



Keras

An API spec for building deep learning

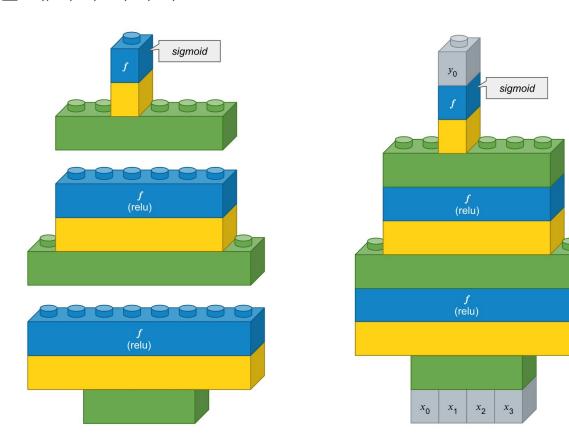




딥러닝을 사용하기 쉽게 만들면 더 많은 분들이 접근할 수 있겠죠. 케라스의 핵심은 모두의 손에 쥐어주는 것입니다.

#tfdevsummit

다층 퍼셉트론 레이어 이야기



DeepBrick for Keras (케라스를 위한 딥브릭)

Sep 10, 2017 • 김태영 (Taeyoung Kim)

The Keras is a high-level API for deep learning model. The API is very intuitive and similar to building bricks. So, I have started the DeepBrick Project to help you understand Keras's layers and models.

딥러닝과 케라스를 공부하면서 느낀 점은 총을 쌓고 모델을 만들고 하는 과정들이 블록 쌓는 것과 비슷한 느낌을 많이 받았고, 실제로 딥러닝 모델을 설명할 때 블록 그림을 많이 이용하기도 했습니다. 그러다가 (실제 혹은 웹에서) 블록을 쌓으면 딥러닝 모델까지 자동으로 만들 수 있겠다는 생각이 들었습니다. 그래서 딥브릭(DeepBrick)이란 이름으로 프로젝트를 진행해볼까 합니다.

Bricks

There are bricks supported by DeepBrick.

Dataset

Brick	Name	Description
	Input data, Labels	Input data and labels are encoded as vector. 1차원의 입력 데이터 및 라벨입니다.
E	2D Input data	Input data are encoded as 2D vector. 2차원의 입력 데이터입니다.
	2D II put data	In case of imagery, the dimention consists of sample, width, height and channel. 주로 영상 데이터를 의미하며 샘플수, 너비, 높이, 채널수로 구성됩니다.

Layers

Brick	Name	Description
5	Dense	Regular densely-connected neual network layer. 모든 입력 뉴런과 출력 뉴런을 연결하는 전결합충입니다.
	Embadding	Turns positive integer representations of words into a word embedding.



Activation Functions

Brick	Name	Description				
•	sigmoid	Returns a value between 0 and 1. 활성화 함수로 입력되는 값을 0과 1사이의 값으로 출력시킵니다. This is mainly used for the activation function of the output layer of the binary classification model it can be judged as positive if the output value is above a certain threshold value (for example, 0.5) or negative if it is below. 출력값이 특정 임계값(예를 들어 0.5) 이상이면 암성, 이하이면 음성이라고 판별할 수 있기 때문에 이진분류 모델의 출력층에 주로 사용됩니다.				
•	softmax	Returns the probability value per class. 활성화 함수로 입력되는 값을 클래스별로 확률 값이 나오도록 출력시킵니다. If all of these probabilities are added, it becomes 1. 이 확률값을 모두 더하면 1이 됩니다. It is used mainly for the activation function of the output layer of a multi-class model, and the class with the highest probability value is the class classified by the model. 다중클래스 모델의 솔릭증에 주로 사용되며, 확률값이 가장 높은 클래스가 모델이 분류한 클래스입니다.				
	tanh	Returns a value between -1 and 1. 활성화 함수로 입력되는 값을 -1과 1사이의 값으로 출력시킵니다. It is used for the activation function of LSTM layer. LSTM의 출력 활성화 함수로 사용됩니다.				
de	relu	It is mainly used of the activation funition of the hidden layer. 활성화 함수로 주로 은닉층에 사용됩니다.				
4	relu	It is mainly used of the activation funition of the hidden layer such as Conv2D. 활성화 함수로 주로 Conv2D 은닉층에 사용됩니다.				

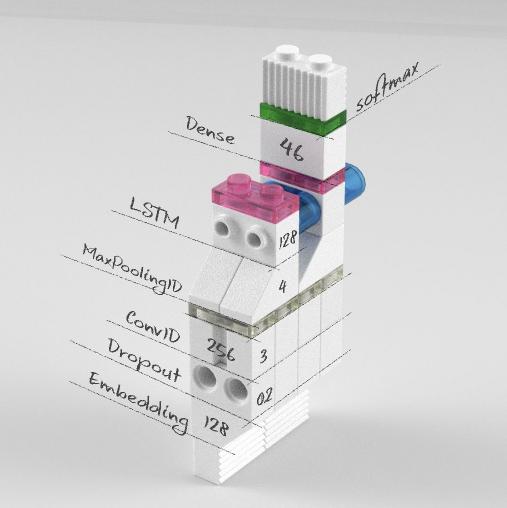


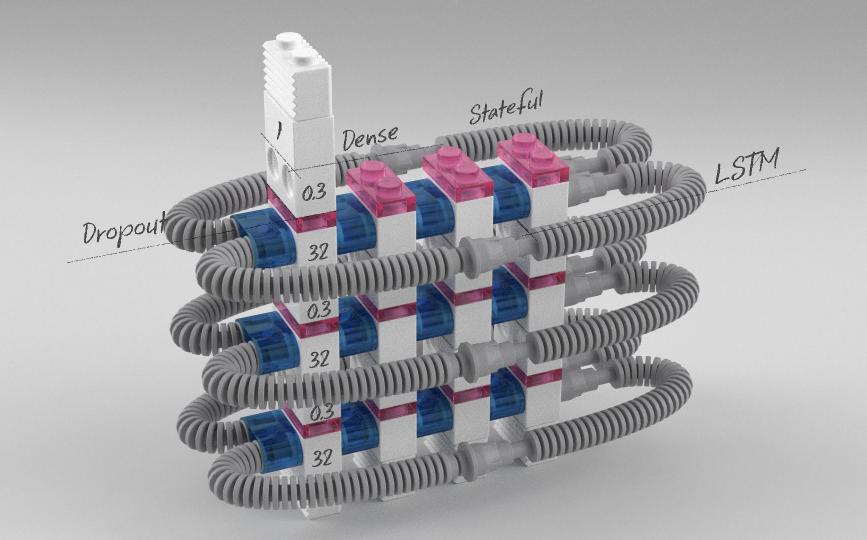


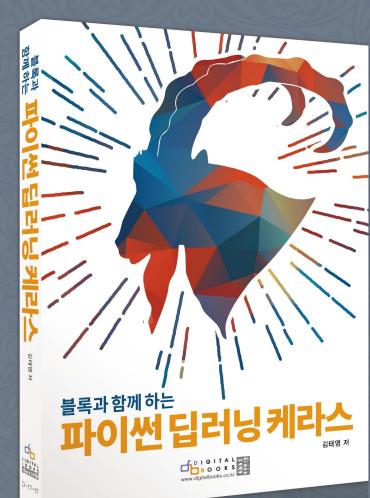


```
Block 5
Block 4
Block 3
Block 2
Block,
```

```
# Block 1
x = Conv2D(64, (3, 3), activation='relu', padding='same',
name='block1_conv1')(img_input)
x = Conv2D(64, (3, 3), activation='relu', padding='same',
name='block1_conv2')(x)
x = MaxPooling2D((2, 2), strides=(2, 2),
name='block1_pool')(x)
# Block 2
x = Conv2D(128, (3, 3), activation='relu', padding='same',
name='block2_conv1')(x)
x = Conv2D(128, (3, 3), activation='relu', padding='same',
name='block2_conv2')(x)
x = MaxPooling2D((2, 2), strides=(2, 2),
name='block2_pool')(x)
# Block 3
x = Conv2D(256, (3, 3), activation='relu', padding='same',
name='block3_conv1')(x)
x = Conv2D(256, (3, 3), activation='relu', padding='same',
name='block3_conv2')(x)
x = Conv2D(256, (3, 3), activation='relu', padding='same',
name='block3_conv3')(x)
x = MaxPooling2D((2, 2), strides=(2, 2),
name='block3_pool')(x)
# Block 4
x = Conv2D(512, (3, 3), activation='relu', padding='same',
name='block4_conv1')(x)
x = Conv2D(512, (3, 3), activation='relu', padding='same',
name='block4_conv2')(x)
x = Conv2D(512, (3, 3), activation='relu', padding='same',
name='block4_conv3')(x)
x = MaxPooling2D((2, 2), strides=(2, 2),
name='block4_pool')(x)
# Block 5
x = Conv2D(512, (3, 3), activation='relu', padding='same',
name='block5_conv1')(x)
x = Conv2D(512, (3, 3), activation='relu', padding='same',
name='block5_conv2')(x)
x = Conv2D(512, (3, 3), activation='relu', padding='same',
name='block5_conv3')(x)
x = MaxPooling2D((2, 2), strides=(2, 2),
name='block5_pool')(x)
if include_top:
    # Classification block
    x = Flatten(name='flatten')(x)
    x = Dense(4096, activation='relu', name='fc1')(x)
    x = Dense(4096, activation='relu', name='fc2')(x)
    x = Dense(classes, activation='softmax',
name='predictions')(x)
else:
    if pooling == 'avg':
        x = GlobalAveragePooling2D()(x)
    elif poolina == 'max':
        x = GlobalMaxPoolina2D()(x)
```







اوور الدرداددر الدادرودا لطفادروا رودا رود 3 الوددادور الود الود ال<mark>ل</mark>ادوادور ال<mark>ل</mark>ادو 🔏

حرور اوور واووروا وووافهم والووا ووفاة

위 약보로 연주한 곡은 아래 링크에서 다운로드할 수 있습니다.

http://tykimos.github.com/Keras/warehouse/2017-4-9-Stateless_LSTM_one_step_

http://tykimos.github.com/Keras/warehouse/2017-4-9-Stateless_LSTM_full_song_ prediction, mp3

7. 상태유지 LSTM 모델

이번에는 상태유지(Stateful) LSTM 모델에 대하여 알아보겠습니다. 여기서 상태유지라는 것은 현 제 학습된 상태가 다음 학습 시 초기 상태로 전달된다는 것을 의미합니다.

상태우지 모드에서는 현재 성품의 하는 상태가 다음 성품의 초기 상태로 전달된다.

긴 시퀀스 데이터를 처리할 때, LSTM 모델은 상태유지 모드에서 그 전가를 발휘합니다. 긴 시퀀스 데이터를 샘플 단위로 잘라서 학습하더라도 LSTM 내무적으로 기약할 것은 기약하고, 비밀 것은 비 현시 기억해야 할 중요한 정보만 이어갈 수 업도를 상태가 유지되기 때문입니다. 상태유지 LST넘 모 델을 생성하기 위해서는 LSTM 케이어 생성 시, stateful=True로 설정합니다. 도한 상대휴지 모드 에서는 임략형태를 batch_input_shape = (매치사이즈, 타임스템, 속성)으로 설정해야 합니다. 상 대유지 모드에서 배치사이즈 개념은 조금 어려우므로 다음 장에서 다무기로 하겠습니다.

model = Sequential()
model_add(LSTB(12B, band_input_shape = (1, 4, 1), stateful=True))
model_add(Dense(one_but_vec_size, activation="softmax"))



- 이 표현은 다음을 의미합니다.
- 일력 이미지 사이즈가 3x3이고 채널이 3개입니다.
- · 2x2 커널을 가진 필터가 2개입니다. 채널마다 커널이 힘당되어 총 가중치는 3x2x2x2로 24개 입니다. · 출력 이미자는 사이즈가 3K3이고 채널이 2개입니다.

2, 사소한 변화를 무시해주는 맥스플링(Max Pooling) 레이어

건블루션 레이어의 클릭 이미지에서 주요같만 뽑아 크기가 작은 클릭 영상을 만듭니다. 이것은 지역 적인 사소한 변화가 영향을 미치지 않도록 합니다.

MaxPooling2D(pool_size=(2, 2)) 주요 인자는 다음과 같습니다.

- · pool_size: 수직, 수평 축소 비율을 지정합니다. (2, 2)이면 출력 영상 크기는 입력 영상 크기의 반으로 중이됩니다

예를 들어, 입력 영상 크기가 4×4이고, pool size를 (2, 2)로 했을 때를 도식화하면 다음과 같습니다. 녹색 블루은 임리 영상을 나타내고, 노란색 블루은 pool size에 따라 나는 정계를 표시합니다. 해당 정치에서 가장 큰 값을 선택하여 파란 불목으로 만들면, 그것이 출력 영상이 됩니다. 가장 오른쪽은 맥스플링 레이어를 약식으로 표시한 것입니다.



