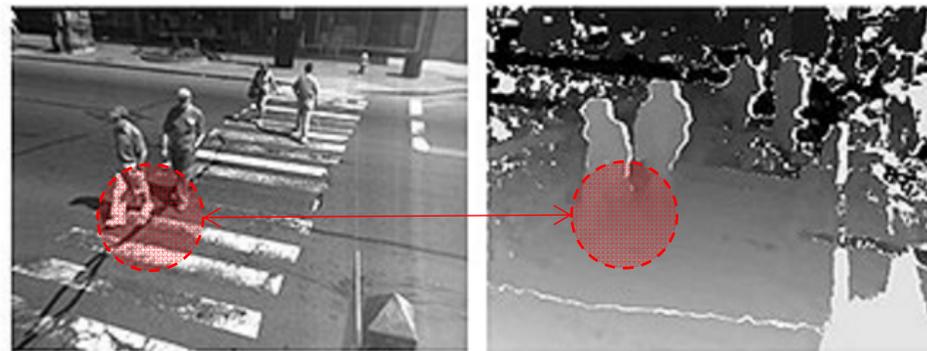


자율 주행 기능 이상으로 사망사고를 낸 Tesla 자동차. (좌) 사고 차량 (우) 영상 인식 실패로 말미암아 사고 차량이 충돌한 상대 차량

MMDAE for Automotive

연구 배경

- 센서 이상 동작의 연유들
 - ✓ 센서 자체의 hardware적인 파손
 - ✓ 외부 물질 등에 의한 측정 방해
 - Ex) 눈, 진흙 등이 센서 수신부 일부를 덮을 경우
 - ✓ Stereo camera 등 inferencing 과정을 거치는 센서의 inferencing 오류

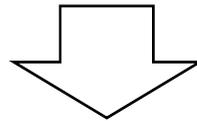


Stereo Depth 추정의 부정확성. (좌) 원본 영상 (우) 추정된 depth

MMDAE for Automotive

■ 연구 배경

- 센서 이상 동작 탐지에 관한 전통적인 접근법
 - ✓ 센서의 정상 동작에 대해 정의된 Rule (If-Then) 기반 판별
 - ✓ 제한된 숫자의 rule로, 가능한 모든 비정상 상황을 판별하기는 어려움
 - ✓ Inferencing이 잘못된 것에 대해서는 판별 불가능

