MELTINGCON

COMMUNITY

ALLIANCE

BigData Scale Deep learning

on Spark & Horovod , etc…

Hoon Dong Kim

Korea Spark User Group

hoondongkim@gmail.com

I am ...

MELTINGCON
COMMUNITY
ALLIANCE

- 김훈동
- 스사모(Korea Spark User Group) 운영진
- 신세계 그룹 온라인 포털 SSG.COM 빅데이타파트 리더
- Hadoop, Spark, Machine Learning, Azure ML 분야 Microsoft MVP(Most Valuable Professional)
- http://hoondongkim.blogspot.kr
- https://www.facebook.com/kim.hoondong

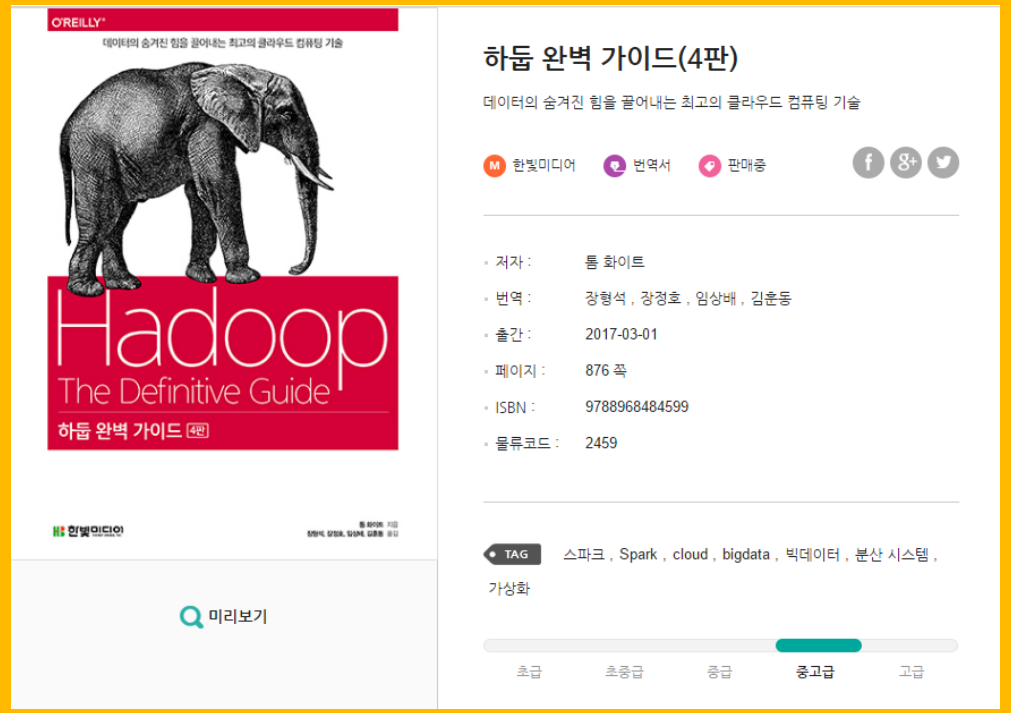

오늘의 주제

MELTINGCON
COMMUNITY
ALLIANCE

[1] Public Cloud

[2] BigData

[3] AI > Machine Learning > Deep Learning

- [1]을 만난 [2] 에 대하여
- [2]와 결합한 [3]에 대하여

오늘의 주제를 다시보자

MELTINGCON
COMMUNITY
ALLIANCE

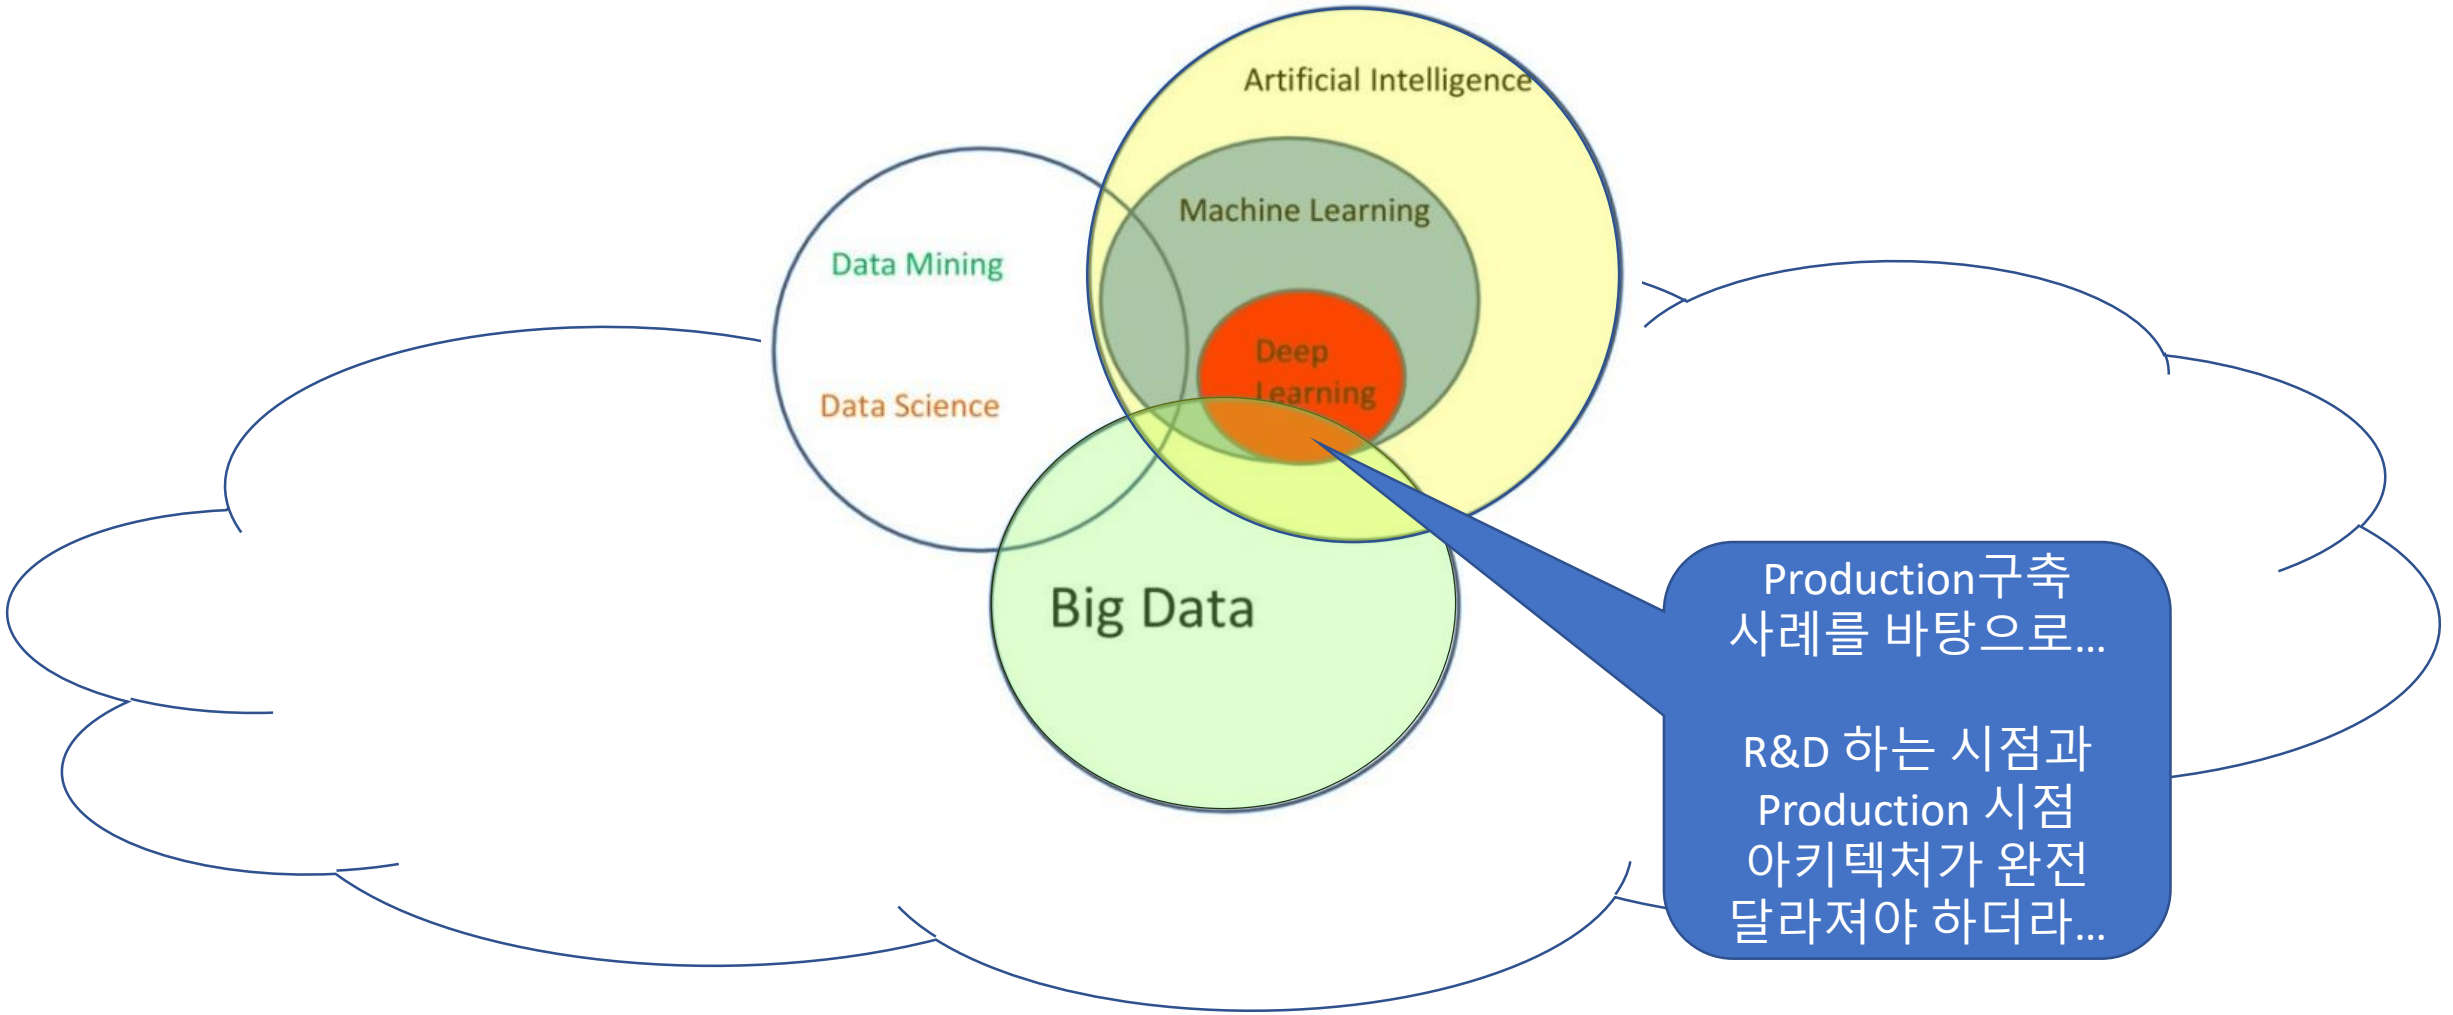

MELTINGCON
COMMUNITY
ALLIANCE

BigData Scale Deep Learning을

논하고자 한다면....

MELTINGCON
COMMUNITY
ALLIANCE

BigData Scale Deep Learning!

1. Scale Out Training 에 대하여…
2. Scale Out Serving 에 대하여…

차례

MELTINGCON
COMMUNITY
ALLIANCE

MELTINGCON
COMMUNITY
ALLIANCE

Motive!

그건 왜 하려고 하는데??

Motive 및 우리가 목표하는 것들...

MELTINGCON
COMMUNITY
ALLIANCE

알리바바, 광군제 주문 폭주 'AI·로봇'으로 대응했다

송고시간 | 2017/11/12 12:15

주문 단계에서 알리바바의 AI는 개인 맞춤형 추천 상품을 제시해 소비자의 결정을 돕고 재고를 관리한다.