OWNEROS_ESSAG SIGN HOR CORP. - 119

상태유지 모드에서는 모델 학습 시, 상태 초기화에 대한 고민이 필요합니다. 현재 점증 학습 상태가 다음 생품 학습의 초기상대로 상대를 유지시키지 않고 초기화력이 합니다. 전달되는 식인데, 현재 생품과 다음 생품 간의 순차적인 문제가 없음 경우에는 상태가 유지되지 않고 요기화가 되어야 함 니다. 예를 들면,

- 마지막 생품 학습을 마치고, 새로운 에르크 수행 시 새로운 생품 학습을 해야하므로 상태 초 기화 평요
- 한 에포크 안에 여러 시원스 테이터 새로가 있을 경우, 새로운 시원스 테이터 새로를 학습 전 에 상태 초기화 필요

현재 코드에서는 한 곡을 가지고 계속 학습을 시키고 있으므로 새로운 예르크 시작 시에만 상태 초 기화를 수행하면 됩니다.

for epoch lide in range (nun epochs)

model.add(Dropout(0,3)) model.add(Dense(1))



· 상태유지 스텍 순환신경망 모델

상태유지 순환신경당을 여러점 쌓아올린 모델입니다. 중이 하나인 순환신정당에 비해 더 깊은 주론 이 가능한 모델입니다.

for i in range(2): model.add(LSTM(32, batch_inpun_shape=(1, look_back, 1), staneful=True, return_

sequences=True)) model.add(Dropout(0.3)) model.add(LSTM(32, batch_input_shaper(1, look_back, 1), stateful=True))



омителя и дерозда од об на нап. - 257

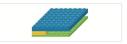
CHAPTER 25 _ DESCH EIGH HOLH OLD 1 * 121

4. 한 번 쌓아보기

지금까지 알아본 레이어를 이용해서 간단한 건물무선 신경망 모델을 만들어보겠습니다. 먼저 간단 한 문제를 정의해봅시다. 삼각형, 사각형, 원을 손으로 그린 이미지가 있고 어미지 크기가 8x8이라 고 가정해봅니다. 삼각형, 사각형, 원을 구분하는 3개의 클래스를 분류하는 문제이기 때문에 출리 배 터는 3개여야 합니다. 필요하다고 생각하는 레이어를 구성해보았습니다.



 건물부선 레이어: 임리 이미지 크기 8/8, 임리 이미지 재널 1개, 캠퍼 크기 3/3, 캠퍼 수 2개, 경 계 타임 'same', 활성화 함수 'relu'



맥스플링 레이어 : 중 크기 2×2



이 레이어는 영상의 작은 변화라든지 사소한 움직임이 특징을 추출할 때 크게 영향을 미치지 않도 목 합니다. 영상 내에 특징이 세 개가 있다고 가정됐을 때, 아래 그림에서 첫 번째 영상을 기준으로 두 번째 영상은 오른쪽으로 이동하였고, 세 번째 영상은 약간 미름이 졌고, 내 번째 영상은 조금 확 대되었지만, 핵스물링한 점과는 모두 동일합니다. 얼굴 인식 문제를 예를 들면, 핵스물링의 역할은 사람마다 눈, 코, 입 위치가 조금씩 다른데 이러한 차이가 사람이라고 인식하는데 있어서는 큰 영향 을 미치지 않게 합니다.



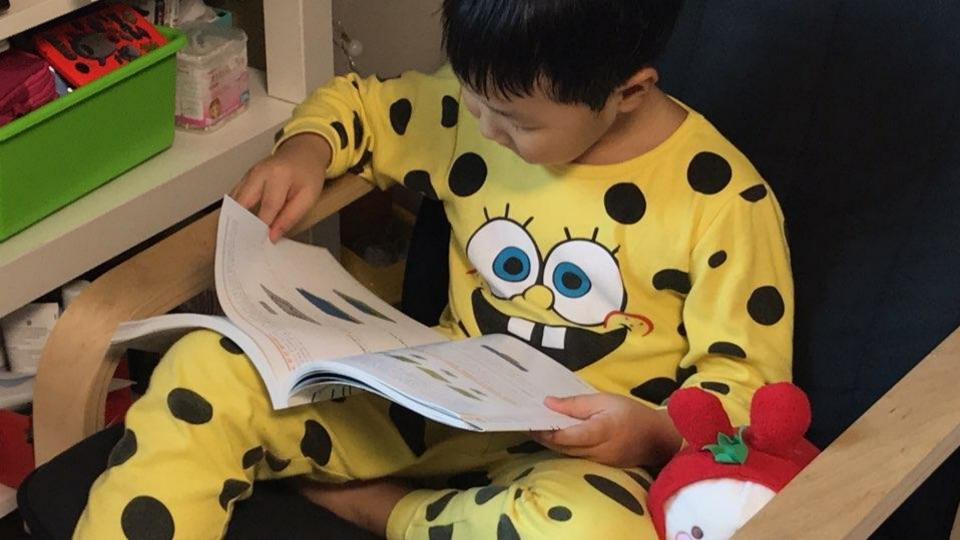
3. 영상을 일치원으로 바꿔주는 플래튼(Flatten) 레이어

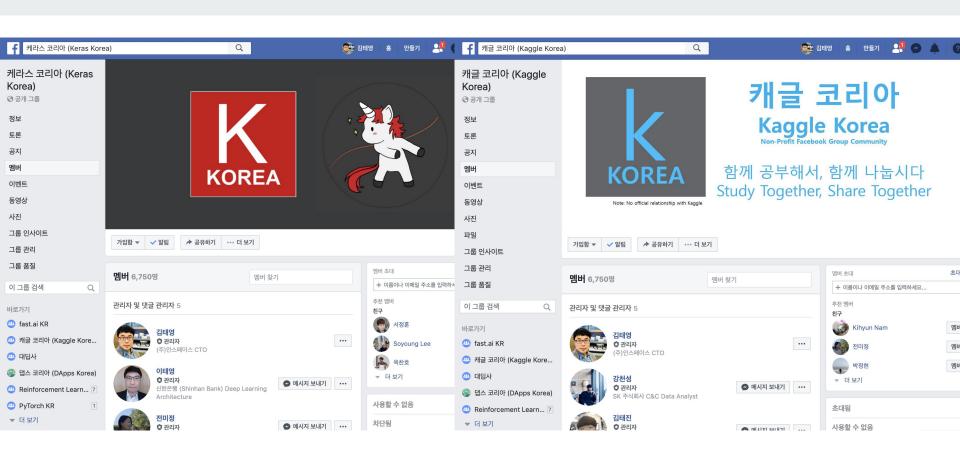
컨블루션 신경당 모델에서 컨블루션 레이어나 백스품링 레이어를 만복적으로 거치면 주요 득정만 추 출되고 추출된 주요 특징은 전집합중에 전달되어 학습됩니다. 컨블루션 레이어나 맥스플링 레이어는 주로 2차원 자료를 다무지만 전골함층에 전달하기 위해선 1차원 자료로 바록줘야 합니다. 이 때 사 용되는 것이 끝래든 레이어입니다. 사용 예시는 다음과 같습니다.



이건 레이어의 출력 정보를 이용하며 일력 정보는 자동으로 설정되며, 출력 형태는 일력 형태에 따 라 자동으로 제산되기 때문에 별도로 사용자가 파라미터를 지정해주지 않아도 됩니다. 크기가 3x3 인 영상을 1차원으로 변경했음 경우를 도식화하면 다음과 같습니다.





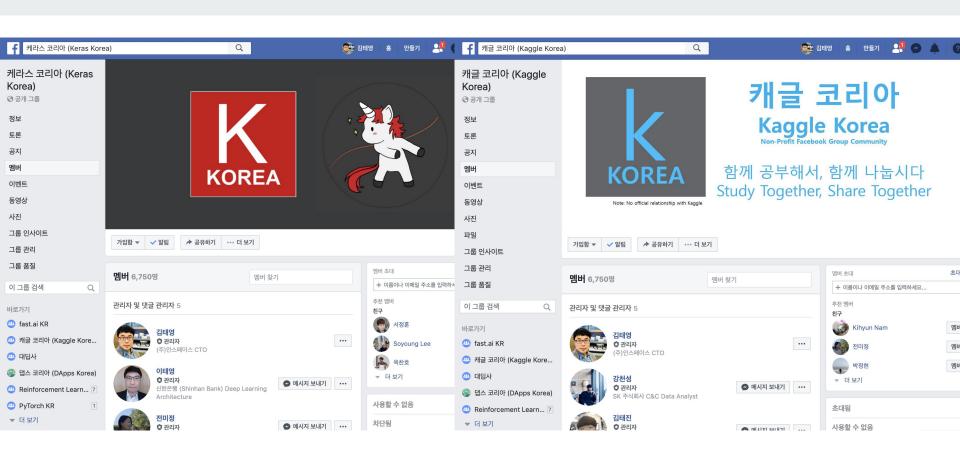


Solar farside magnetograms from deep learning analysis of STEREO/EUVI data

Taeyoung Kim^{1,7}, Eunsu Park ^{1,7}, Harim Lee ^{1,2,7}, Yong-Jae Moon ^{1,2,4}, Sung-Ho Bae³, Daye Lim¹, Soojeong Jang⁴, Lokwon Kim³, Il-Hyun Cho ^{1,2}, Myungjin Choi⁵ and Kyung-Suk Cho^{4,6}

Solar magnetograms are important for studying solar activity and predicting space weather disturbances¹. Farside magnetograms can be constructed from local helioseismology without any farside data²⁻⁴, but their quality is lower than that of typical frontside magnetograms. Here we generate farside solar magnetograms from STEREO/Extreme UltraViolet Imager (EUVI) 304-Å images using a deep learning model based on conditional generative adversarial networks (cGANs). We train the model using pairs of Solar Dynamics Observatory (SDO)/Atmospheric Imaging Assembly (AIA) 304-Å images

training step, the generator is trained to learn the polarity patterns of active regions. In the evaluation and generation step, the generator reproduces the pattern. Since all data are from the 24th solar cycle, there is no difficulty in producing the Hale's law pattern in this cycle. We note that the polarity of the solar magnetic field is reversed cycle by cycle. Hence, since our model has been trained on the 24th solar cycle, it would be effective for even solar cycles, but should be tested for odd cycles. A careful comparison between two magnetograms shows that the tilt angle between a preceding sunspot and the one that follows it is not always properly generated,



 \equiv

비지니스 모델

제조 혁신 >> Smart Factory

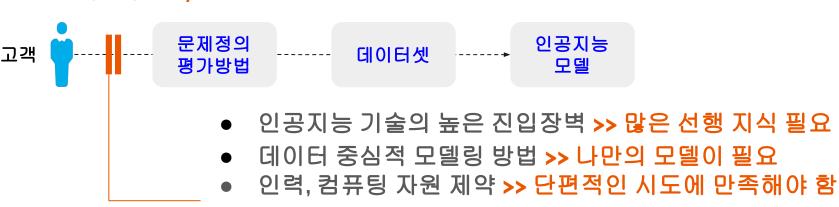
AI 혁신 >> AI Factory

배경



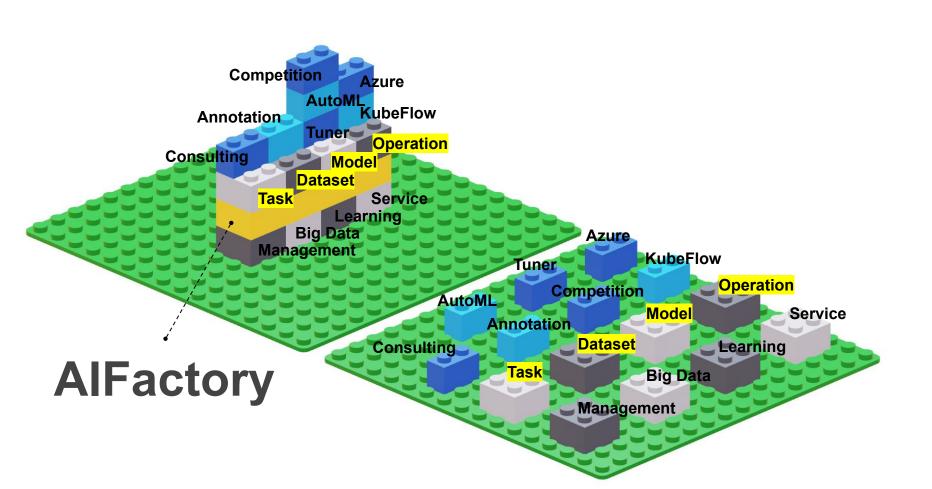
- 인공지능 기술 수요 급증
- 인공지능의 눈부신 발전속도 >> 더불어 오픈되는 소스코드
- 많은 튜토리얼과 다양한 적용사례 정보 >> 기술접근 용이
 - 각종 정부지원 사업 및 범용 인공지능 모델 서비스 >> 기술보편화

하지만, 세가지 요소를 모두 갖춰야만 인공지능 기술 도입이 가능

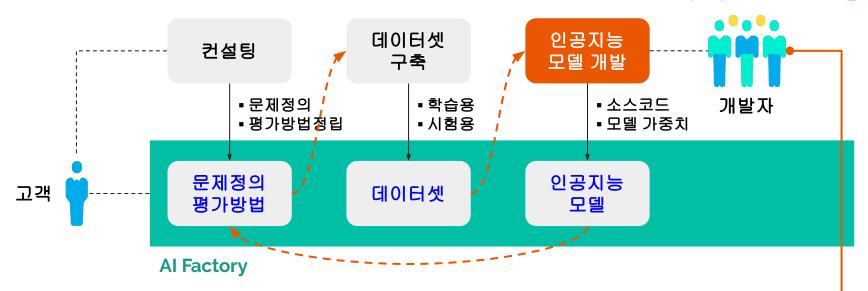


애로사항

- 인공지능 전문가 품귀현상 >> 높은 비용
- 성능 예측의 어려움 >> 높은 리스크
- 소요시간 산정의 어려움 >> 시장 선점 실패



크라우드 소싱



크라우드 소싱 기반 인공지능 문제해결 협업 플랫폼

- 세 가지 요소를 플랫폼에서 묶어줌 >> 고객은 컨설팅만 수행
- 목표 성능 선착순 달성 보상 지급 방식>> 기간과 비용을 단축시키면서 고성능의 모델 획득



넷플릭스 추천시스템 머신러닝 경연대회

상금 \$1,000,000 (약 11.7억원)