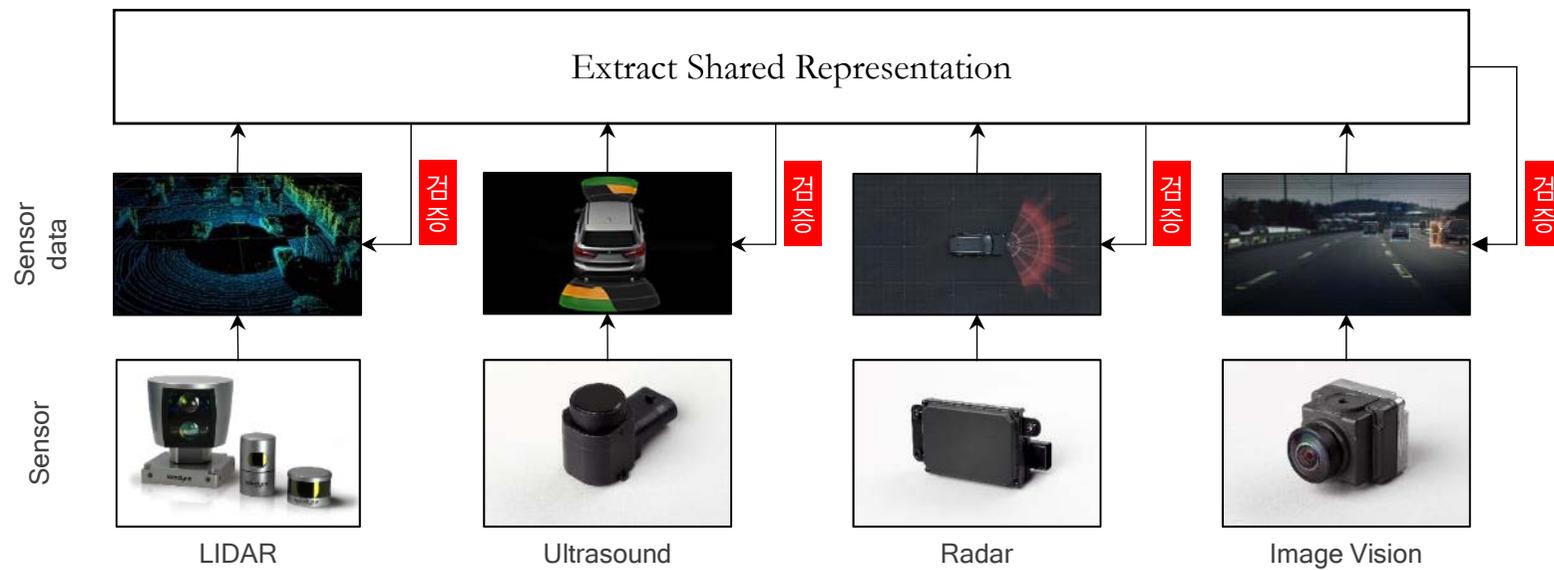


다수의 센서가 동시에 고장날 확률은 상대적으로 적으므로,
 센서 간의 cross validation을 구축하면 어떨까?

MMDAE for Automotive

첫 번째 연구 목표

- 비정상 작동 센서 탐지
- 센서 데이터 간 correlation modeling
 - ✓ 공통적으로 존재하는 정보 추출
 - ✓ 추출된 정보와 불일치하는 센서 데이터 판별
 - ✓ 이를 위해 Multi-Modal Deep Auto-Encoder 도입