시스템 개발을 책임지는 엔지니어 차이샤오우는 "우리는 소매업자가 판매량을 늘리는 데 AI가 더 효율적일 것이라고 확신한다"며 " 수많은 브랜드와 변수를 고려해 추천 상품을 선정하는 데 있어 노련한 패션업계 전문가보다 빅데이터와 AI가 더 탁월한 능력을 보인다"고 말했다.

알리바바는 고객 상담에도 AI를 적극적으로 활용하고 있다.

알리바바의 고객 상담용 챗봇인 '디엔샤오미'(電小秘)는 고객이 문의하는 내용의 90% 이상을 이해할 수 있으며, 하루에 350만 명의 고객을 상담할 수 있다.

알리바바의 제품 관리자 류지엔룽은 "모든 상담을 AI가 대신할 수는 없지만, 광군제처럼 단시간에 문의가 급증할 때는 큰 도움이 된다"며 "최신 버전은 상담 과정에서 나타난 고객의 감정까지 읽을 수 있다"고 전했다.

고객의 제품 주문이 이뤄지면 포장과 운송은 로봇이 담당한다.

알리바바의 물류 자회사 차이냐오(菜鳥)가 중국 남부 선전(深천<土+川>) 인근 휘저우(徽州)에 새로 개장한 자동화 물류 창고에서는 약 200대의 로봇이 24시간 일하고 있다.

알리바바 광군절 매출 27.5조, 8억 5,120만 건 주문

Posted 2017. 11. 13 오전 8:59:58

14만 개 이상의 브랜드에서 1,500만 가지 상품이 알리바바 광군절 이벤트에 참가했다. 알리바바는 인공지능 상품 추천 알고리즘, 알리페이 결제, 알리 클라우드 결제 시스템 등 자사 기술을 총 동원했다.

아마존 개인화

김** 로그인

동일 시점

박** 로그인

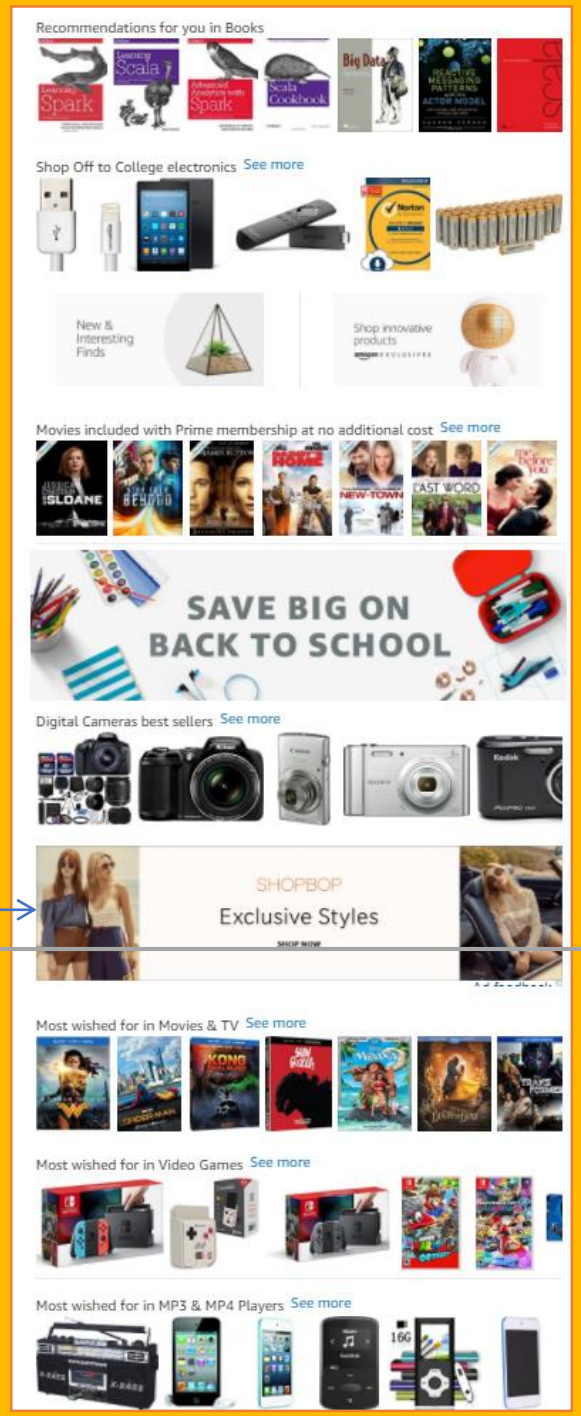

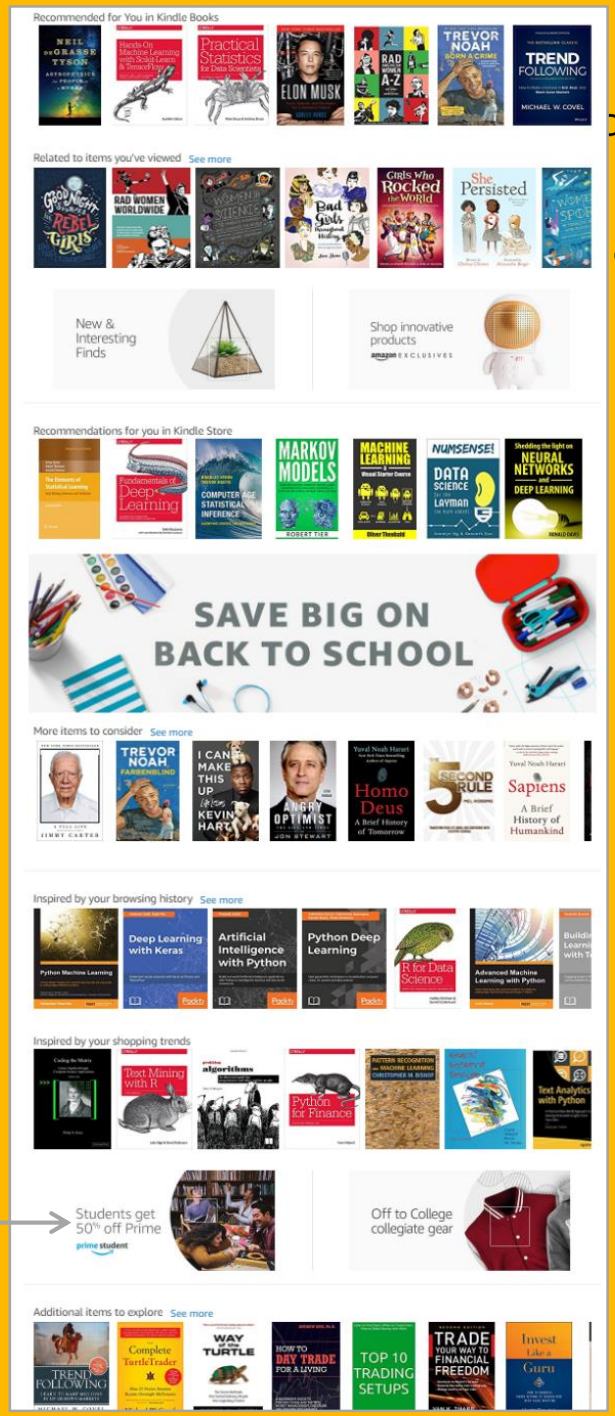

아마존 첫 페이지는 각 영역들의 순서가 개인화 되어 있고, 해당 영역에 노출되는 Item 도 개인화 되어 있음.
광고 위치 광고 종류 또한 다름.

Youtube 개인화

김** 로그인

동일 시점

박** 로그인

유튜브 첫 페이지 또한 각 영역들의 순서가 개인화 되어 있고, 해당 영역에 노출되는 Item 도 개인화 되어 있음.

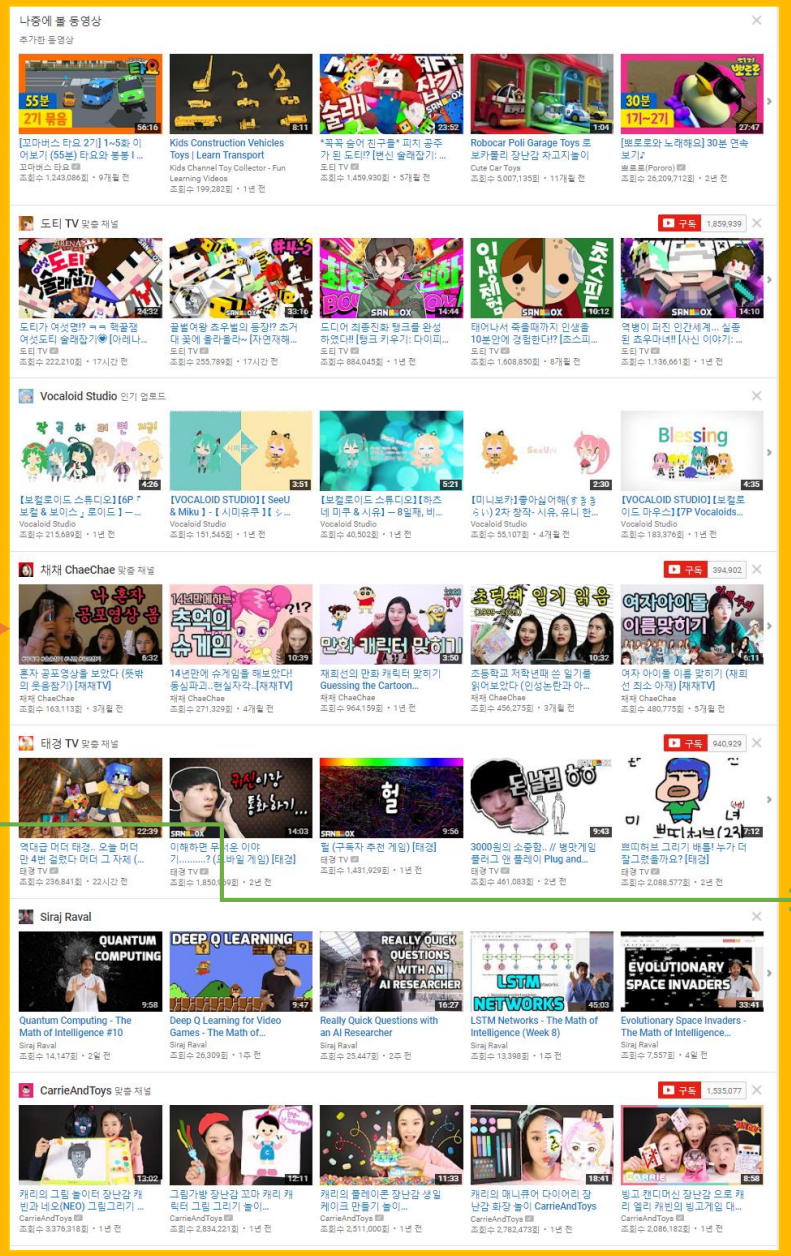

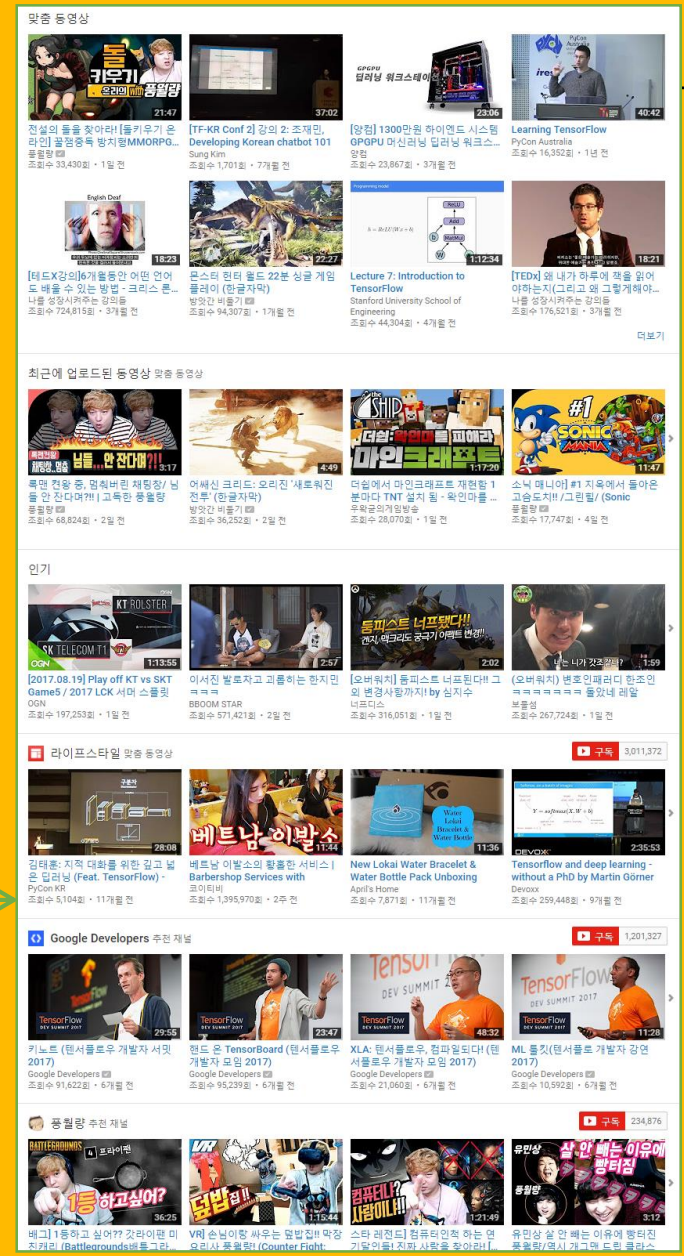

MELTINGCON
COMMUNITY
ALLIANCE

혹자는 말한다!