빅데이터 분석 분야에 크라우드 소싱 가능성 입증

넷플릭스 핵심인 추천시스템 알고리즘의 발전 계기가 됨

4회	2달	6시간	1억	92%	-
랩	기간	체크포인트	상금	목표	달성
1회	2주	-	3천	-	-
2회	-	6시간	-	-	-
3회	-	6시간	-	-	-
4회	-	6시간	-	92%	-

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
시작	1회	2주	_	3천	-	-
	2회	-	6시간	-	-	_
	3회	-	6시간	-	-	-
	4회	-	6시간	-	92%	-

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
2주 후	1회	2주	-	3천	-	70%
	2회	-	6시간	-	-	-
	3회	-	6시간	-	-	-
	4회	-	6시간	-	92%	-

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	-	3천	-	70%
랩설정	2회	-	6시간	2천	80%	-
	3회	-	6시간	2천	88%	-
	4회	-	6시간	3천	92%	-

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	_	3천	-	70%
시작	2회	-	6시간	2천	80%	-
	3회	-	6시간	2천	88%	-
	4회	-	6시간	3천	92%	-

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	_	3천	-	70%
3일 후	2호	3일	6시간	2천	80%	89%
	3회	-	6시간	2천	88%	_
	4회	-	6시간	3천	92%	-

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	-	3천	-	70%
	2회	3일	6시간	2천	80%	89%
재설정	3회	-	6시간	2천	92%	-
	4회	-	6시간	3천	95%	-

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	_	3천	-	70%
	2회	3일	6시간	2천	80%	89%
시작	3회	-	6시간	2천	92%	-
	4회	-	6시간	3천	95%	=

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	_	3천	-	70%
	2회	3일	6시간	2천	80%	89%
1주 후	3회	1주	6시간	2천	92%	94%
	4회	-	6시간	3천	95%	_

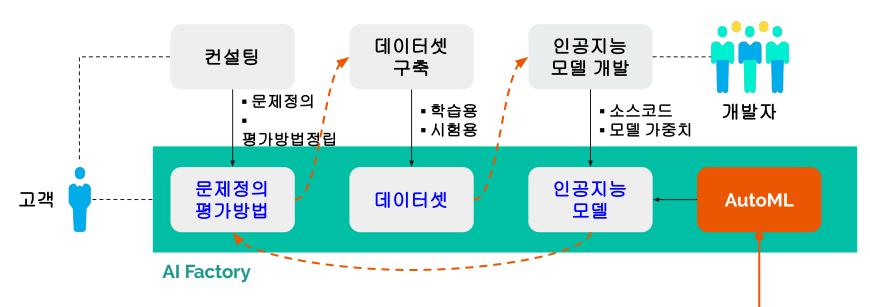
	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	_	3천	-	70%
	2회	3일	6시간	2천	80%	89%
	3회	1주	6시간	2천	92%	94%
재설정	4회	-	6시간	3천	97%	-

4회	2달	6시간	1억	92%	-
랩	기간	체크포인트	상금	목표	달성
1회	2주	_	3천	-	70%
2회	3일	6시간	2천	80%	89%
3회	1주	6시간	2천	92%	94%
4회	-	6시간	3천	97%	-
	래 1회 2회 3회	랩 기간 1회 2주 2회 3일 3회 1주	랩 기간 체크포인트 1회 2주 - 2회 3일 6시간 3회 1주 6시간	랩 기간 체크포인트 상금 1회 2주 - 3천 2회 3일 6시간 2천 3회 1주 6시간 2천	랩 기간 체크포인트 상금 목표 1회 2주 - 3천 - 2회 3일 6시간 2천 80% 3회 1주 6시간 2천 92%

	4회	2달	6시간	1억	92%	-
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	-	3천	-	70%
	2회	3일	6시간	2천	80%	89%
	3회	1주	6시간	2천	92%	94%
4일 후	4회	4일	6시간	3천	97%	98%
					 	

	4회	2달	6시간	1억	92%	98%
	랩	기간	체크포인트	상금	목표	달성
	1회	2주	_	3천	-	70%
	2회	3일	6시간	2천	80%	89%
	3회	1주	6시간	2천	92%	94%
	4회	4일	6시간	3천	97%	98%
No.	흥기긴	3주				

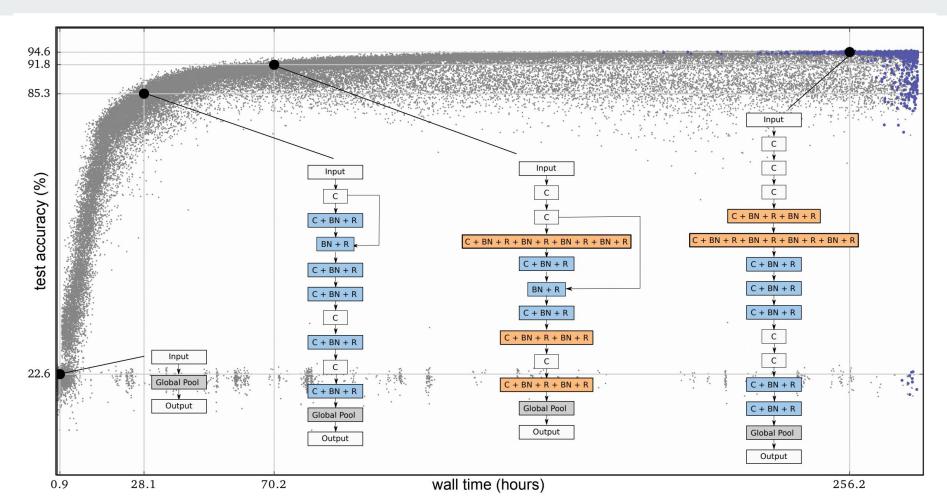
4회	2달	6시간	1억	92%	98%
랩	기간	제크포인트	상금	목표	달성
1회	2주	-	3천	-	70 %
2호	3일	6시간	2천	80%	89%
3회	1주	6시간	2천	92%	94%
4호	4일	6시간	3천	97%	98%
총 기간	3주				



데이터셋에서 머신러닝 모델을 자동으로 생성

- AutoML이 개발자와 함께 경연대회 가능
- AutoML만으로 수행할 경우 데이터 공개 불필요

비지니스 모델: AutoML







Example

Here is a short example of using the package.

```
import autokeras as ak
clf = ak.ImageClassifier()
clf.fit(x_train, y_train)
results = clf.predict(x_test)
```

For detailed tutorial, please check here.

```
model = Sequential()
model.add(Conv2D(32, kernel_size=(3, 3),
                activation='relu',
                input_shape=input_shape))
model.add(Conv2D(64, (3, 3), activation='relu'))
model.add(MaxPooling2D(pool_size=(2, 2)))
model.add(Dropout(0.25))
model.add(Flatten())
                                                          clf = ImageClassifier(verbose=True, augment=False)
model.add(Dense(128, activation='relu'))
model.add(Dropout(0.5))
                                                          clf.fit(x_train, y_train, time_limit=12 * 60 * 60)
model.add(Dense(num_classes, activation='softmax'))
                                                          clf.final_fit(x_train, y_train, x_test, y_test, retrain=True)
                                                          y = clf.evaluate(x_test, y_test)
model.compile(loss=keras.losses.categorical_crossentropy,
                                                          print(y * 100)
             optimizer=keras.optimizers.Adadelta(),
                                                          print("end")
             metrics=['accuracy'])
                                                           MNIST Test Accuracy
model.fit(x_train, y_train,
         batch_size=batch_size,
         epochs=epochs,
                                                           Keras: 0.9912
         verbose=1,
         validation_data=(x_test, y_test))
                                                           AutoKeras: 0.994(0.998)
score = model.evaluate(x_test, y_test, verbose=0)
```

Task API

AutoKeras support the following task APIs.

ImageClassifier class

```
autokeras.task.ImageClassifier(
    num_classes=None,
   multi_label=False,
    loss=None,
   metrics=None,
    name="image_classifier",
   max_trials=100,
    directory=None,
    objective="val_loss",
    seed=None,
```

AutoKeras image classification class.

Table of contents

ImageClassifier class ImageRegressor class TextClassifier class TextRegressor class

Coming Soon:

[source]





Search



GitHub 6.3k Stars · 1.0k Forks

- airectory: String. The path to a directory for storing the search outputs. Defaults to None, which would
 create a folder with the name of the AutoModel in the current directory.
- **objective**: String. Name of model metric to minimize or maximize, e.g. 'val_accuracy'. Defaults to 'val_loss'.
- seed: Int. Random seed.

Table of contents

ImageClassifier class

ImageRegressor class

TextClassifier class

TextRegressor class

Coming Soon:

Coming Soon:

StructuredDataClassifier

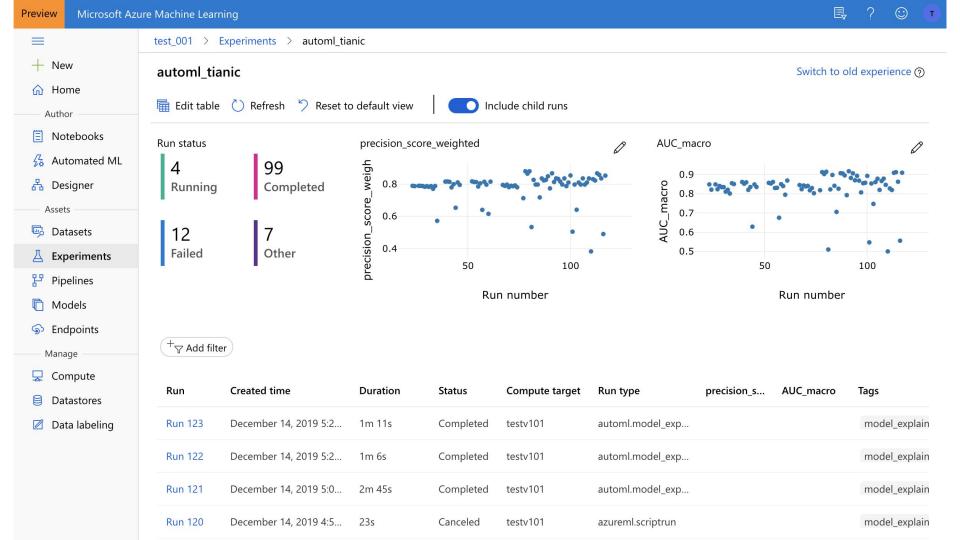
StructuredDataRegressor

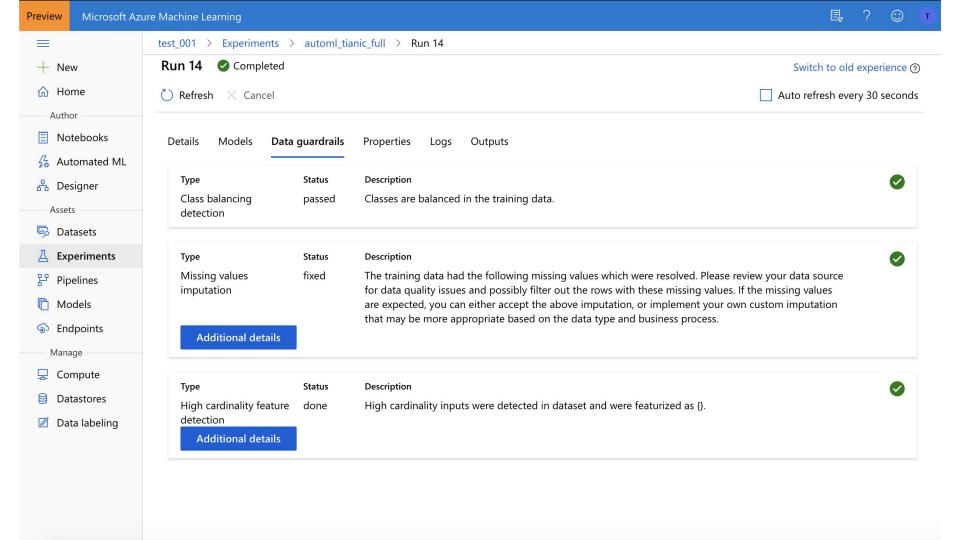
TimeSeriesForecaster

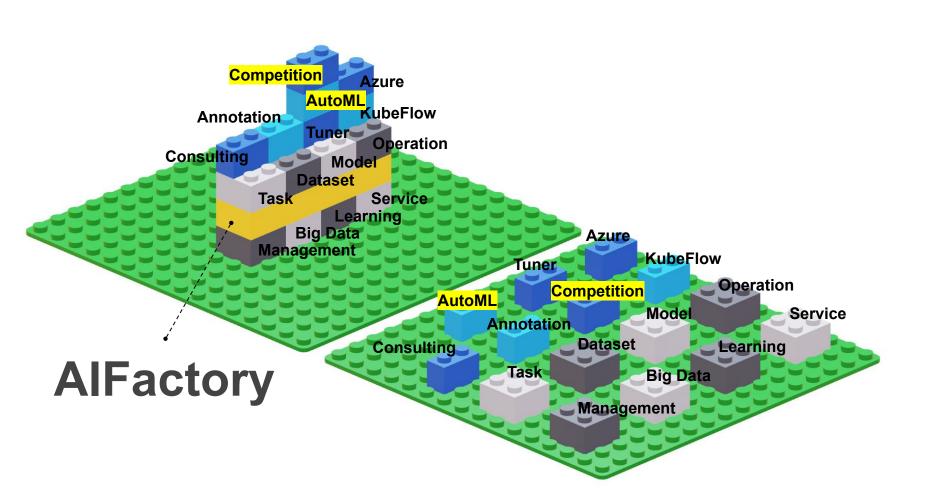
← Contributing Guide

Next AutoModel

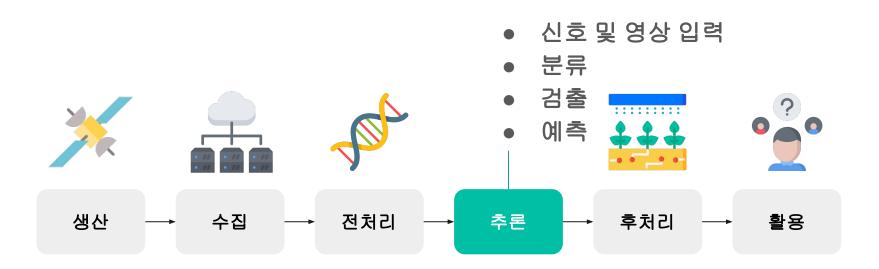








비지니스 모델: 데이터셋 구축



- 데이터는 중요하나 프로세스마다 그 가치가 다름
- 인공지능 추론의 기술 가치는 하락하고 있음
- 일부 데이터만 공개, 비식별 조치 >> 공개 조건 달성
- 데이터셋 암호화 기술 발전 >> 폐쇄 학습 가능