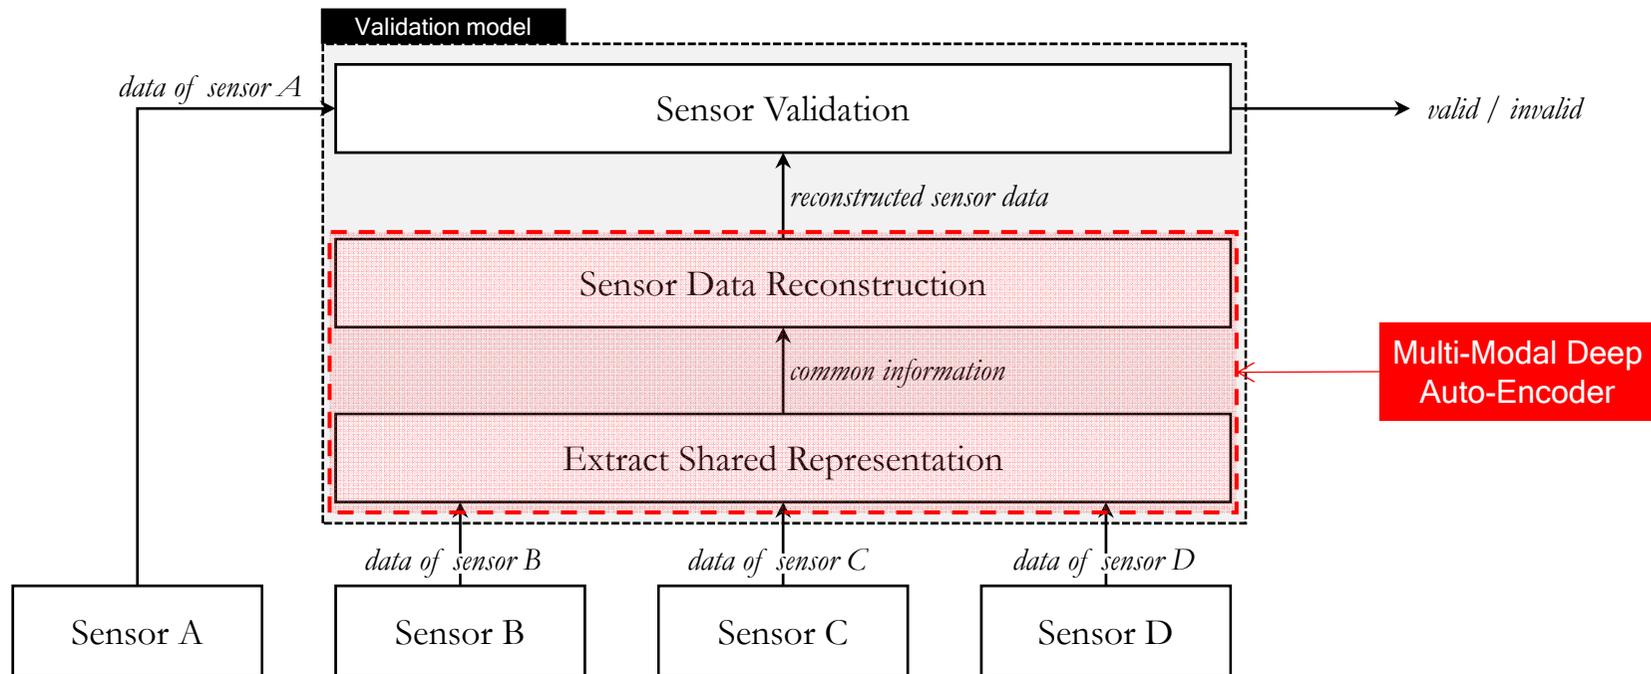


System Overview

MMDAE for Automotive

비정상 작동 센서 탐지: 센서 A의 검증

- 1) A의 센서 데이터를 제외한 다른 센서 데이터들을 검증 모델에 인가
- 2) Shared representation 추출
- 3) 센서 A에 대한 reconstruction 수행
- 4) 실제 센서 A로부터 취득된 정보와 reconstruction 결과 비교



MMDAE for Automotive

▪ 두 번째 연구 목표

- 측정 해상도가 높을 수록 센서의 가격 상승
- 자율 주행 차량에서 사용되는 센서의 종류와 수가 점차로 증가
- 센서들을 통해 얻은 정보를 효과적으로 취합할 경우, 그 가능성은?

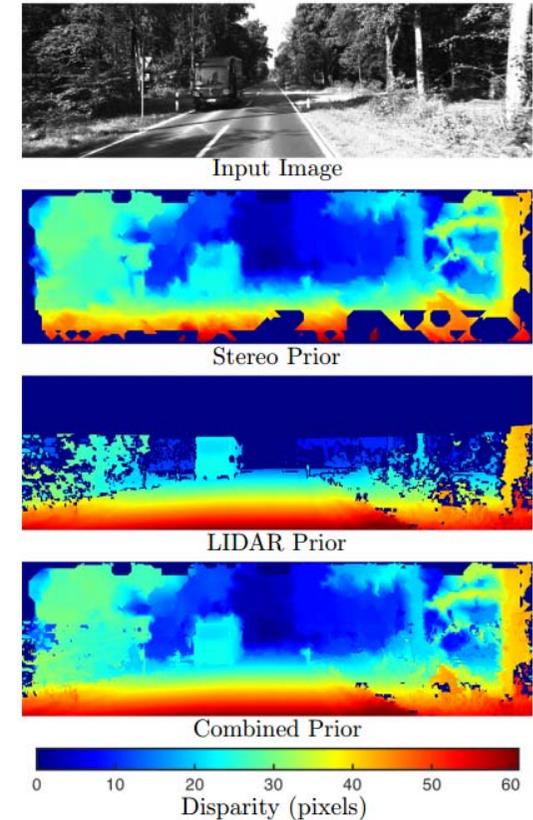


Uber의 무인 주행 차량: 다양한 종류, 많은 수의 센서를 장착

MMDAE for Automotive

▪ 두 번째 연구 목표

- Sparse LIDAR + Stereo 카메라의 collaboration
 - ✓ 고가의 dense LIDAR를 대체하기 위해 많은 선행 연구 존재
 - ✓ 대부분 probabilistic modeling을 통해 해결
 - 즉, 사람이 수동으로 design한 model에 의거하여 LIDAR와 stereo depth 값을 fusion
 - 과연 다양한 환경 (조명 및 날씨 등)에 잘 대응할 것인가?
- Sparse LIDAR + Stereo의 data fusion에 MMDAE를 도입한다면?
 - ✓ Sparse LIDAR data와 stereo image를 통해 dense LIDAR 값 reconstruction