1. BigData 거품론!
2. AI 거품론!
3. 그런 기술은 실제 돈을 벌어주는 기술이 아니다???

MELTINGCON
COMMUNITY
ALLIANCE

지피지기(知彼知己)!

우리 경쟁사들의 기술의 위치를
줄 세워 보고
우리를 가늠해보자.

Technology Comparison(예시)

(절대적인 수치는 아님. 편차 설명을 위한 주관적 예시 수치 임)

MELTINGCON

TY

E

- 안 중요 한 것이 아님.
- 그냥 이것은 기본임.
- 이걸 잘해야 하는 것은 당연한 일.
- **[필요조건 or 필수조건]**
- But, 차별요소가 아님.

- 오늘 말하고자 하는것
- **[충분조건의 부분집합]**
- 차별요소를 극대화 하고 …
- 고도화 선도기술을 쉽고 빠르게 도입해보는…
- Fast Follwer 전략에 관한 내용 임…

	Web/DB/App **[기본기술]**	BigData/NoSQL/ 샤딩DB/DataAnalytics **[차별기술]**	개인화/ML/DL/MAB DevOps/Microservice BigData Scale AI **[고도화선도기술]**
1. 글로벌 선두 권 - First Mover (Google, Amazon, Alibaba, Facebook, etc)	100%	100%	98%
2. 글로벌 상위권, 국내 최상위권 - Fast Follower 혹은 차별화 선두 권(Naver, Kakao, etc)	100%	100%	90%
3. Local(국내) 상위권	100%	95%	70%
4. Local(국내) 중위권	98%	60%	
5. Local(국내) 하위권	95%		

MELTINGCON
COMMUNITY
ALLIANCE

글로벌 선두권 들은
어떻게 하고 있나??!!

Reinforcement Learning to Rank in E-Commerce Search Engine

MELTINGCON COMMUNITY ALLIANCE

- By Alibaba & Taobao
- https://arxiv.org/abs/1803.00710
- 해당 논문에 대한 블로깅.

실시간성…
개인화…
Training & Serving 이 동시에…

Figure 1: A typical search session in TaoBao. A user starts a session from a query, and has multiple actions to choose, including clicking into an item description, buying an item, turning to the next page, and leaving the session.

YouTube Recommendation

MELTINGCON
COMMUNITY
ALLIANCE

Deep Neural Networks for YouTube Recommendations

- 세 가지 중요한 잣대: Scale, Freshness, Noise
  - Scale: 데이터가 매우 많으므로 scalability가 중요하다.
  - Freshness: 새로운 비디오가 추가되었을때 추천에 바로바로 반영되어야 한다.
  - Noise: 데이터의 sparsity, ground truth의 부재, 거의 항상 implicit feedback만 갖고있다, meta data 가 엉망인 점 등을 고려해야함.
- 구현
  - Tensorflow를 사용함
  - 전체 시스템은 10억개정도의 파라미터 존재
  - 트레이닝 데이터는 수천억개정도.

Serving Layer

Freshness

Scalability

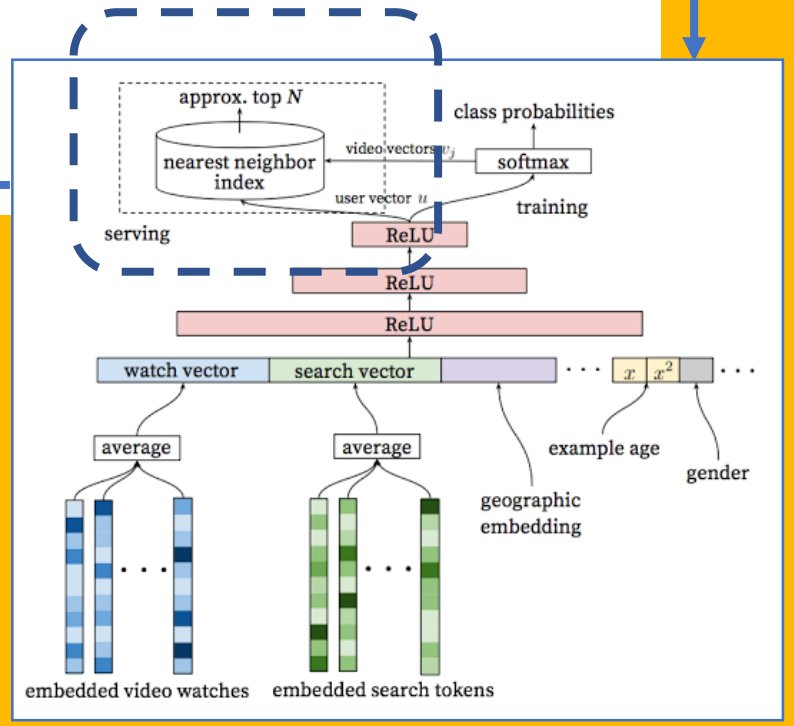

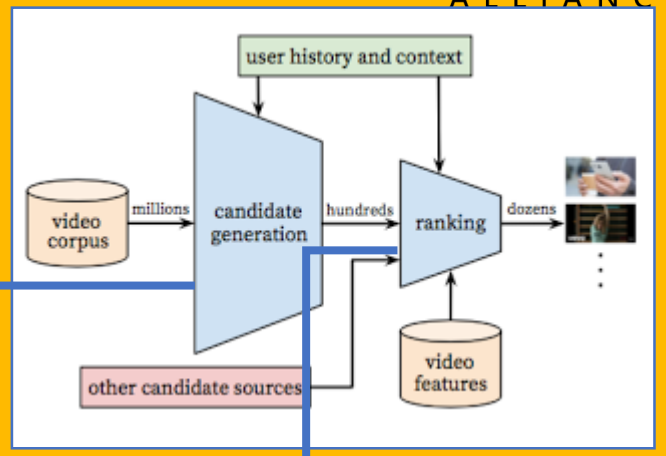

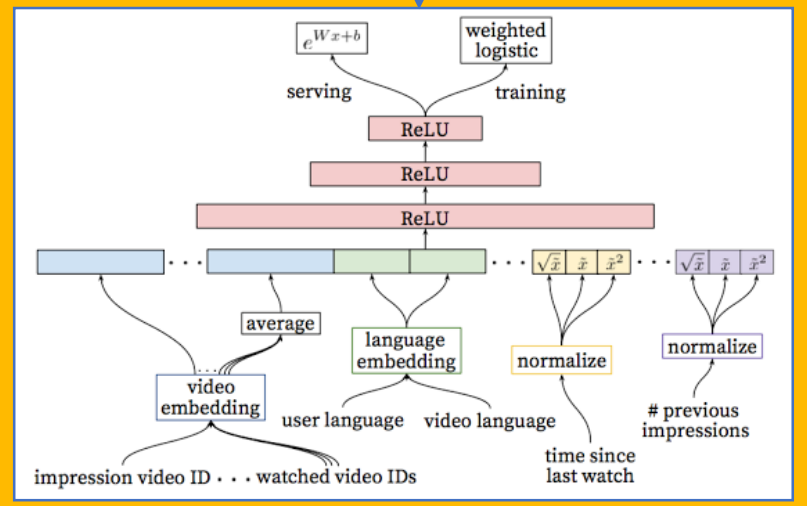

실무 Production 에서의 Chatbot 이란?

MELTINGCON
COMMUNITY
ALLIANCE

- Google Smart Reply (이메일 문의 처리) 시스템의 예
  - https://arxiv.org/abs/1606.04870
  - **Smart Reply: Automated Response Suggestion for Email (by Google)**
  - LSTM
  - 10% 정도를 커버.(2016년 기준)
  - Production 상황의 Pain Point 를 잘 설명.
    - Diversity
    - Scalability
    - 25% 가 20 token 미만
    - Coherent
    - Response Quality
    - Utility
    - Privacy

Semi-supervised Learning 방식 채용

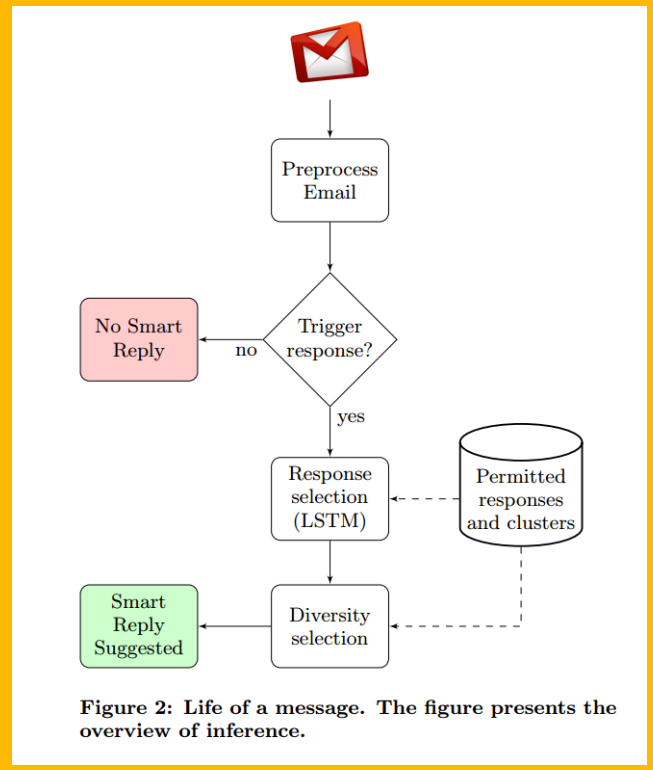

Figure 2: Life of a message. The figure presents the overview of inference.

실무 Production 에서의 Chatbot 이란?