TF Encrypted Keras

- Encrypted Training
- Encrypted Predictions with Public Training
- Encrypted Predictions After Public Training with Differential Privacy

Encrypted Training

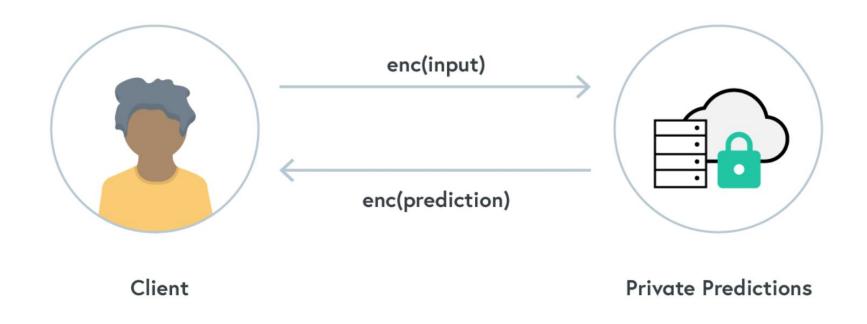


Using TFE Keras, Data Scientists can train models on encrypted data

Encrypted Training

```
import tf_encrypted as tfe
   from tf_encrypted.keras.losses import BinaryCrossentropy
    from tf encrypted.keras.optimizers import SGD
    from common import DataOwner
   num features = 10
    batch size = 100
    steps per epoch = (training set size // batch size)
   epochs = 20
11
12 # Provide encrypted training data
   data_owner = DataOwner('data-owner', batch_size)
   x_train, y_train = data_owner.provide_private_training_data()
15
16 # Define model
   model = tfe.keras.Sequential()
   model.add(tfe.keras.layers.Dense(1, batch input shape=[batch size, nur
    model.add(tfe.keras.layers.Activation('sigmoid'))
20
   # Specify optimizer and loss
   model.compile(optimizer=SGD(lr=0.01),
                  loss=BinaryCrossentropy())
23
24
   # Start training
    model.fit(x_train,
27
              y train,
28
              epochs=epochs,
29
              steps per epoch=steps per epoch)
```

Encrypted Predictions with Public Training



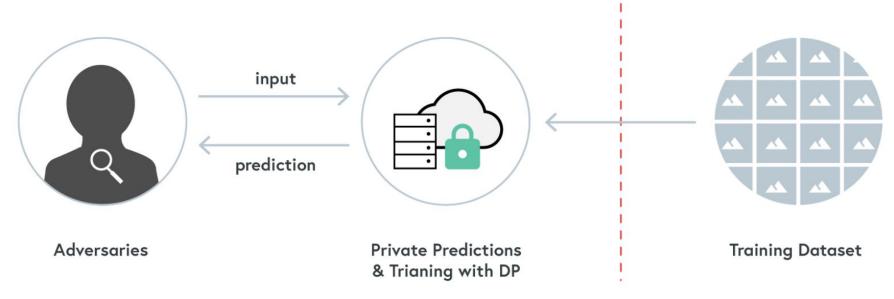
Using TFE Keras, users only share encrypted data to get the prediction

Encrypted Predictions with Public Training

```
import tensorflow as tf
    import tf encrypted as tfe
    # Define plaintext model with tf Keras
    model = tf.keras.Sequential([
            tf.keras.layers.Conv2D(16, 8,
 6
                                    strides=2.
 8
                                    padding='same',
                                    activation='relu',
 9
10
                                    batch input shape=input shape),
11
            tf.keras.layers.AveragePooling2D(2, 1),
12
            tf.keras.layers.Conv2D(32, 4,
13
                                    strides=2.
                                    padding='valid',
14
15
                                    activation='relu'),
16
            tf.keras.layers.AveragePooling2D(2, 1),
17
            tf.keras.layers.Flatten(),
            tf.keras.layers.Dense(32, activation='relu'),
18
19
            tf.keras.layers.Dense(10, name='logit')
20
      1)
    # load trained weights
    pre trained weights = 'short-dnn.h5'
    model.load_weights(pre_trained_weights)
25
   # create private model from tf Keras model
    tfe model = tfe.keras.models.clone model(model)
```

Encrypted Predictions After Public Training with Differential Privacy

- membership inference
- model inversion.

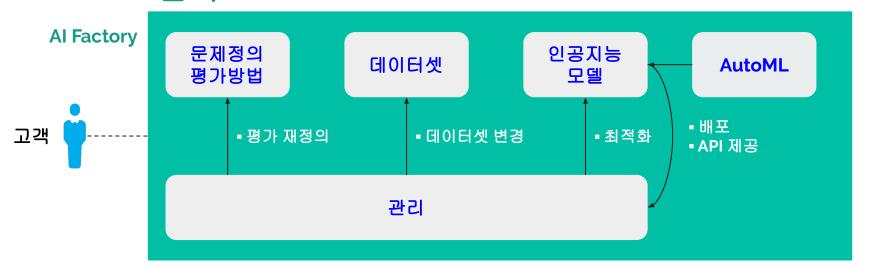


Differential Privacy prevents the model from memorizing sensitive data

Encrypted Predictions After Public Training with Differential Privacy

```
if FLAGS.dpsqd:
  ledger = privacy ledger.PrivacyLedger(
      population_size=60000,
      selection probability=(FLAGS.batch size / 60000))
  # Use DP version of GradientDescentOptimizer. Other optimizers are
  # available in dp optimizer. Most optimizers inheriting from
  # tf.train.Optimizer should be wrappable in differentially private
  # counterparts by calling dp_optimizer.optimizer_from_args().
  optimizer = dp_optimizer.DPGradientDescentGaussianOptimizer(
      12 norm clip=FLAGS.12 norm clip,
                                                                      else:
      noise multiplier=FLAGS.noise multiplier,
                                                                        optimizer = GradientDescentOptimizer(learning_rate=FLAGS.learning_rate)
                                                                        training_hooks = []
      num_microbatches=FLAGS.microbatches,
                                                                        opt loss = scalar loss
      ledger=ledger,
                                                                      global step = tf.compat.v1.train.get global step()
      learning rate=FLAGS.learning rate)
                                                                      train_op = optimizer.minimize(loss=opt_loss, global_step=global_step)
  training hooks = [
                                                                      # In the following, we pass the mean of the loss (scalar loss) rather than
      EpsilonPrintingTrainingHook(ledger)
                                                                      # the vector loss because tf.estimator requires a scalar loss. This is only
                                                                      # used for evaluation and debugging by tf.estimator. The actual loss being
                                                                      # minimized is opt loss defined above and passed to optimizer.minimize().
  opt loss = vector loss
                                                                      return tf.estimator.EstimatorSpec(mode=mode,
                                                                                                      loss=scalar loss.
                                                                                                     train_op=train_op,
                                                                                                     training hooks=training hooks)
```

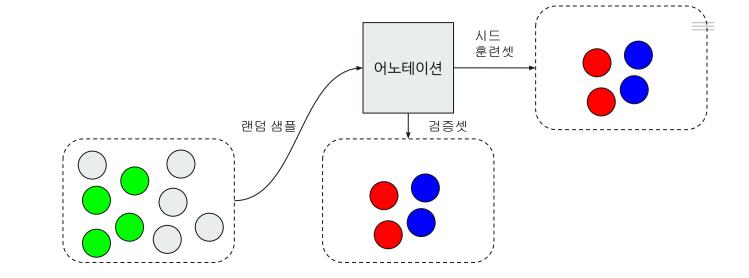
인공지능 모델 유지 관리 비용은 만만치 않다 >> 자동 관리

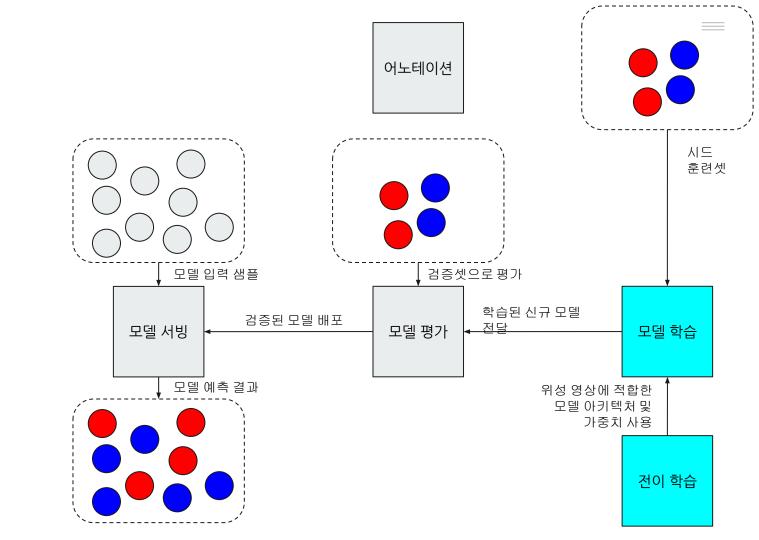


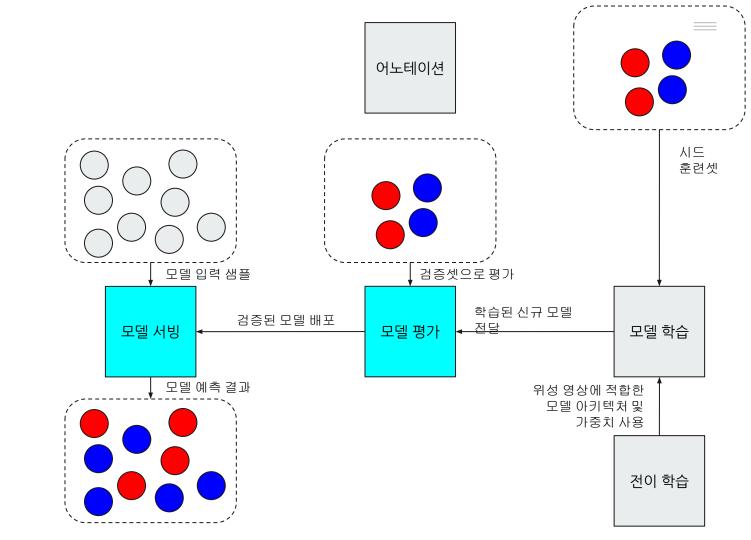
- 세 요소 중 하나가 변경 >> 자동으로 성능 업데이트
- 액티브/온라인 러닝 지원 >> 데이터셋 효율 생산 및 변경 관리
- 자동 하이퍼파라미터 튜닝 >> 모델 최적화
- 모델 배포 및 Open API 제공 >> 손쉬운 서비스 연계

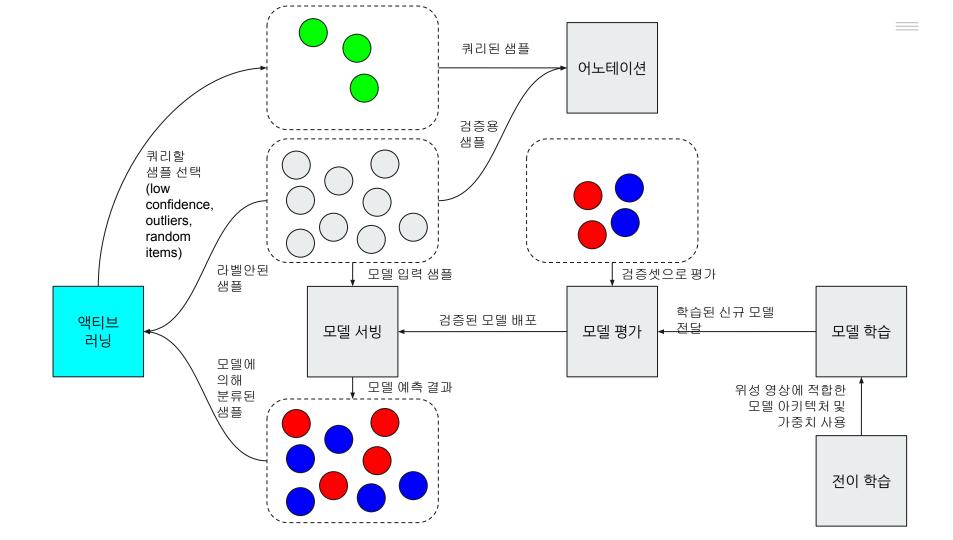
Active Learning

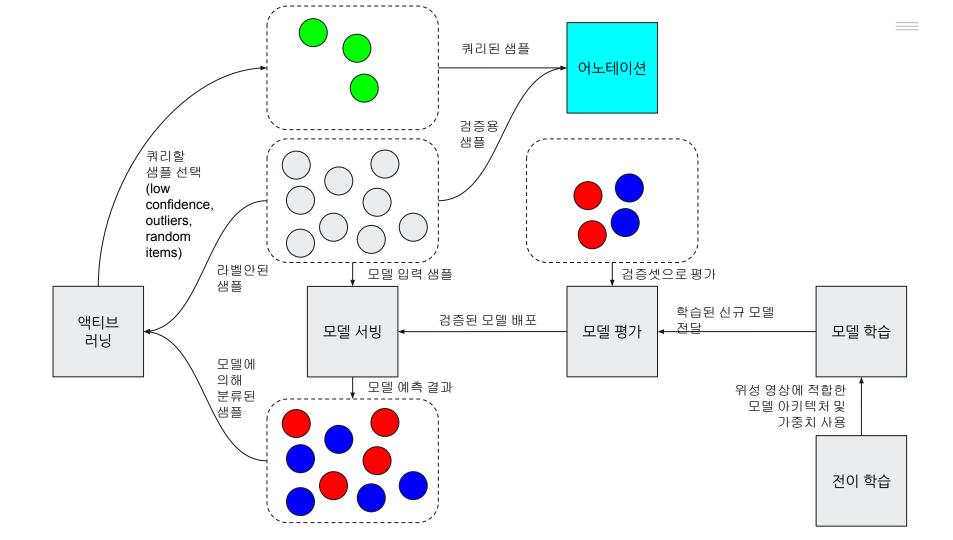
- 문제점
 - ㅇ 데이터셋 양이 방대하여 모두 라벨링을 하기에 제한이 있을 때
- 해결방안
 - 라벨링 돼있지 않은 데이터셋에 한하여 보다 효율적인 데이터에 한해 전문가에게 라벨링
 요청을 함
 - 효율적인 데이터를 판단하는 기준
 - https://inspaceai.github.io/2019/06/05/ActiveLearning_Introduction/
 - Cross-Entropy
 - Least Confidence
 - Margin Sampling