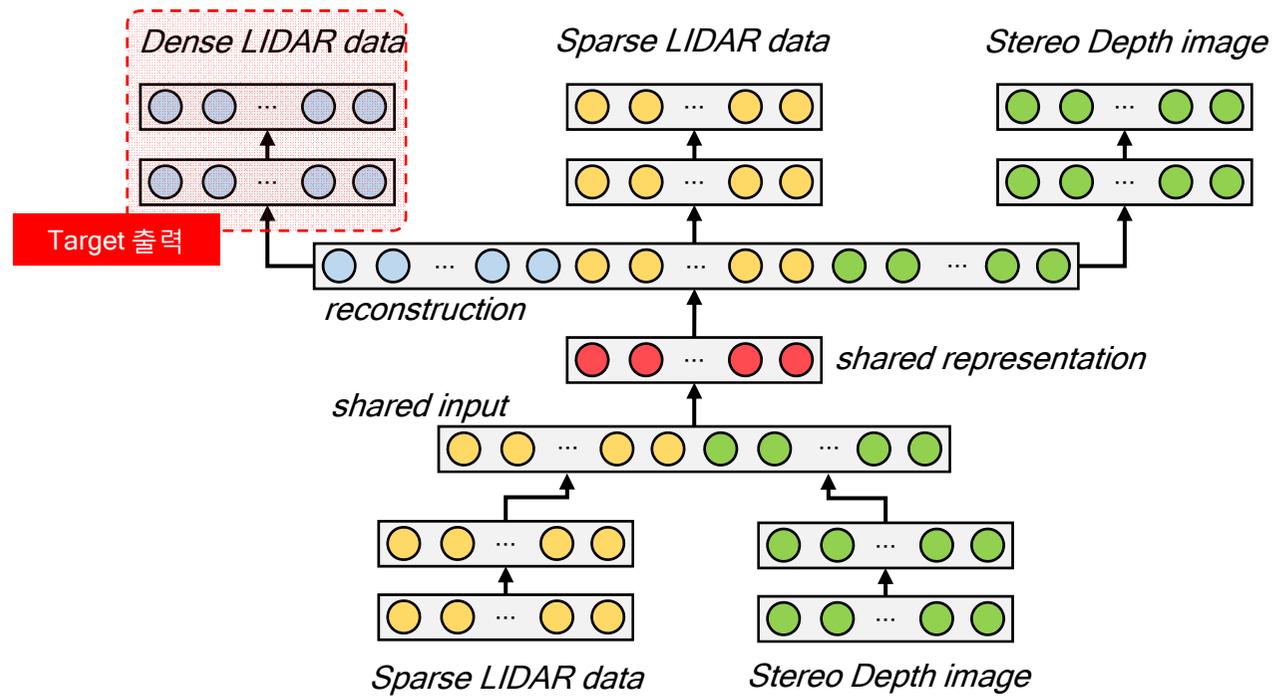


Stereo camera + LIDAR fusion의 예시
(2016년 IROS 논문 중 “Real-time probabilistic fusion of sparse 3D LIDAR and dense stereo”)

MMDAE for Automotive

▪ 두 번째 연구 목표

- Sparse LIDAR data와 stereo depth image를 입력으로 받고
- Dense LIDAR data를 출력하는 MMDAE



Multi-Modal Deep Auto-Encoder

▪ 향후 기대되는 연구 전망

- 현재까지 killing application 부재
 - ✓ 차량 관련 적용도 올해 들어 호주의 Reid 교수팀이 유일

- MMDAE에 variational auto-encoder와 같이, share representation에 대한 의미론적인 학습이 시도될 것으로 예상
 - ✓ Shared representation만으로 사람이 이해할 수 있는 상황 설명 제공 가능
 - ✓ 처음부터 끝까지 Black box 영상을 보는 대신, 주요 상황을 글로 summary 가능
 - ✓ 그 외, variational auto-encoder의 generation을 이용하여, 실차 테스트 이전에 사용할 수 있는 풍부한 가상의 데이터 생성 가능

- 결과적으로, multi-modal을 통해 보다 깊이 있는 상황 인식 및 이해에 관한 연구들 기대