MELTINGCON
COMMUNITY
ALLIANCE

- Sequential Model + Semi Supervised Learning Model 챗봇
  - Smart Reply
    - https://arxiv.org/abs/1606.04870
    - **Smart Reply: Automated Response Suggestion for Email (by Google)**
    - LSTM

Semi-supervised Learning 방식 채용

- **Large Scale Distributed Semi-Supervised Learning Using Streaming Approximation (by Google)**
- https://arxiv.org/pdf/1512.01752.pdf

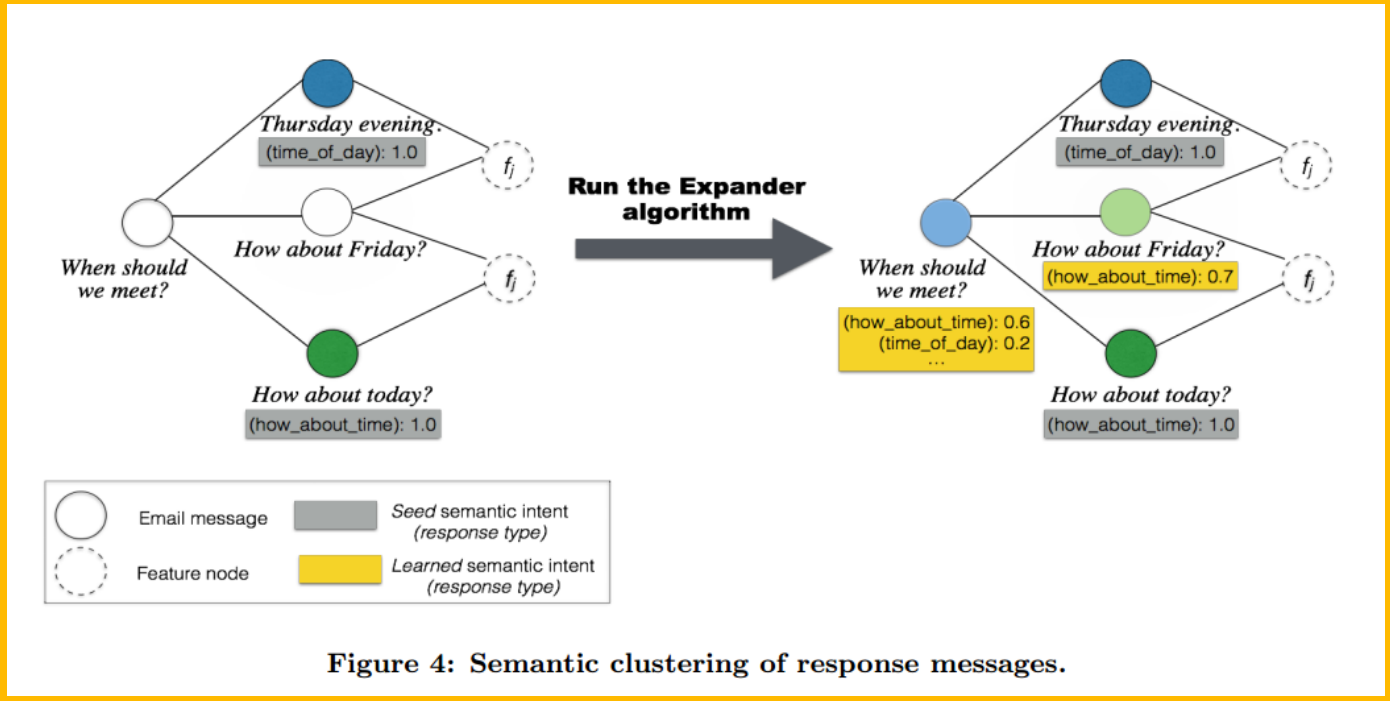

Figure 4: Semantic clustering of response messages.

Deep Learning for Semantic Search (by Google)

MELTINGCON COMMUNITY ALLIANCE

- Predicting Latent Structured Intents from Shopping Queries
- Hybrid LSTM
- https://www.cs.utexas.edu/~cywu/www2017_shopping_query.pdf

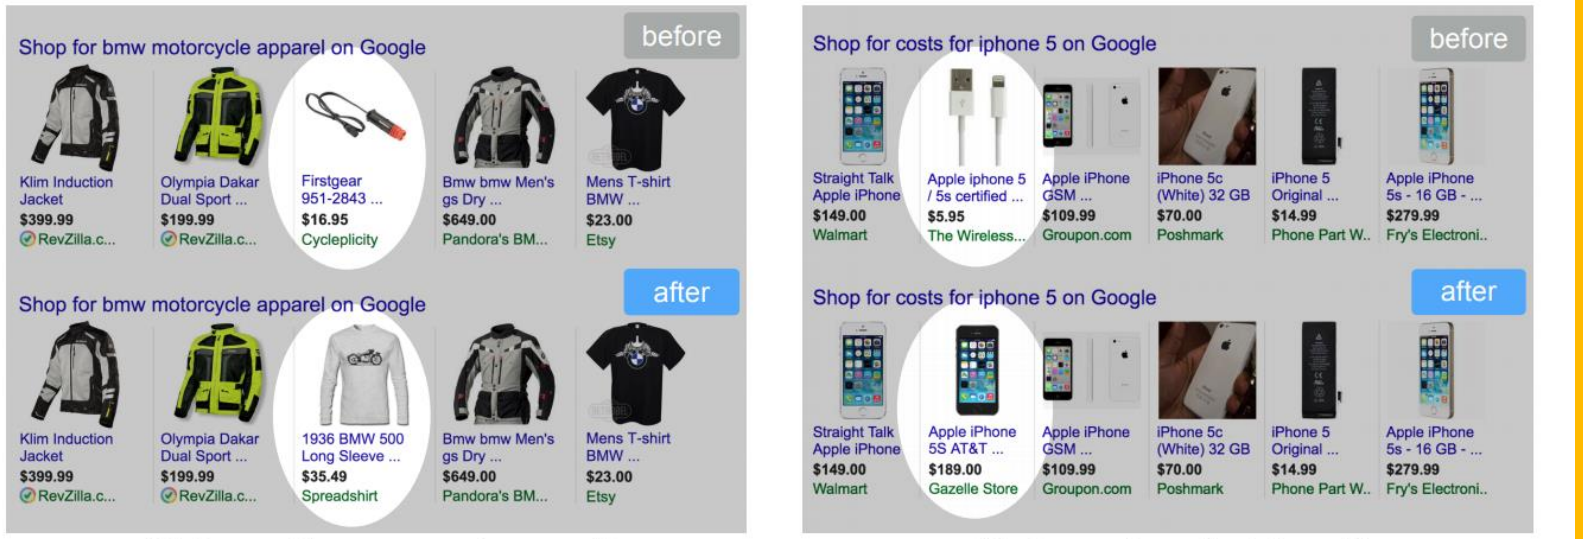

(a) Query: *"bmw motorcycle apparel"*

(b) Query: *"costs for iphone 5"*

Figure 6: Examples of re-ranking of results (before and after). (a) Our model correctly predicts the category *"Shirts and Tops"*, so our boosting promotes and shows a T-shirt instead of an adaptor at position 3. (b) Production incorrectly shows an iPhone charger at position 2. However, after boosting we demote that result and instead show an iPhone 5S.

Google Did!

- 구글 년도 별 주요 발표 내용

Deep Learning 기술 이전에 BigData, NoSQL, MicroService 등에 대한 Core 기술 경쟁력이 뛰어남.

년도	Google 발표 기술	OpenSource 진영 기술
2003년	GFS	Hadoop HDFS
2004년	MapReduce	Hadoop MapReduce
2006년	Chubby	Zookeeper
2006년	BigTable	HBase
2010년	Pregel	Neo4J, Spark Graph-X
2010년	Dremel	Spark
2011년	Tenzing	Hive, Spark SQL
2012년	Spanner, F1	RDB Sharding + Kafka + Redis : RDB 분산 Scale Out 및 동기화 시스템
2013년	Omega	Docker(Mesos)
2014년	Word2Vec 외 다수	Word2Vec (NLP 요소 기술) 외 다수
2015년	Tensorflow 외 다수	Tensorflow (Deep Learning Framework) 외 다수
2016년	AlphaGo, DeepQN 외 다수	복합문제를 해결하는 다수의 Deep Learning 방법론
2017년	PathNet 외 다수	PathNet(Deep Learning 학습의 진화방법) 외 다수

BigData 기술

NoSQL 기술

분산 RDB 기술

MicroService & DevOps 기술

Deep Learning & AI 기술

Production 에서는 Model 개발 외에도 많은 부분의 Engineering Art 가 필요함.

MELTINGCON COMMUNITY ALLIANCE

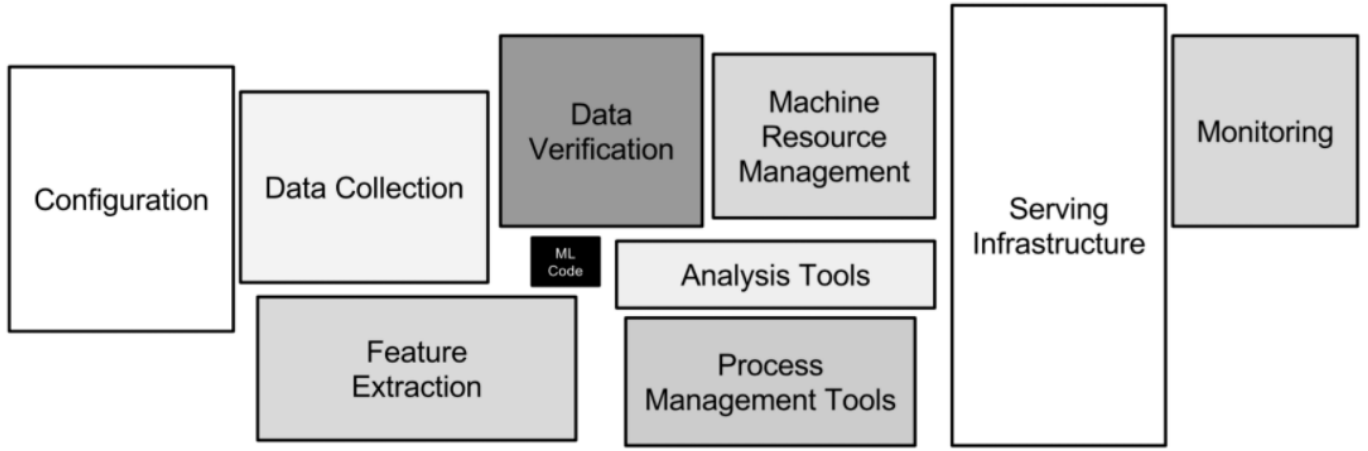

Only a tiny fraction of the code in many ML systems is actually devoted to learning or prediction.

Schulley et al, Hidden Technical Debt in Machine Learning Systems, In NIPS 2015.

Model 개발에 소요되는 시간 및 난이도는 오히려 다른 부분에 비하여 쉬운 편.(예외도 있음)
다수 동접자 Serving Layer 나 고객의 반응을 실시간 학습 시켜 반영 하는 Realtime inference, 모델의 무중지 Rolling Upgrade 및 각종 BigData Scale Data Pipelining 은 매우 어려운 문제.

MELTINGCON
COMMUNITY
ALLIANCE

적은 인원과, 적은 기회와, 적은 시간으로...

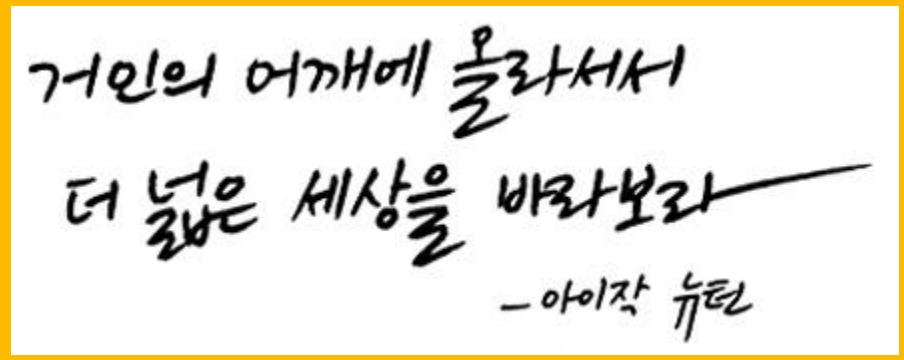

Fast Follow 해보기.

Google 따라하기! + 알파

MELTINGCON
COMMUNITY
ALLIANCE

Hadoop Eco System & NoSQL

- Volume , Variety , Velocity 를 Legacy 대비 100 배 끌어 올리기까지 다양한 Eco System 의 도움이 필요 하였음.