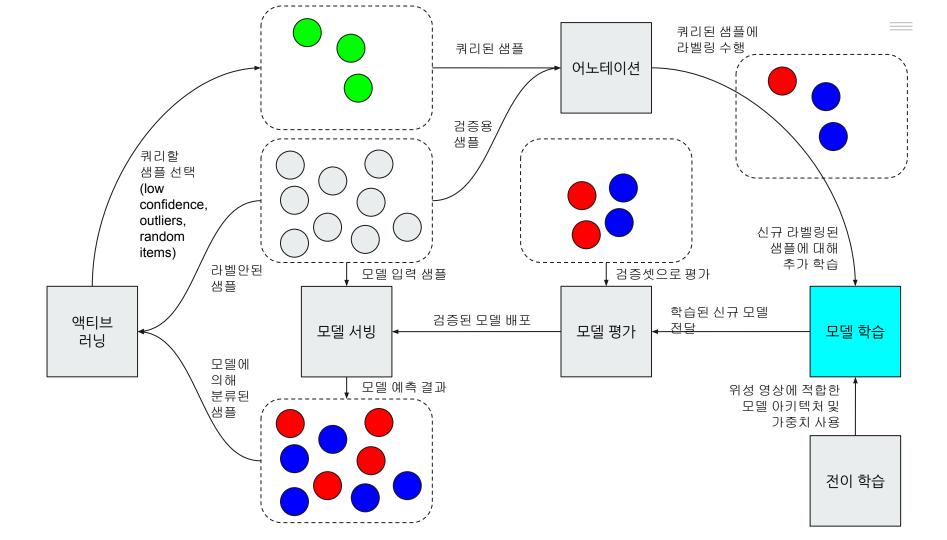


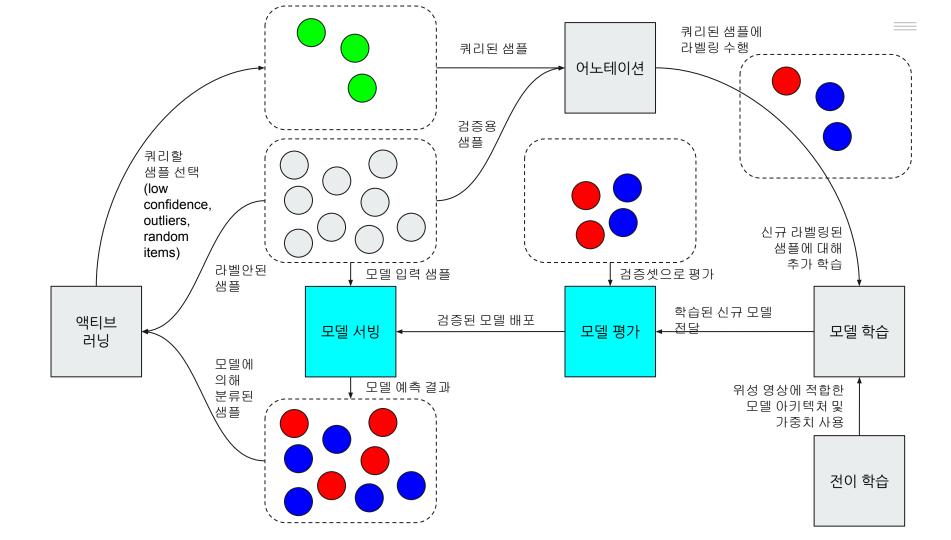


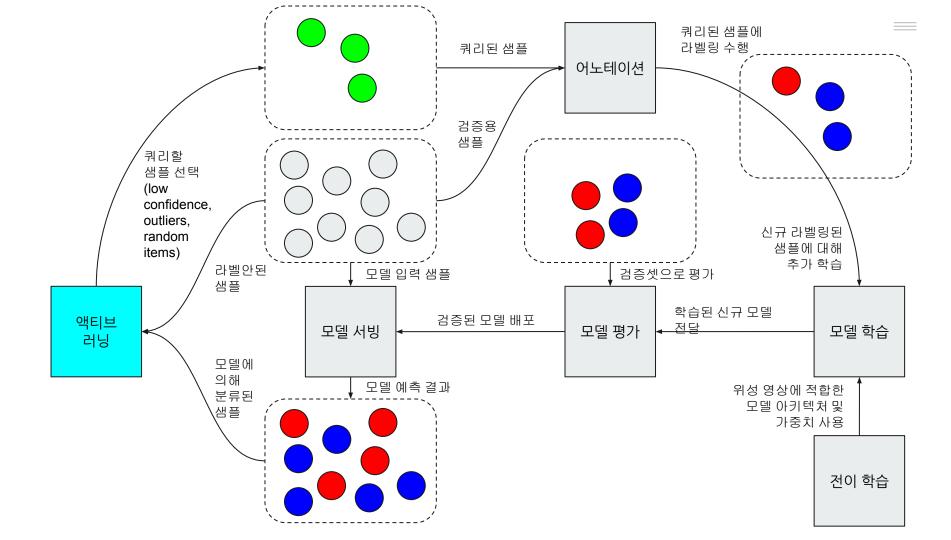


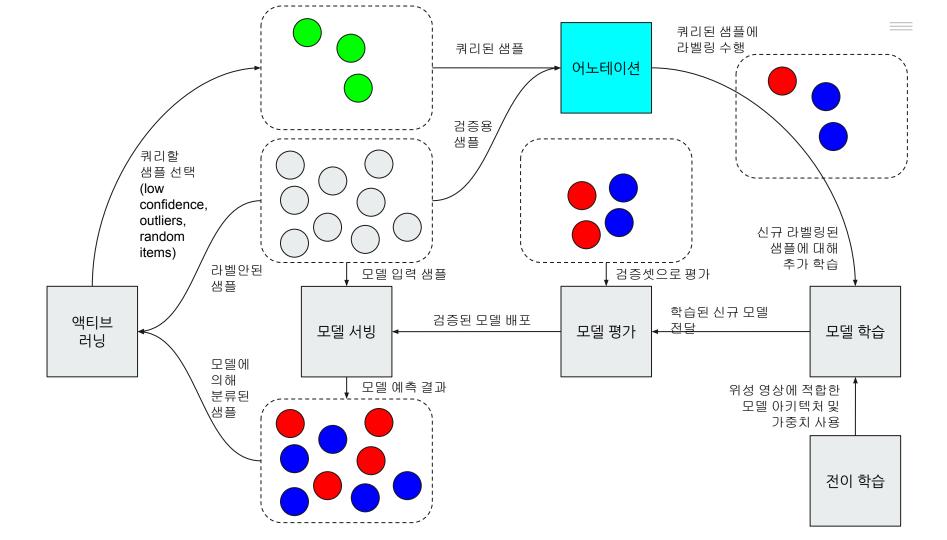






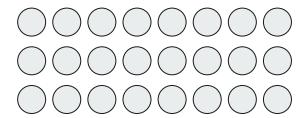






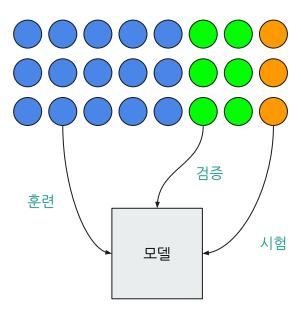
Online Learning

- 유사용어
 - Incremental Learning, Streaming Learning
- 문제점
 - 데이터 셋(라벨링 포함)이 너무 방대하여 하드웨어 자원이 부족할 때
 - 데이터 셋(라벨링 포함)이 스트리밍 형식으로 매 시간 생성될 때
- 해결방안
 - 메모리에 적재할 수 있는 만큼 가져와 배치학습 실시
 - 데이터 셋이 생성되는 대로 배치학습 실시

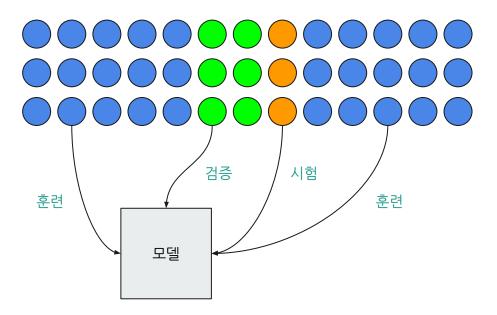


모델

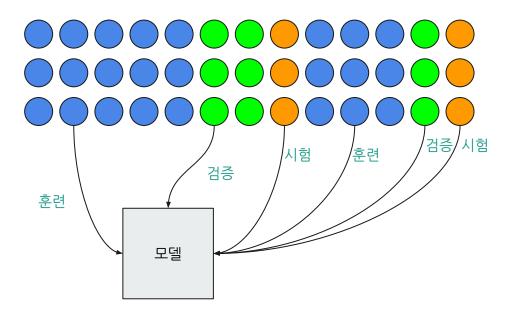




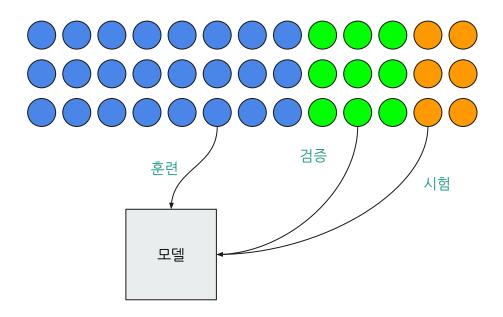




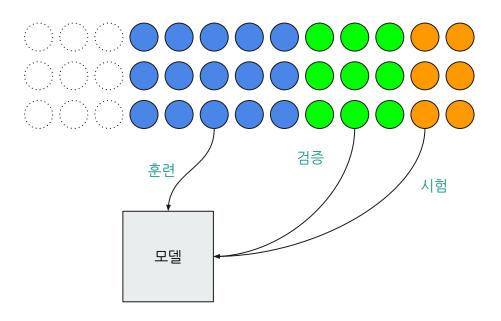






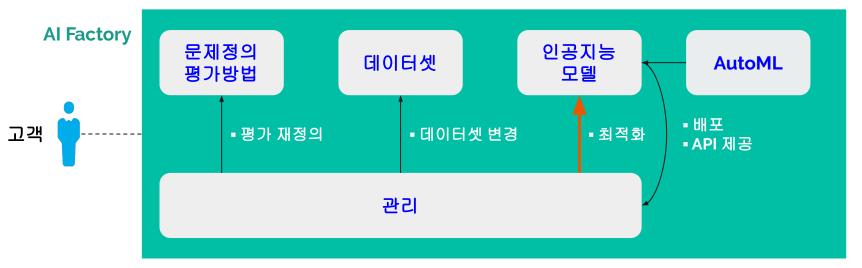






비지니스 모델 : 클라우드 기반 관리

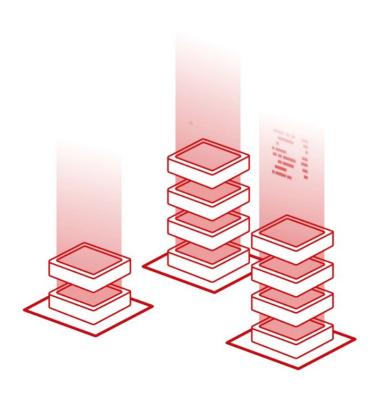
인공지능 모델 유지 관리 비용은 만만치 않다 >> 자동 관리



- 세 요소 중 하나가 변경 >> 자동으로 성능 업데이트
- 액티브/온라인 러닝 지원 >> 데이터셋 효율 생산 및 변경 관리
- 자동 하이퍼파라미터 튜닝 >> 모델 최적화
- 모델 배포 및 Open API 제공 >> 손쉬운 서비스 연계