	Google	Open Source 진영	비고
2003년	GFS	HDFS	Hadoop
2004년	MapReduce	MapReduce	
2006년	Chubby	Zookeeper	클러스터 관리
2006년	BigTable	Hbase(Casandra,MongoDB,OrientDB)	NoSQL
2010년	Dremel	Drill,Impala,Tajo,Hwaq(vs Spark)	SQL on Hadoop (+ In-Memory)
2013년	Omega	Docker(vs Mesos)	Process Virtualization

+ TensorFlow

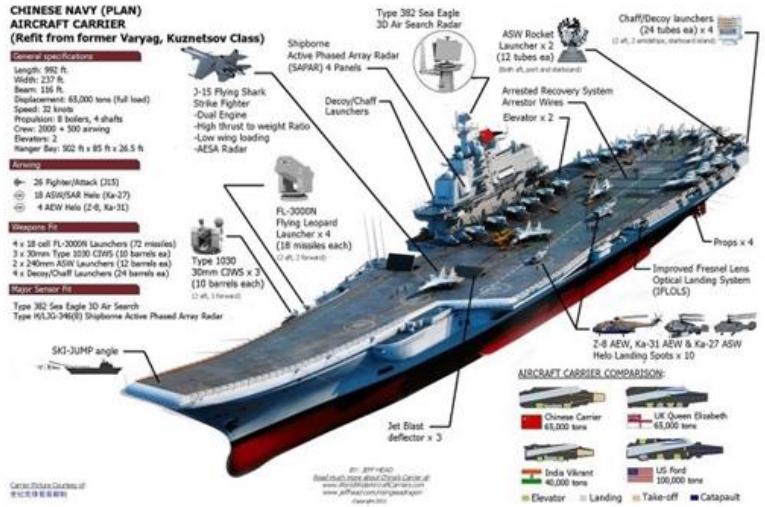

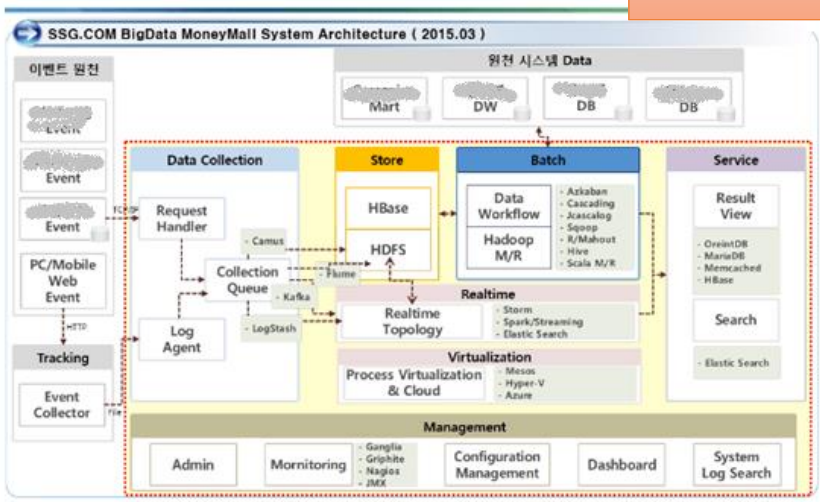

하는 일에 단계를 밟아가고 있음!
– 과거 현재 미래

MELTINGCON
COMMUNITY
ALLIANCE

- 과거를 분석 한다. (BigData Eco System Infra)
  - 트래킹 로그를 남긴다.
  - 빅데이타 수집 저장 분석을 위한 인프라를 만든다.
  - 빅데이타 배치로 과거 시계열 분석을 하고 시각화를 한다.
- 현재에 반응 한다. (RealTime Layer / Spark Streaming / ELK)
  - 실시간으로 데이터 스트림을 분석한다.
  - FDS, 보안관제, 모니터링 등 즉각적으로 현재 상황에 대처하여 현재를 능동적으로 대비한다.
- 미래를 예측 한다. (Mining / Machine Learning / Deep Learning)
  - 고객이 관심 갖고 있고 곧 살 것 같은 것을 추천한다.
  - 미래에 집행할 광고 및 제휴 채널 예산을 보다 ROI 높게 배분한다.
  - 발주를 예측한다.
  - 최적의 트럭 경로를 예측한다.
  - 가격을 올릴지 말지 얼마나 세일할지 최적의 가격을 예측한다.
- 미래를 대비 한다. (Machine Learning / Deep Learning)
  - Chatbot
  - 자연어 활용, 이미지 활용 -> 검색 및 추천 고도화
  - BigData Scale Deep Learning.
  - 다중 접속자를 위한 개인화 Deep Learning 서비스.
  - Auto Scale Out, 무중지 AI 모델의 진화 및 원순환 배포.

4~5년 전

2~3년 전

요즘

순서가 있고,
단계가 있고,
아랫 기술은 윗 기술로
부터 시너지가 나더라....

Production 에서 중요한 것!

MELTINGCON
COMMUNITY
ALLIANCE

Sample Data, Selected Feature 정교한 모델

주1회 or 일1회

모두에게 적용하는 정교한 단일 모델

최고 정확도

VS

더 많은 Data(or 전수 Data)에 적용하는 Simple 모델

최신성
(매 시간 or 준실시간)

개인화 모델

덜 정확해도 빠르고,
다수에게, **실시간**으로…

BigData Scale Deep Learning!

MELTINGCON
COMMUNITY
ALLIANCE

Deep Dive ~~

[차례]

1. 국내 타 업체들의 방식
2. 국외 대표 업체들의 접근 방식
3. 기존에 시도해본 방식(on-premise)
4. 최근에 시도한 방식(serverless public cloud)

MELTINGCON
COMMUNITY
ALLIANCE

BigData Scale Deep Learning!
Deep dive~~

1. 국내 타 업체들의 방식

국내 업체들의 방식

MELTINGCON
COMMUNITY
ALLIANCE

NVIDIA DEEP LEARNING SDK UPDATE

Up to 3x Faster Deep Learning on Volta

GPU-accelerated DL Primitives

cuDNN 7

2.5x Faster Training of CNNs for computer vision

3x Faster Training of RNNs for speech and machine translations

Leading frameworks support

Multi-GPU & Multi-node

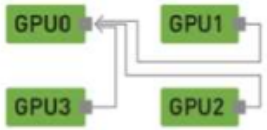

NCCL 2

Multi-node distributed training on up-to 8 servers

Near-linear scaling on PCIe and Nvink interconnect

Leading frameworks support

Inference Optimizer and Runtime Engine

TensorRT 3

3.5x Faster Inference

Optimize TensorFlow or Caffe trained models

Linux, Windows, QNX and Android support

국내 업체들의 방식

NVIDIA Collective Communications Library (NCCL) 2

Multi-GPU and multi-node collective communication primitives

High-performance multi-GPU and multi-node collective communication primitives optimized for NVIDIA GPUs

Fast routines for multi-GPU multi-node acceleration that maximizes inter-GPU bandwidth utilization

Easy to integrate and MPI compatible. Uses automatic topology detection to scale HPC and deep learning applications over PCIe and NVink

Accelerates leading deep learning frameworks such as Caffe2, Microsoft Cognitive Toolkit, MXNet, PyTorch and more

Multi-GPU:
NVLink
PCIe

Multi-Node:
InfiniBand verbs
IP Sockets

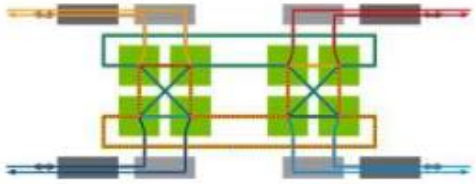

Automatic
Topology
Detection

국내 업체들의 방식

MELTINGCON
COMMUNITY
ALLIANCE

NCCL: MULTI-GPU AND MULTI-NODE SCALING

7x Faster Training on DGX vs. single GPU

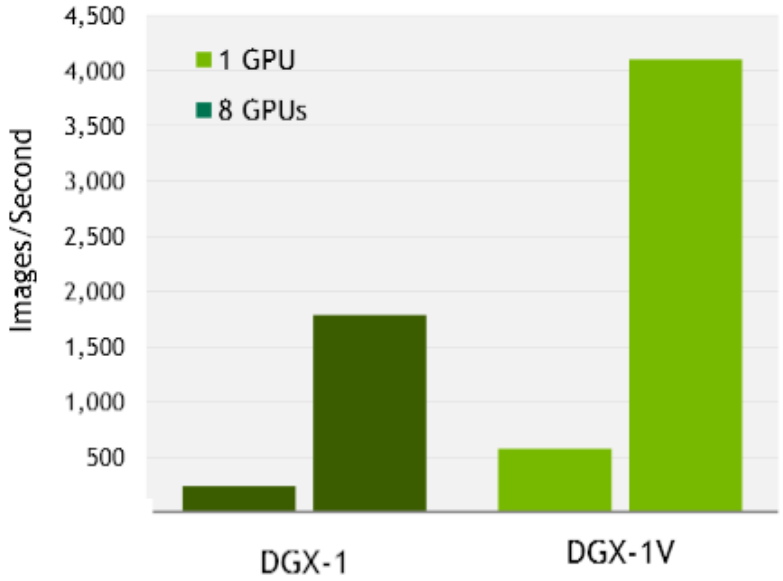

Caffe2 multi-GPU performance (images/sec) DGX-1 + cuDNN 6 (FP32), DGX-1V + cuDNN 7 (FP16). ResNet50, Batch size: 64

Near-Linear Multi-Node Scaling

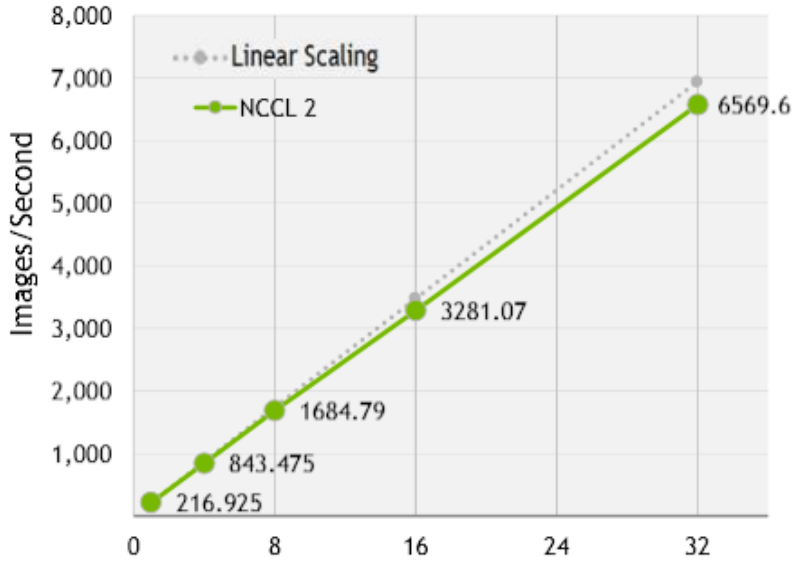

Microsoft Cognitive Toolkit multi-node scaling performance (images/sec), NVIDIA DGX-1 + cuDNN 6 (FP32), ResNet50, Batch size: 64

developer.nvidia.com/nccl

국내 업체들의 방식

MELTINGCON
COMMUNITY
ALLIANCE

Job scheduler system, GPU and Container

add GPU resource to Job Script.
use NVIDIA Docker for the command

…

then scheduler will do the job

```
#!/bin/bash
#PBS -l nodes=1:ppn=2
#PBS -l walltime=00:00:59
#PBS -l gpus=8
NV_GPU=$NV_GPU nvidia-docker run --net
host -e PASSWORD=root -e USERNAME=root
-e PORT=$PORT
idock.daumkakao.io/dkos/nvidia-cuda-
sshd:dev
```

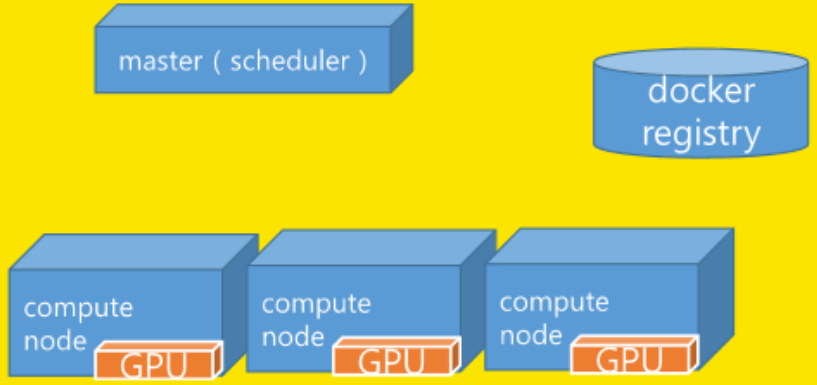

국내 업체들의 방식

MELTINGCON
COMMUNITY
ALLIANCE

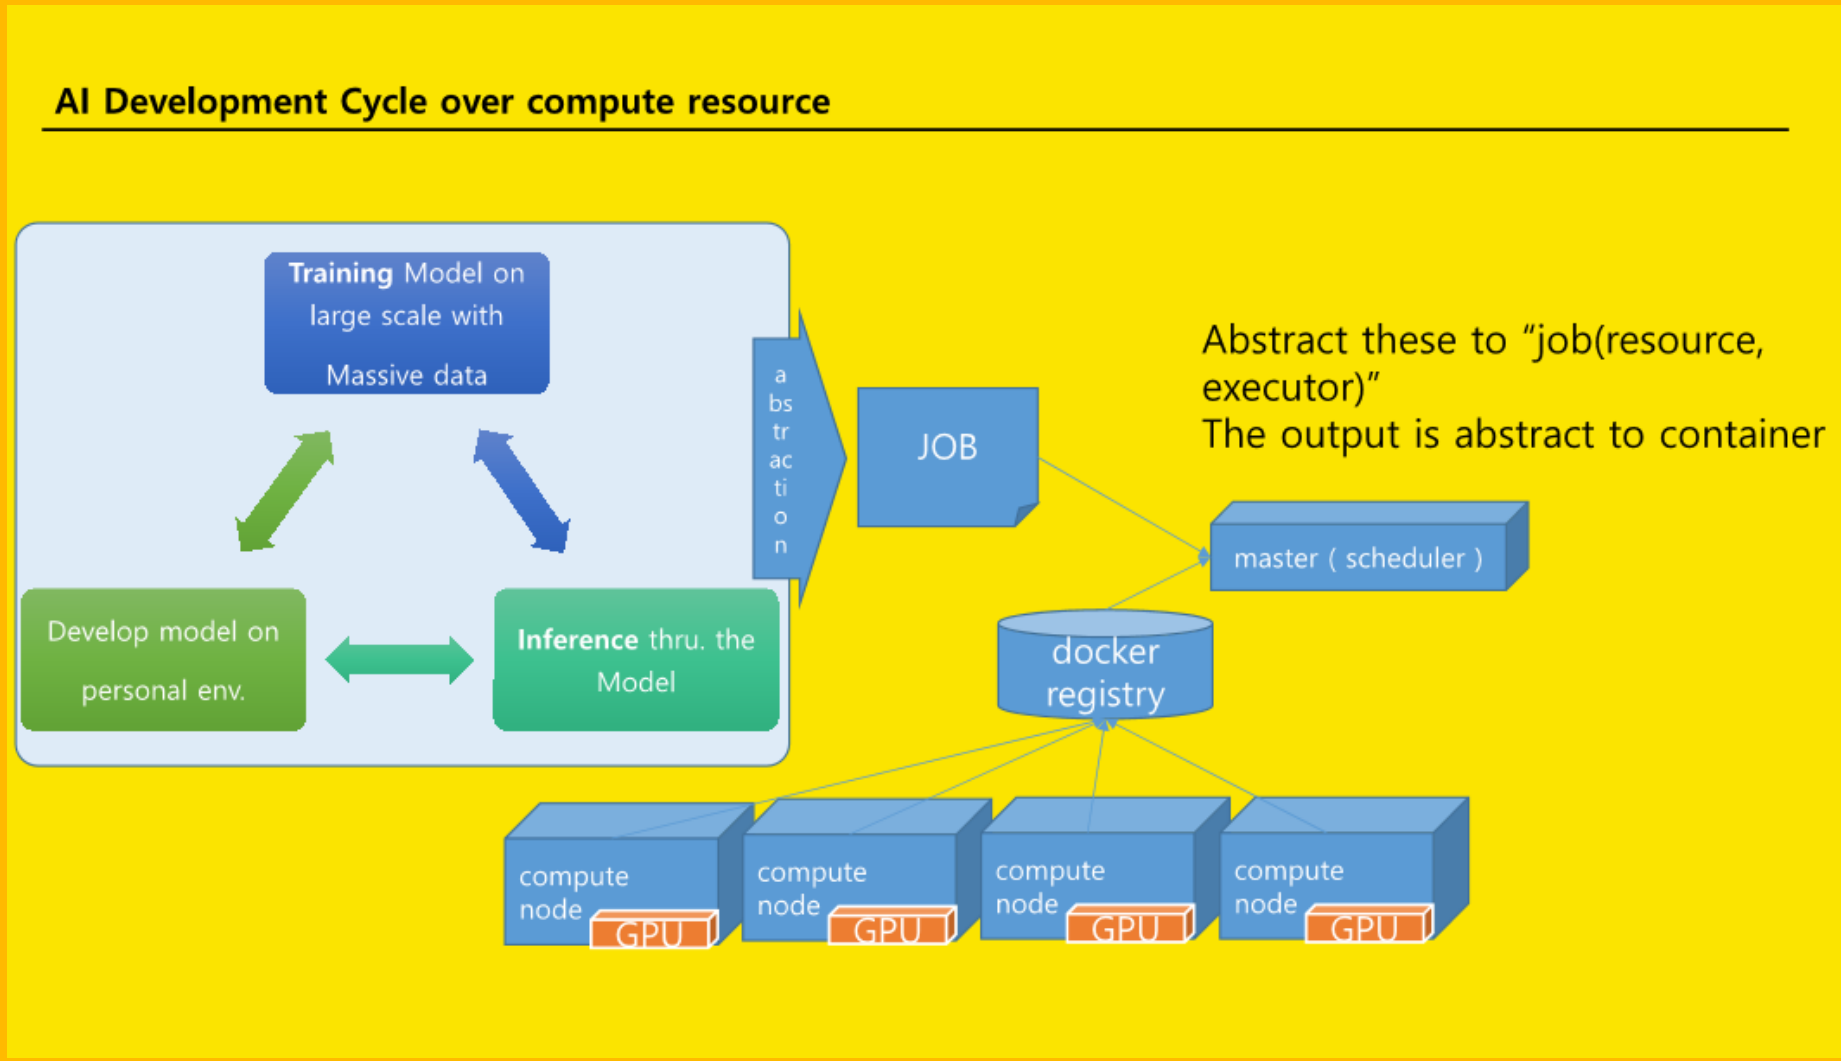

MELTINGCON
COMMUNITY
ALLIANCE

BigData Scale Deep Learning!
Drill down~~

2. 국외 대표 업체들의 접근 방식

Amazon 따라하기! + 알파

Amazone 의 사례(for Personalized Deep Learning Approach)

MELTINGCON
COMMUNITY
ALLIANCE

Large Scale Parallel Deep Learning Example

- https://aws.amazon.com/ko/blogs/big-data/generating-recommendations-at-amazon-scale-with-apache-spark-and-amazon-dsstne/

- https://github.com/amzn/amazon-dsstne

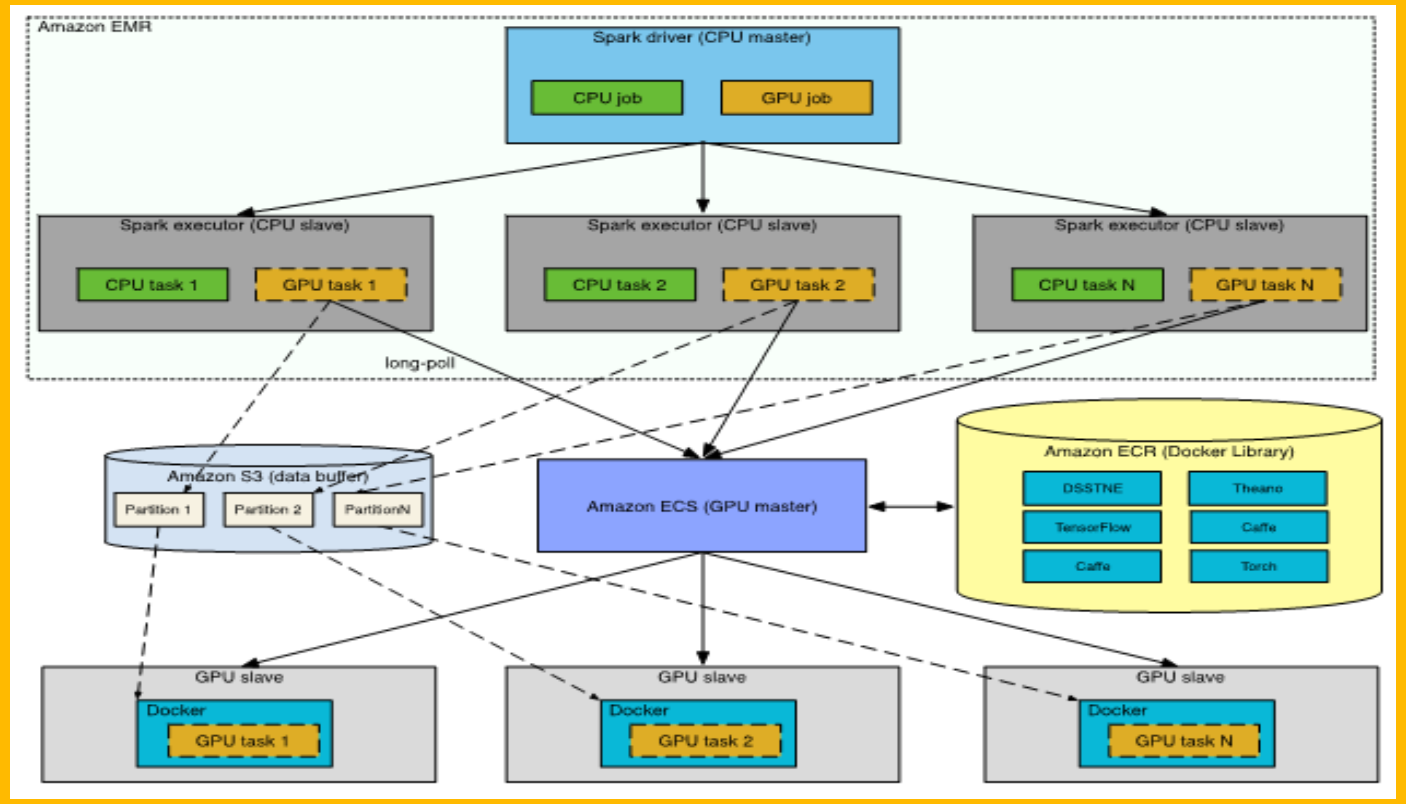

BigData진영 대표주자 Spark의 진화
=> BigData 에서 BigData + AI 로...

MELTINGCON
COMMUNITY
ALLIANCE

Spark Summit is Becoming the Spark + AI Summit

by Matei Zaharia
Posted in **COMPANY BLOG** | December 6, 2017

We're excited to announce that Spark Summit is expanding its coverage in 2018 to include in-depth content on artificial intelligence. We are also renaming the conference **Spark + AI Summit**. AI has always been one of the most exciting applications of big data and Apache Spark, so with this change, we are planning to bring in keynotes, talks and tutorials about

TensorFlow On Spark: Scalable TensorFlow Learning on Spark Clusters
Andy Feng (Yahoo)
Lee Yang (Yahoo)

Spark Summit 2017 에서도 이미...

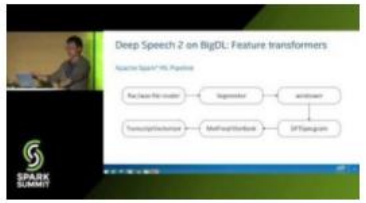

Deep Learning to Big Data Analytics on Apache Spark Using BigDL
Xianyan Jia (Intel)

Very Large Data Files, Object Stores, and Deep Learning—Lessons Learned While Looking for Signs o...