Hyperparameter Tuning >> Keras Tuner

Keras Tuner Home Tutorials -Documentation -Examples ▼ **Contributing Guide** Q Search **←** Previous Next → C GitHub Keras Tuner documentation **Keras Tuner documentation** Installation Usage: the basics Installation The search space may contain Requirements: conditional hyperparameters · Python 3.6 You can use a HyperModel TensorFlow 2.0 subclass instead of a modelbuilding function Install latest release: Keras Tuner includes pre-made tunable applications: HyperResNet pip install -U keras-tuner and HyperXception Install from source: You can easily restrict the search space to just a few parameters git clone https://github.com/keras-team/keras-tuner.git About parameter default values



Getting the optimal model requires to tune many inter-dependent parameters

```
model = Sequential()
model.add(Conv2D(32, kernel size=(3, 3), activation='relu',
  input shape=(28, 28, 1))
model.add(Conv2D(64, kernel size=(3, 3), activation='relu'))
model.add(Flatten())
model.add(Dense(20, activation='relu'))
model.add(Dropout(0.2))
model.add(Dense(10, activation='softmax'))
model.compile(loss='categorical crossentropy',
  optimizer=Adam(0.001))
model.summary()
```

- 첫번째 Conv2D의 필터 수 : L1_NUM_FILTERS
- 두번째 Conv2D의 필터 수 : L2_NUM_FILTERS
- Dense Dropout 은닉층의 반복횟수 : NUM_LAYERS
- Dense 레이어의 출력뉴런 수 : NUM_DIMS
- Dropout 레이어의 드랍율 : DROPOUT_RATE
- 최적화기의 학습률 : LR

```
LR = Choice('learning_rate', [0.001, 0.0005, 0.0001],
   group='optimizer')

DROPOUT_RATE = Linear('dropout_rate', 0.0, 0.5, 5,
   group='dense')

NUM_DIMS = Range('num_dims', 8, 32, 8, group='dense')

NUM_LAYERS = Range('num_layers', 1, 3, group='dense')
```

L2 NUM FILTERS = Range('12 num filters', 8, 64, 8,

L1 NUM FILTERS = Range('l1 num filters', 8, 64, 8,

group='cnn')

group='cnn')

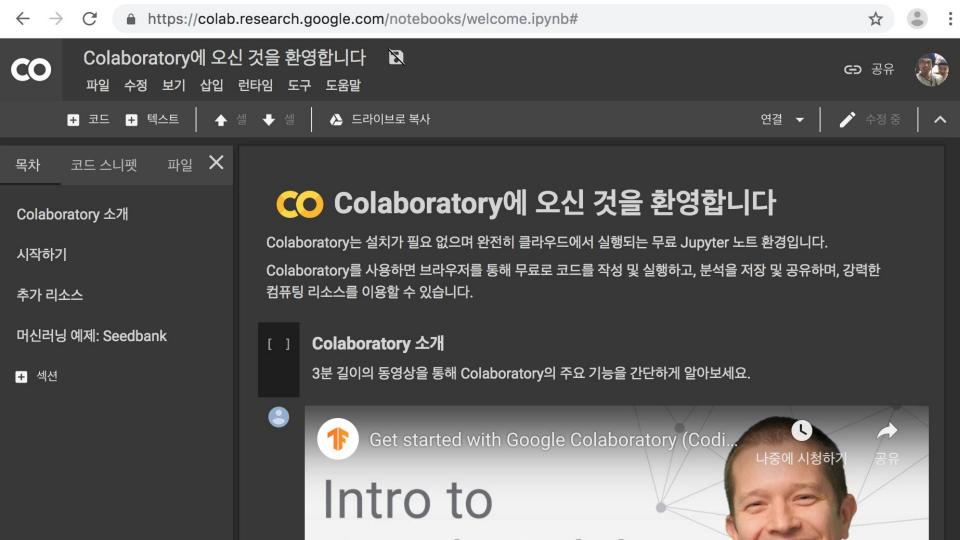
```
def model fn():
    LR = Choice('learning rate', [0.001, 0.0005, 0.0001],
        group='optimizer')
    DROPOUT RATE = Linear ('dropout rate', 0.0, 0.5, 5,
        group='dense')
    NUM DIMS = Range('num dims', 8, 32, 8, group='dense')
    NUM LAYERS = Range('num layers', 1, 3, group='dense')
    L2 NUM FILTERS = Range('12 num filters', 8, 64, 8,
        group='cnn')
    L1 NUM FILTERS = Range('11 num filters', 8, 64, 8,
        group='cnn')
```

```
model = Sequential()
model.add(Conv2D(L1 NUM FILTERS, kernel size = (3, 3), activation='relu'))
model.add(Conv2D(L2 NUM FILTERS, kernel size = (3, 3), activation='relu'))
model.add(Flatten())
for in range(NUM LAYERS):
    model.add(Dense(NUM DIMS, activation = 'relu'))
    model.add(Dropout(DROPOUT RATE))
model.add(Dense(10, activation='softmax'))
model.compile(loss='categorical crossentropy', optimizer=Adam(LR))
```

return model

```
tuner = Tuner(model_fn, 'val_accuracy' epoch_budget=500,
    max_epochs=5)
```

tuner.search(train data, validation data=validation data)



```
1 !pip install git+https://github.com/keras-team/keras-tuner.git
```

Cloning https://github.com/keras-team/keras-tuner.git to /tmp/pip-req-build-mg0

Running command git clone -q https://github.com/keras-team/keras-tuner.git /tmp

Requirement already satisfied: tensorflow>=2.0.0-betal in /usr/local/lib/python3.

Requirement already satisfied: numpy in /usr/local/lib/python3.6/dist-packages (f Requirement already satisfied: tabulate in /usr/local/lib/python3.6/dist-packages Requirement already satisfied: colorama in /usr/local/lib/python3.6/dist-packages Requirement already satisfied: tqdm in /usr/local/lib/python3.6/dist-packages (fr Requirement already satisfied: requests in /usr/local/lib/python3.6/dist-packages Successfully built Keras-Tuner

Successfully uninstalled Keras-Tuner-0.9.0.1561748737 Successfully installed Keras-Tuner-0.9.0.1561755703

Uninstalling Keras-Tuner-0.9.0.1561748737:

Found existing installation: Keras-Tuner 0.9.0.1561748737

Installing collected packages: Keras-Tuner

1 from tensorflow import keras
2 from tensorflow.keras import layers
3
4 import numpy as np
5
6 from kerastuner.tuners import RandomSearch

7 from kerastuner.engine.hypermodel import HyperModel

8 from kerastuner.engine.hyperparameters import HyperParameters

```
1 (x, y), (val_x, val_y) = keras.datasets.mnist.load_data()
2 x = x.astype('float32') / 255.
3 val x = val x.astype('float32') / 255.
```

4

5 x = x[:10000]6 y = y[:10000]

```
1 """Basic case:
 2 - We define a `build model` function
 3 - It returns a compiled model
 5
 6 def build model(hp):
      model = keras.Sequential()
 8
       model.add(layers.Flatten(input shape=(28, 28)))
 9
       for i in range(hp.Range('num layers', 2, 20)):
10
           model.add(layers.Dense(units=hp.Range('units ' + str(i), 32, 512, 32),
11
                                   activation='relu'))
      model.add(layers.Dense(10, activation='softmax'))
12
13
      model.compile(
           optimizer=keras.optimizers.Adam(
14
15
               hp.Choice('learning rate', [1e-2, 1e-3, 1e-4])),
16
           loss='sparse categorical crossentropy',
           metrics=['accuracy'])
17
18
       return model
```

```
1 """Basic case:
2 - It uses hyperparameters defined on the fly
  tuner = RandomSearch(
      build model,
      objective='val accuracy',
8
      max trials=5,
      executions_per_trial=3,
10
      directory='test dir')
11
```

```
|-Default search space size: 4
                                                    num_layers (Range)
                                                    |-default: 2
                                                    |-min_value: 2
  tuner.search_space_summary()
                                                    units_O (Range)
  tuner.search(x=x,
                                                    |-default: 32
                      y=y,
5
                      epochs=3,
                                                    |-min_value: 32
6
                      validation data=(val
                                                    units_1 (Range)
  tuner.results_summary()
                                                    |-default: 32
                                                    |-min_value: 32
                                                    learning_rate (Choice)
                                                    |-default: 0.01
```

Search space summary

New model

Trial summary

Hp values:

|-learning_rate: 0.01

|-num_layers: 15

|-units_0: 288

|-units_1: 320

validati Execution 1/3

WARNING: Logging before flag parsing goes t W0628 21:03:56.702659 140279821547392 depre

Instructions for updating:

Use tf.where in 2.0, which has the same bro HBox(children=(IntProgress(value=0, max=313))

HBox(children=(IntProgress(value=0, max=313

```
1 tuner.search space s
 tuner.search(x=x,
                y=y,
5
                epochs:
                validat
6
 tuner.results summa:
```

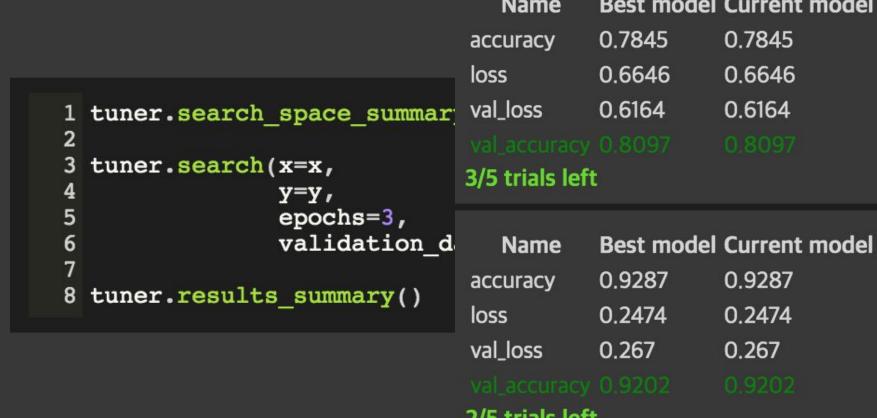
Execution 3/3

HBox(children=(IntProgress(value=0, max=313),

HBox(children=(IntProgress(value=0, max=313),

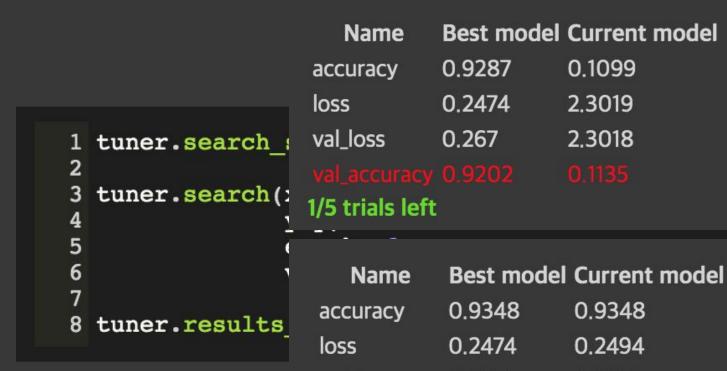
HBox(children=(IntProgress(value=0, max=313),

	Name	Best model	Current model
	accuracy	0.5377	0.5377
	loss	1.1953	1.1953
	val_loss	1.2095	1.2095
ı			0.5524



Best model	Current model				
0.7845	0.7845				
0.6646	0.6646				
0.6164	0.6164				
3/5 trials left					
	0.7845 0.6646 0.6164 0.8097				

0.9287	0.9287				
0.2474	0.2474				
0.267	0.267				
2/5 trials left					
	0.2474 0.267 0.9202				



 val_loss
 0.267
 0.3198

 val_accuracy
 0.9229
 0.9229

Hypertuning complete - results in test_dir/untitled_project

val_accuracy 0.9229 0.9229

Hypertuning complete - results in test_dir/untitled_project

```
Results summary

| -Results in test_dir/untitled_project |
| -Ran 5 trials |
| -Ran 15 executions (3 per trial) |
| -Best val_accuracy: 0.9229 |
```

You can use a HyperModel subclass instead of a model-building function

This makes it easy to share and reuse hypermodels.

A HyperModel subclass only needs to implement a build(self, hp) method.

```
from kerastuner import HyperModel
class MyHyperModel(HyperModel):
    def __init__(self, num_classes):
        self.num_classes = num_classes
    def build(self, hp):
        model = keras.Sequential()
        model.add(layers.Dense(units=hp.Range('units',
                                              min value=32,
                                              max value=512.
                                              step=32).
                               activation='relu'))
        model.add(layers.Dense(self.num_classes, activation='softmax'))
        model.compile(
            optimizer=keras.optimizers.Adam(
                hp.Choice('learning_rate',
```

```
model.add(layers.bense(selt.num_classes, activation='sortmax'))
        model.compile(
            optimizer=keras.optimizers.Adam(
                hp.Choice('learning_rate',
                          values=[1e-2, 1e-3, 1e-4])),
            loss='sparse_categorical_crossentropy',
            metrics=['accuracy'])
        return model
hypermodel = MyHyperModel(num_classes=10)
tuner = RandomSearch(
    hypermodel,
    objective='val_accuracy',
    max trials=10,
    directory='my_dir',
    project_name='helloworld')
tuner.search(x, y,
             epochs=5,
             validation_data=(val_x, val_y))
```

Keras Tuner includes pre-made tunable applications: HyperResNet and HyperXception

These are ready-to-use hypermodels for computer vision.