Building Deep Learning Powered Big Data

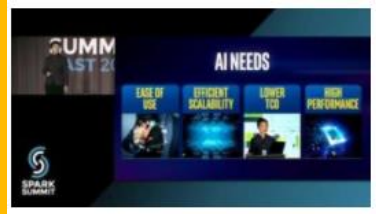

Accelerating Machine Learning and Deep Learning At Scale...With Apache Spark

Distributed Tensor Flow on Spark: Scaling Google's Deep Learning Library

Scalable Deep Learning Platform On Spark In Baidu
Kyle Tsai (Baidu)

Netflix – Productionizing Spark On Yarn For ETL At Petabyte Scale
Ashwin Shankar (Netflix)

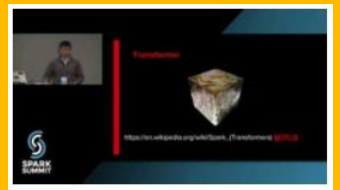

Netflix's Recommendation ML Pipeline Using Apache Spark
DB Tsai (Netflix)

Going Real-Time: Creating Frequently-Updating Datasets for Personalization
Shriya Arora (Netflix)

MELTINGCON
COMMUNITY
ALLIANCE

BigData Scale Deep Learning!
Drill down~~

3. 기존에 시도해본 방식

Intent Classifier 예시

MELTINGCON
COMMUNITY
ALLIANCE

1.	Word2Vec + CNN (Batch Normalize + Augmentation)	72.30%
2.	Word2Vec + LSTM	73.94%
3.	Word2Vec + CNN + LSTM	72.97%
4.	Word2Vec + Bidirectional GRU	74.36%
5.	Word2Vec + Bidirectional GRU + Attention Network	73.15%
6.	FastText	72.50%
7.	Glove + LSTM (BigDL on Spark Cluster)	75.25%

450여개 Multiple Class , Top 1 문제.

8. 다양한 Approach 의 조합 최종.

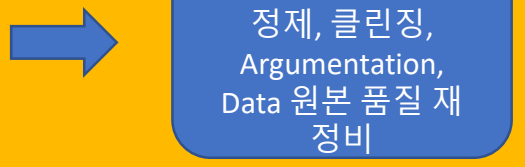

89.6%

Deep Learning 은 고행인가?

MELTINGCON
COMMUNITY
ALLIANCE

- Word2Vec + Bidirectional GRU
- Tesla M40 GPU
- Training Data 165만 건
- Learning Rate 0.0005

```
Epoch 1/5
1649415/1649415 [==============================] - 10174s - loss: 1.0124 - acc: 0.6992 - val_loss: 0.9239 -
Epoch 2/5
1649415/1649415 [==============================] - 9949s - loss: 0.9461 - acc: 0.7157 - val_loss: 0.9076 -
Epoch 3/5
1649415/1649415 [==============================] - 9951s - loss: 0.9318 - acc: 0.7199 - val_loss: 0.9068 -
Epoch 4/5
1649415/1649415 [==============================] - 9953s - loss: 0.9234 - acc: 0.7220 - val_loss: 0.9039 -
Epoch 5/5
1649415/1649415 [==============================] - 9962s - loss: 0.9176 - acc: 0.7241 - val_loss: 0.9079 - val_acc
: 0.7436
tail: keras_output.txt: file truncated
```

- 5 Epoch 에 50000초 = 833분 = 약 14시간

Deep Learning 은 고행인가?

MELTINGCON
COMMUNITY
ALLIANCE

- seq2seq
- Tesla K80 GPU * 2
- Training Data 180만 건
- Training 시간 약 24시간

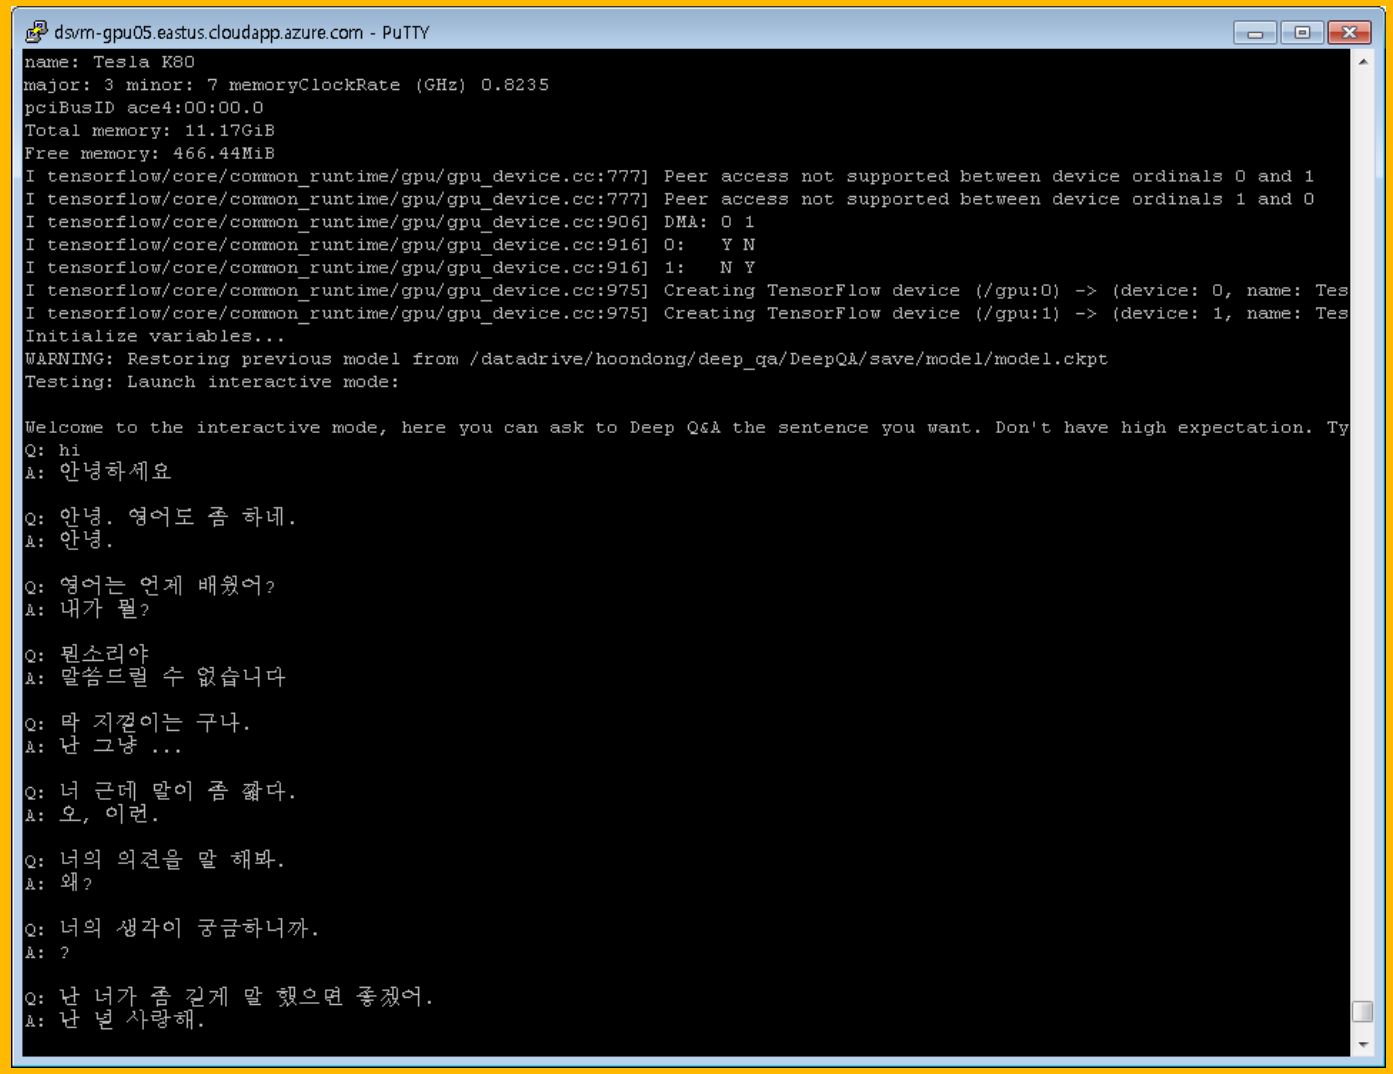

Training & Serving 속도에 대하여

MELTINGCON
COMMUNITY
ALLIANCE

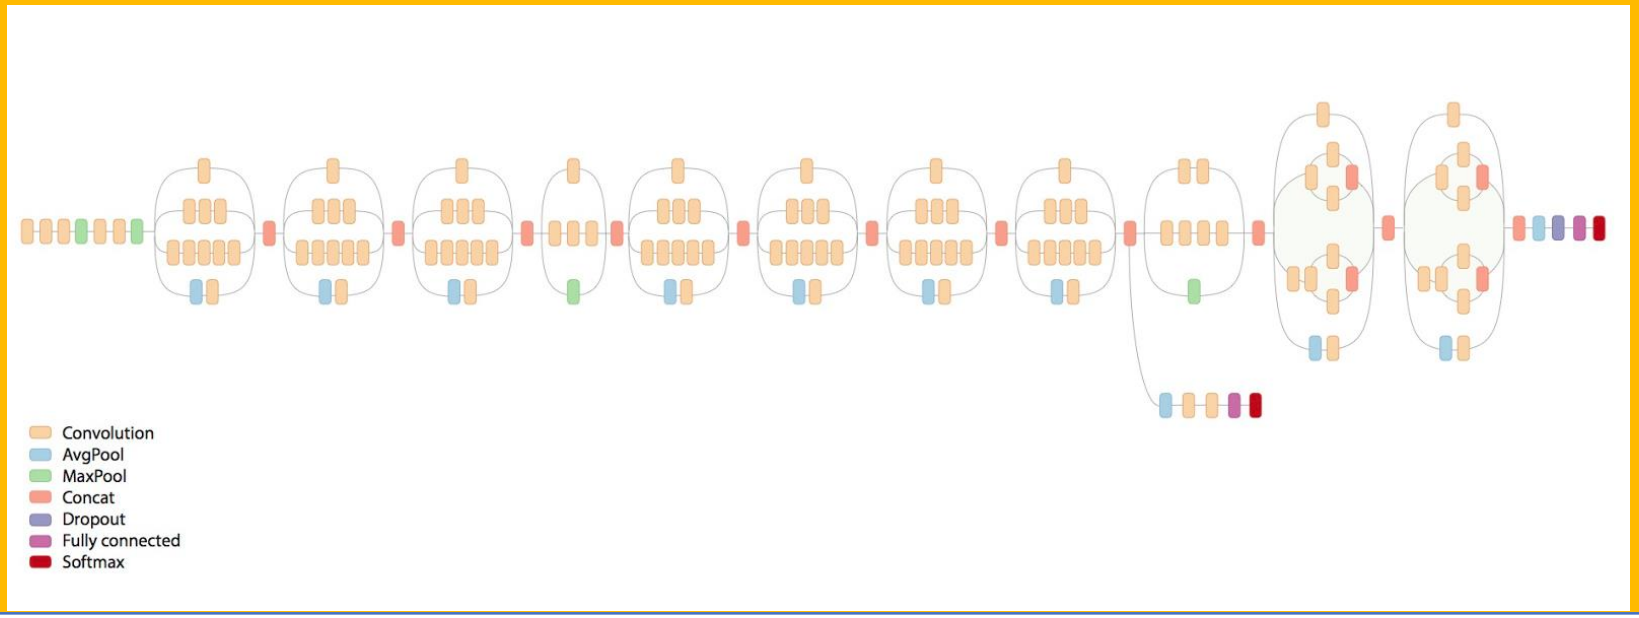

- 이미지와 달리 Text NLP 등은 오픈 된 Pre training Set 이 거의 없음.
- 이미지의 경우에도 실무에서는 정확도를 올리기 위해 Fine Tuning 하는 경우가 많음.
- 깊은 층의 모델로 학습시키는 경우 어마어마한 시간이 걸림.
- 게다가 다양한 Model 의 Mesh Up 필요.
- Live 상품갯수 500만건, 이미지 4000만 건?? 게다가 매일 매일 유입되는 수천건의 이미지?? 매일 매일 바뀌는 수천건의 상품들….
- Production 의 Serving 은 또 따른 문제….

R on Spark

- SparkR
- Sparklyr
- RevoScaleR(MS R)

MELTINGCON
COMMUNITY
ALLIANCE

7 Machine on Spark Cluster

8Core – 65GB Memory. 7 Machine.