They come pre-compiled with loss="categorical_crossentropy" and metrics=["accuracy"].

```
from kerastuner.applications import HyperResnet
from kerastuner.tuners import Hyperband
hypermodel = HyperResnet(input_shape=(128, 128, 3), num_classes=10)
tuner = Hyperband(
    hypermodel,
    objective='val_accuracy',
   max_trials=40,
    directory='my_dir',
    project name='helloworld')
tuner.search(x, y,
             epochs=20,
             validation data=(val x, val y))
```

Help | Advanced Search

Search...

arXiv.org > cs > arXiv:1603.06560

Computer Science > Machine Learning

Hyperband: A Novel Bandit-Based Approach to **Hyperparameter Optimization**

Lisha Li, Kevin Jamieson, Giulia DeSalvo, Afshin Rostamizadeh, Ameet **Talwalkar**

(Submitted on 21 Mar 2016 (v1), last revised 18 Jun 2018 (this version, v4))

Performance of machine learning algorithms depends critically on identifying a good set of hyperparameters. While recent approaches use Bayesian optimization to adaptively select configurations, we focus on speeding up random search through adaptive resource allocation and early-stopping. We formulate hyperparameter optimization as a pure-exploration non-stochastic infinite-armed bandit problem where a predefined resource like iterations, data samples, or features is allocated to randomly sampled configurations. We introduce a novel algorithm, Hyperband, for this framework and analyze its theoretical properties, providing several desirable

Download:

- PDF
- Other formats (license)

Current browse context: cs.LG

< prev next > new | recent | 1603

Change to browse by:

CS

stat

stat.ML

References & Citations

NASA ADS

3 blog links (what is this?) DBLP - CS Bibliography

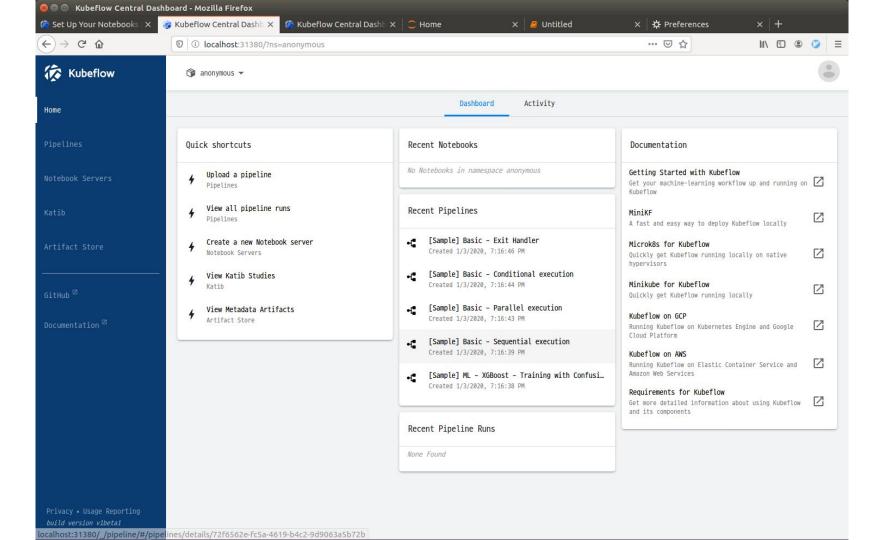
guarantees. Furthermore, we compare Hyperband with popular Bayesian optimization mothods on a suite of hyperparameter entimization problems. We observe that

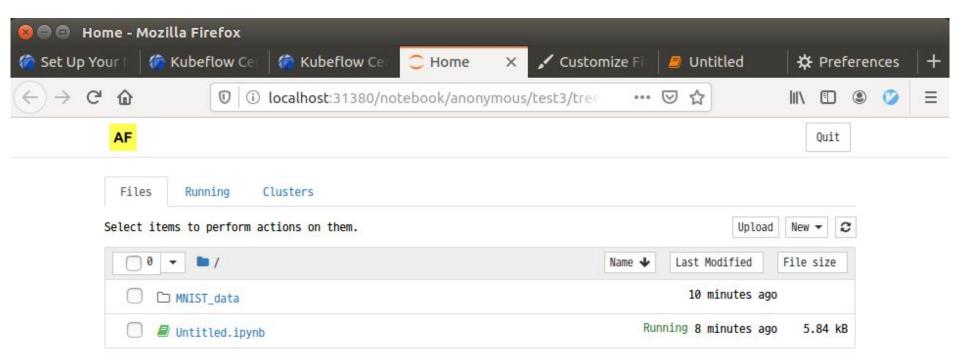
Keras Tuner includes pre-made tunable applications: HyperResNet and HyperXception

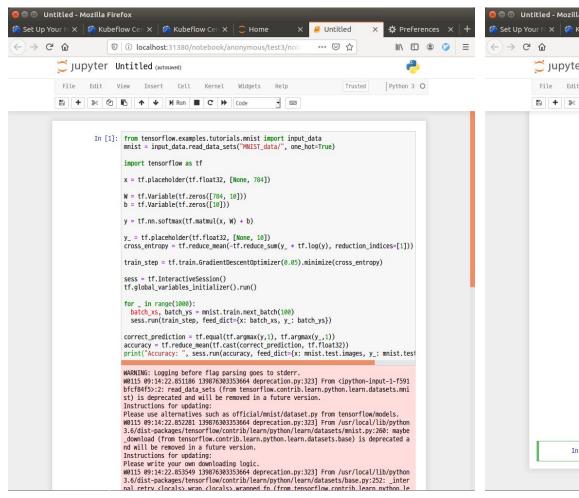
These are ready-to-use hypermodels for computer vision.

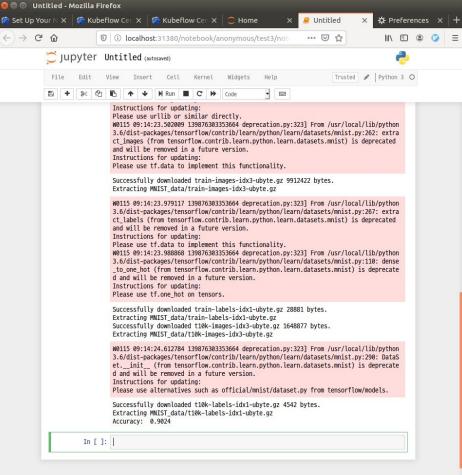
They come pre-compiled with loss="categorical_crossentropy" and metrics=["accuracy"].

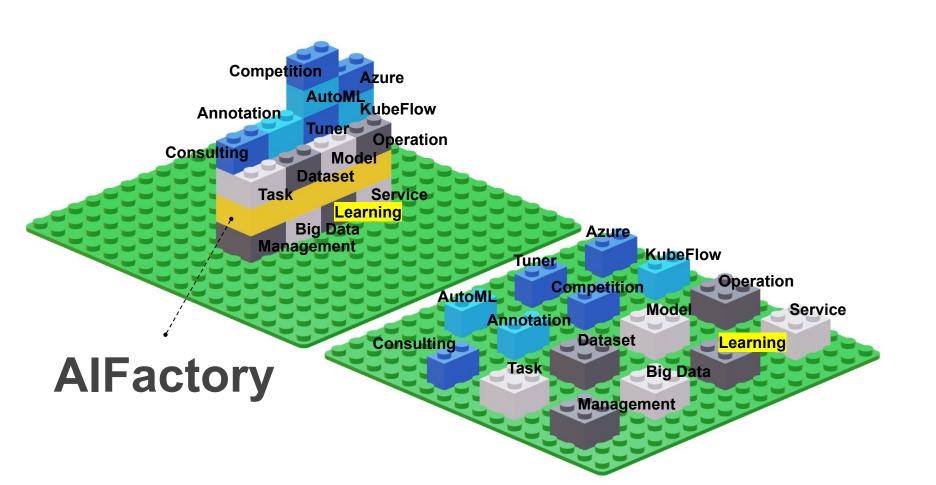
```
from kerastuner.applications import HyperResnet
from kerastuner.tuners import Hyperband
hypermodel = HyperResnet(input_shape=(128, 128, 3), num_classes=10)
tuner = Hyperband(
    hypermodel,
    objective='val_accuracy',
   max_trials=40,
    directory='my_dir',
    project name='helloworld')
tuner.search(x, y,
             epochs=20,
             validation data=(val x, val y))
```

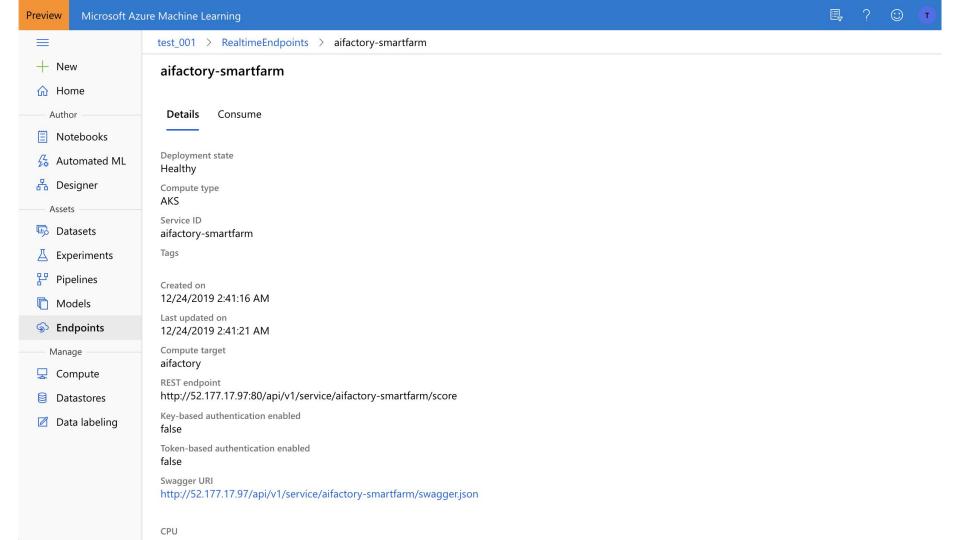


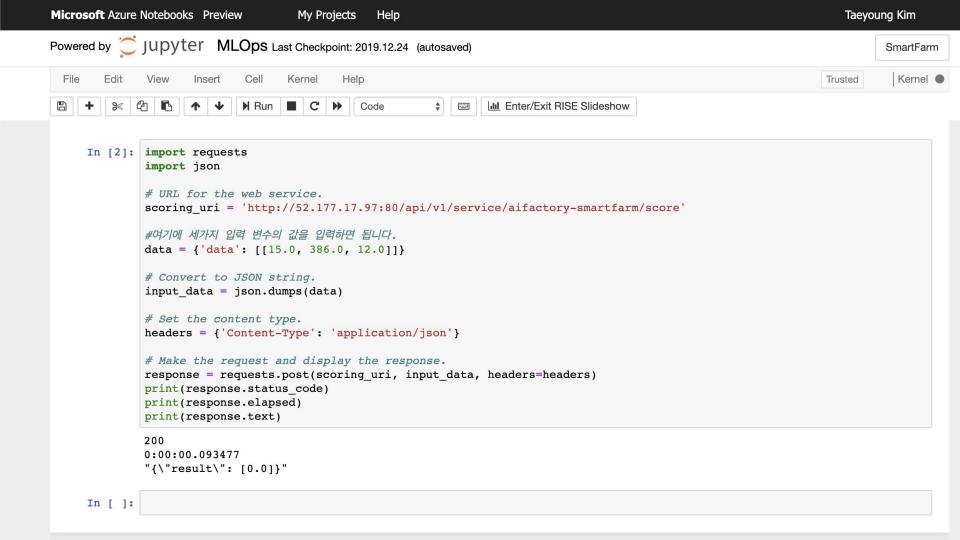


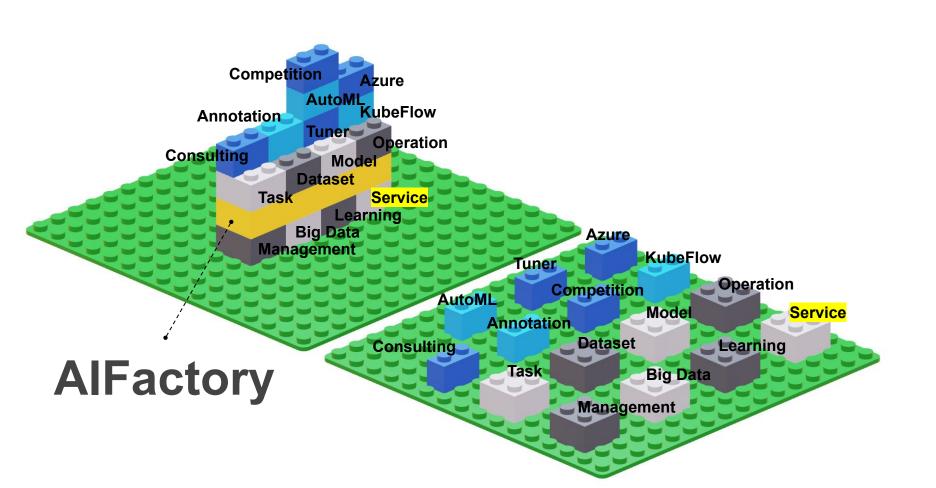












AlFactory Artificial Intelligence Factory for You AlFactory

- 크라우드 소싱 협업
- AutoML
- 데이터셋 보안
- 모델 및 데이터셋 관리
- 클라우드서비스

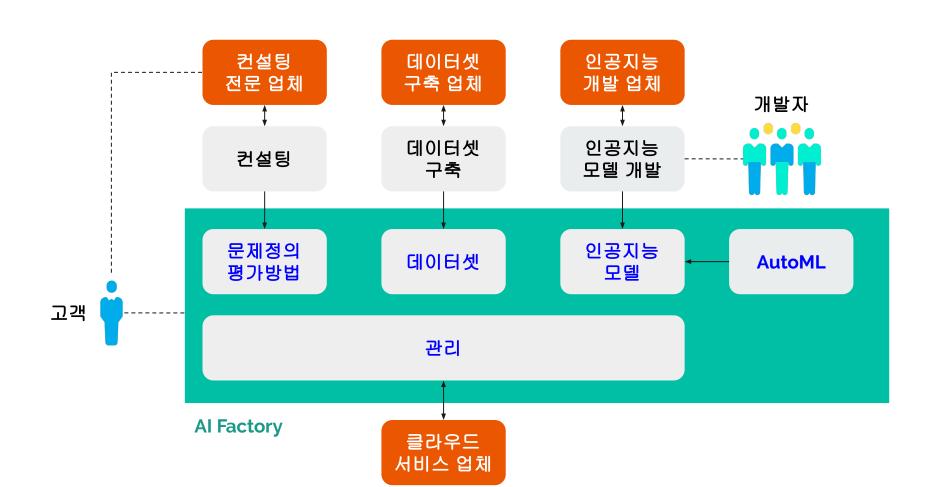


 \equiv

생태계 형성

유연한 협업과 올인원 서비스 제공

시장에서의 유연한 헙업 방식



Al Factory 실제 사례

차세대 의료 진단기술을 위한 인공지능 기술 도입

New IVD system (VEUS)

GIVE CONCERNS, TAKE HEALTH

Versatile, Easy, and User-friendly IVD System

이지다이아텍의 VEUS 기술은 30분 이내에 빠르고 정확한 면역 분석을 수행할 수 있는 완전 자동 ALL IN ONE 시스템을 제공합니다.

효소 면역측정법(ELISA), 형광 면역측정법(FIA), 화학발광 면역측정법(Chemiluminescence Immunoassay, CLIA)과 같은 기존의 면역측정법은

정밀면역검사법으로 사용되고 있지만, 검사시간이 3~4시간 정도 소요되고, 검사장비가 고가이며, 검사를 수행할 전문 인력이 필요해서 중소병원에는 적합하지 않습니다.

VEUS 시스템은 30분내에 정확한 검사결과가 나오며, 누구나 손쉽게 조작할 수 있는 완전자동시스템이므로, 중소병원 및 응급실에 적합합니다.



1 짧은 예열시간

1~2분안에 37°C 도딜

2 효과적인 Heating & Mixing 기술

자성입자의 특성을 살린 시스템

3 다중검지 시스템

독창적인 자성입자 코딩 시스템

4 All in one system

추가 검진기기가 필요없이 진단결과도출

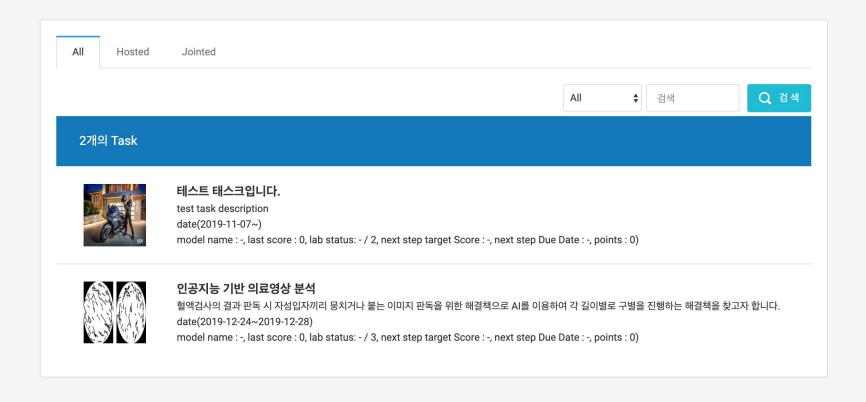
검색

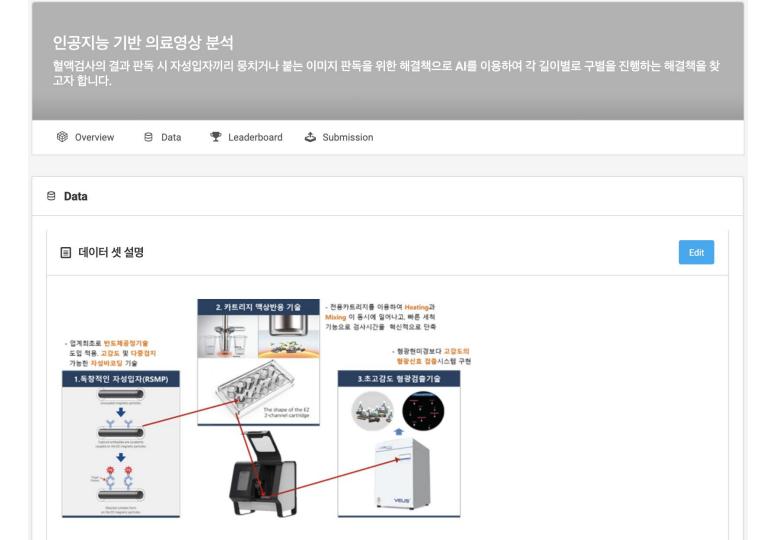
로그인

Q

회원가입

Task



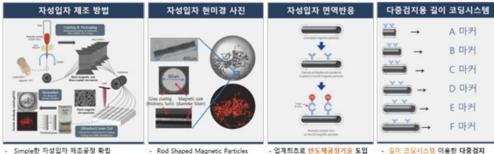


• 상기와 같이 혈액검사에 적합한 시스템 기술을 개발하여 현재 상용화를 진행하고 있으며 해당 기술은 빠른검사, 정확함, 고감도, 다중검지(multi-detection)의 기술적 특징을 가지며 그 중 에서도 다중검지를 위하여 자성입자를 활용하고 있음.



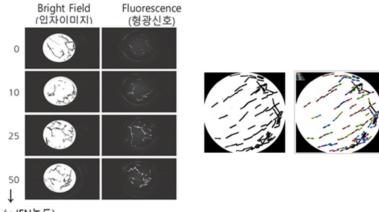
• 해당 시스템의 기술적 특징을 활용하여 상기와 같이 고감도의 다중검지 기능을 활용다면 보다 저렴한 비용과 짧은 시간을 가지고 신속하고 정확하게 진단을 내릴 수 있음.

자성입자 제조 및 진단도입

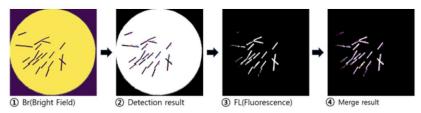


- Simple한 자성입자 제조공정 확립
- 다른 자성입자에 비해 재현성/생산성 개선
- Surface Chemistry 최적화 완성
- Rod Shaped Magnetic Particles - 거대 자성입자 (길이 200~500
 - 지름 60 um. Silica coating : 5
- 길이 코딩시스템 이용한 다중검지
 - 다양한 Multiplex 가능
- 신호 중폭효과 통한 고감도 기능 Duplex, Triplex, Sixplex 등
- 강한 Magnetic Power

• 상기와 같이 자성입자를 제조하며 최대 7가지 길이로 구별하도록 하여 다중검지를 실시할 수 있으며 이를 위하여 형광촬영 된 이미지에서 각 길이별로 구별하여 형광값을 읽어와야 함.



- (γ-IFN농도)
- 혈액검사의 결과 판독은 상기 그림의 Bright Field의 이미지에서 각 길이별 자성입자를 구별 탐색한 정보를 가지고 형광신호 이미지에서 각 자성입자의 위치에 해당하는 형광신호 값을 판독하여 혈액검사 결과를 도출하도록 하고 있음.
- 이러한 방법을 통하여 자성입자 판독을 진행할 때의 어려움으로 자성입자의 자성 때문에 생기는 문제가 있음.
- 각 자성입자가 띄는 자성 때문에 자성입자끼리 뭉치거나 붙는 현상이 있으며 이러한 현상 때문에 현재 Bright Filed 에서의 각 길이별 자성입자의 구별에 어려움이 있어 이를 위한 해결책으로 AI를 이용하여 각 길이별로 구별을 진행하는 해결책을 찾고 있음.



- 현재 형광값의 산출은 상기 그림에서 ①에서와 같이 카트리지에 있는 자성입자의 BR 이미지를 획득하여 ③과 같이 자성입자의 위치를 찾고 ③과 같은 FL 이미지에 합쳐서 ④과 같은 최종 결과에서 원하는 자성입자의 형광 값을 읽어 들임.
- 상기의 사진은 500um 길이의 자성입자의 예이며 이 경우에도 ③ 과 같이 검색하지 못하는 부분이 있으며 단일 크기가 아닌 7가지 길이의 자성입자를 혼합하는 경우 검색하지 못하는 부분이 상대적으로 많아지며 이의 대응을 위하여 AI를 이용하는 해법을 모색하고자 함.

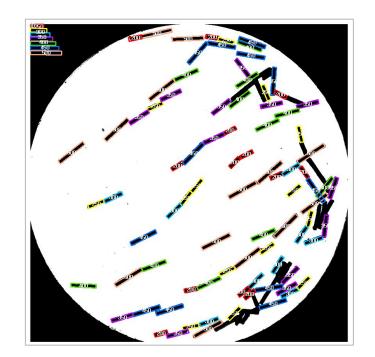
❖ 데이터 셋 분배

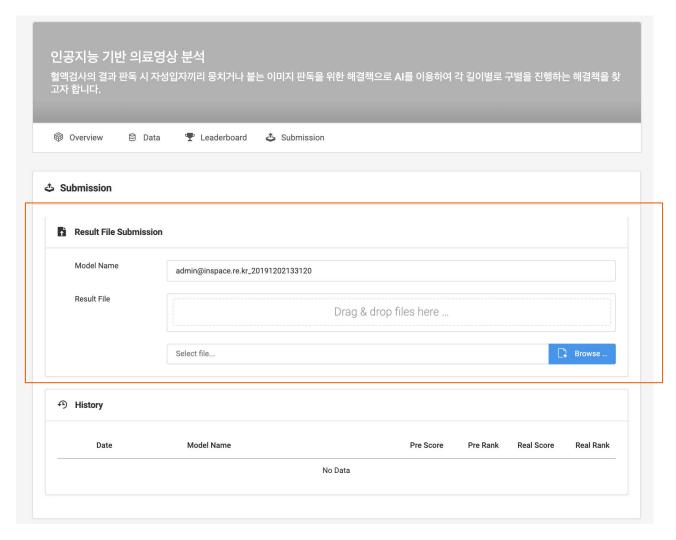
Baseline	Competition	Data Set
Train & Val	-	400
Test	Public	50
	Private	50

❖ 데이터 셋 구축

- ➤ Data set 500장 구축
- ➤ 라벨링 작업 (86/105)
- ➤ 작업시간:100분 ± α (86/105)
- ➤ 400장 Train & Val
- ➤ 100장 Test (Public:50장, Private:50장)

인원	1일 작업량(장)	총 작업량(장)	예상기간(일)
1	5	500	100
2	10	500	50
3	15	500	33
4	20	500	25

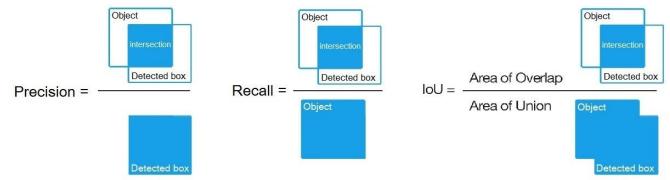




- 자신이 만든 모델의 결과 파일 제출 시 시스템에서 점수 계산
- 공정한 경쟁을 위해 정답지 유출 방지를 위한 문제 구성

평가방법

• 점수 계산 방식



• 점수 상황판 공개

Ÿ Pul	blic Leaderboard	Private Leaderboard			
이 점수 현황은 테스트 데이터의 약 50% 로 계산됩니다.					
No.	UserName	TeamName	Score	Last	lap
1	전인택	-	82	2019-11-18 10:56:17	2/2
2	전인택	-	14	2019-11-07 16:55:59	1/2



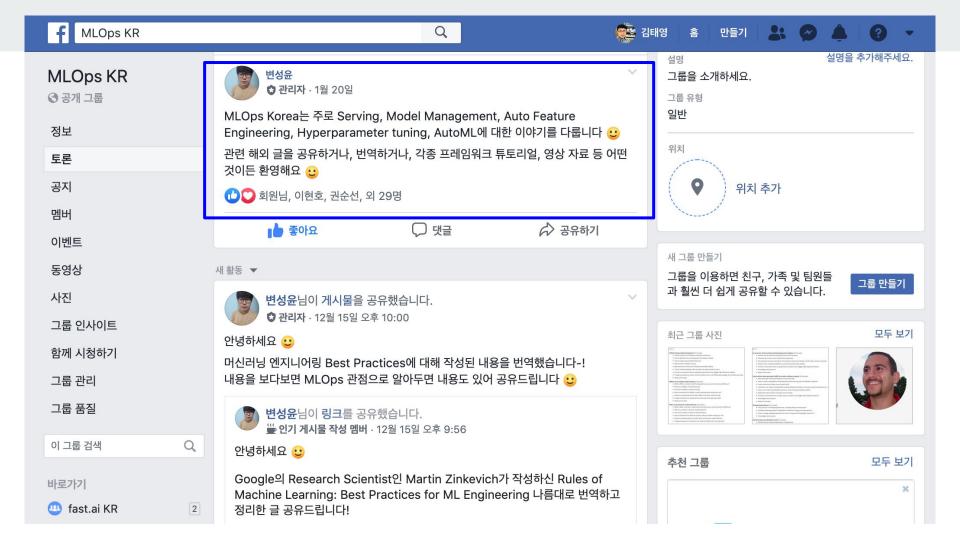
Community > Al > Al Friends



출연연/산업체/대학 중심의 산업 AI 연구 교류 모임입니다.

Tasks

TREND	TASK	MODEL	DESCRIPTION	SCORE	STATUS
20. 20. 20. 20. 20.	최적설계	DesignNetv2	GAN based image generation model	0.76	Open
20. 20 20 20 20	Anomaly Detection	AnoNetv3	Auto Encoder	0.45	Close



감사합니다.