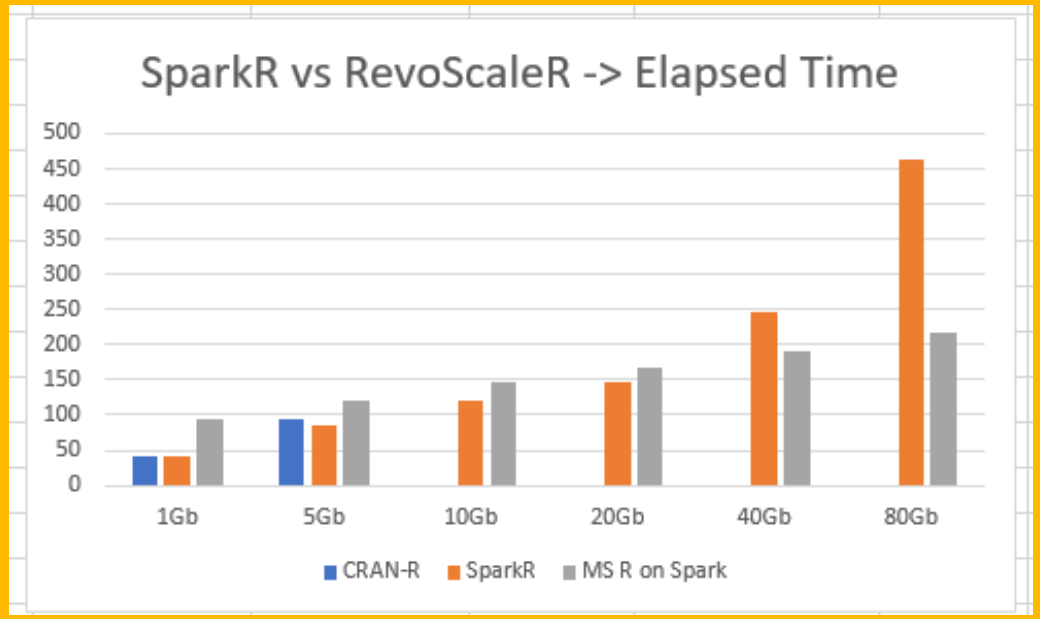

Y축 : Elapsed Time 낮을 수록 성능 좋음.

Python Machine Learning on Spark

MELTINGCON
COMMUNITY
ALLIANCE

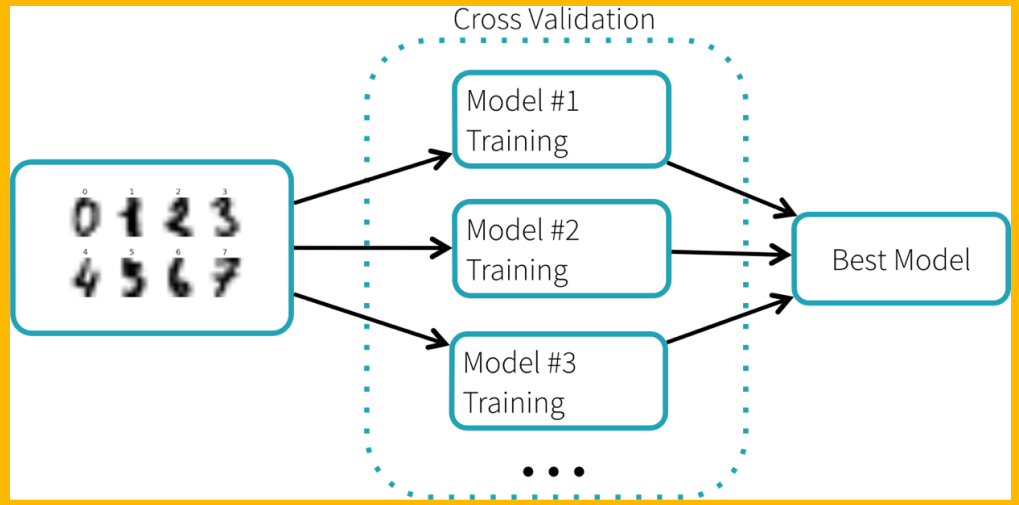

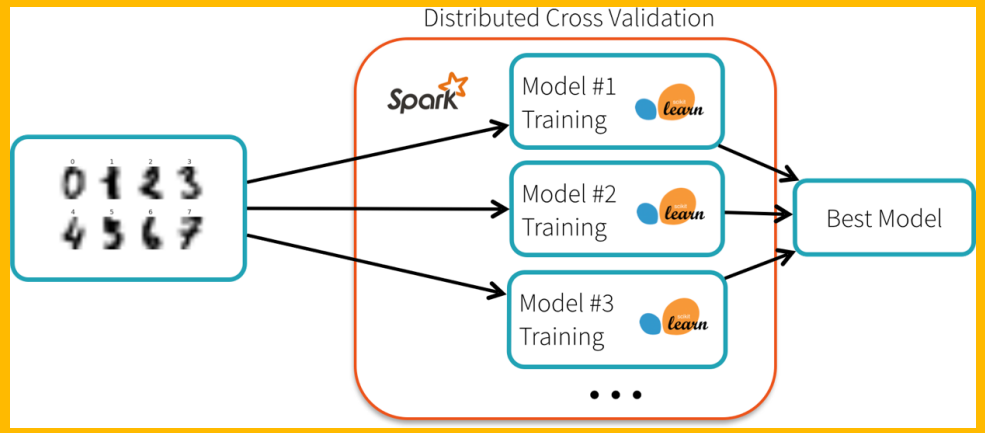


```
from sklearn import grid_search, datasets
from sklearn.ensemble import RandomForestClassifier
from sklearn.grid_search import GridSearchCV
digits = datasets.load_digits()
X, y = digits.data, digits.target
param_grid = {"max_depth": [3, None],
              "max_features": [1, 3, 10],
              "min_samples_split": [1, 3, 10],
              "min_samples_leaf": [1, 3, 10],
              "bootstrap": [True, False],
              "criterion": ["gini", "entropy"],
              "n_estimators": [10, 20, 40, 80]}
gs = grid_search.GridSearchCV(RandomForestClassifier(), param_grid=param_grid)
gs.fit(X, y)
```

```
from sklearn import grid_search, datasets
from sklearn.ensemble import RandomForestClassifier
# Use spark_sklearn's grid search instead:
from spark_sklearn import GridSearchCV
digits = datasets.load_digits()
X, y = digits.data, digits.target
param_grid = {"max_depth": [3, None],
              "max_features": [1, 3, 10],
              "min_samples_split": [1, 3, 10],
              "min_samples_leaf": [1, 3, 10],
              "bootstrap": [True, False],
              "criterion": ["gini", "entropy"],
              "n_estimators": [10, 20, 40, 80]}
gs = grid_search.GridSearchCV(RandomForestClassifier(), param_grid=param_grid)
gs.fit(X, y)
```

Jupyter Notebook 도 BigData Scale 로

Zupyter on PySPark, Zupyter on Hadoop

MELTINGCON
COMMUNITY
ALLIANCE

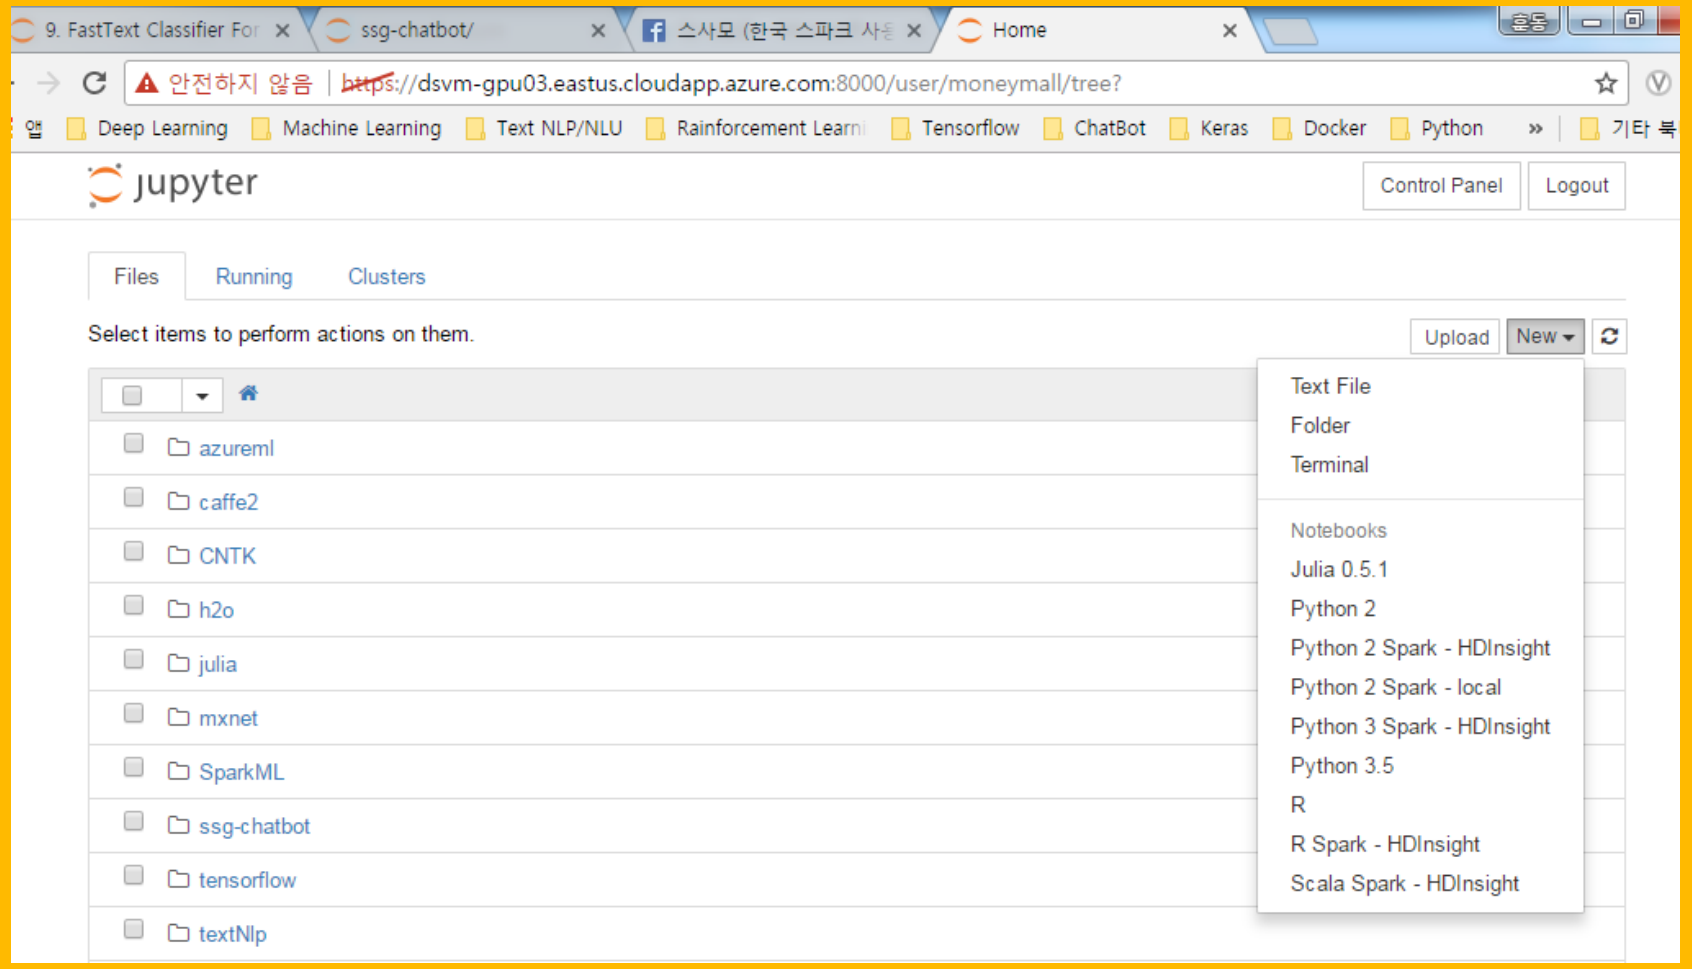

SSG.COM BigDL

MELTINGCON COMMUNITY ALLIANCE

GPU Memory Resource 가 문제될 때는 BigData Scale Large Cluster Parallel Deep Learning Approach with BigDL

- BigDL Deep Learning Job on Hadoop Yarn Manager (by Spark Job)

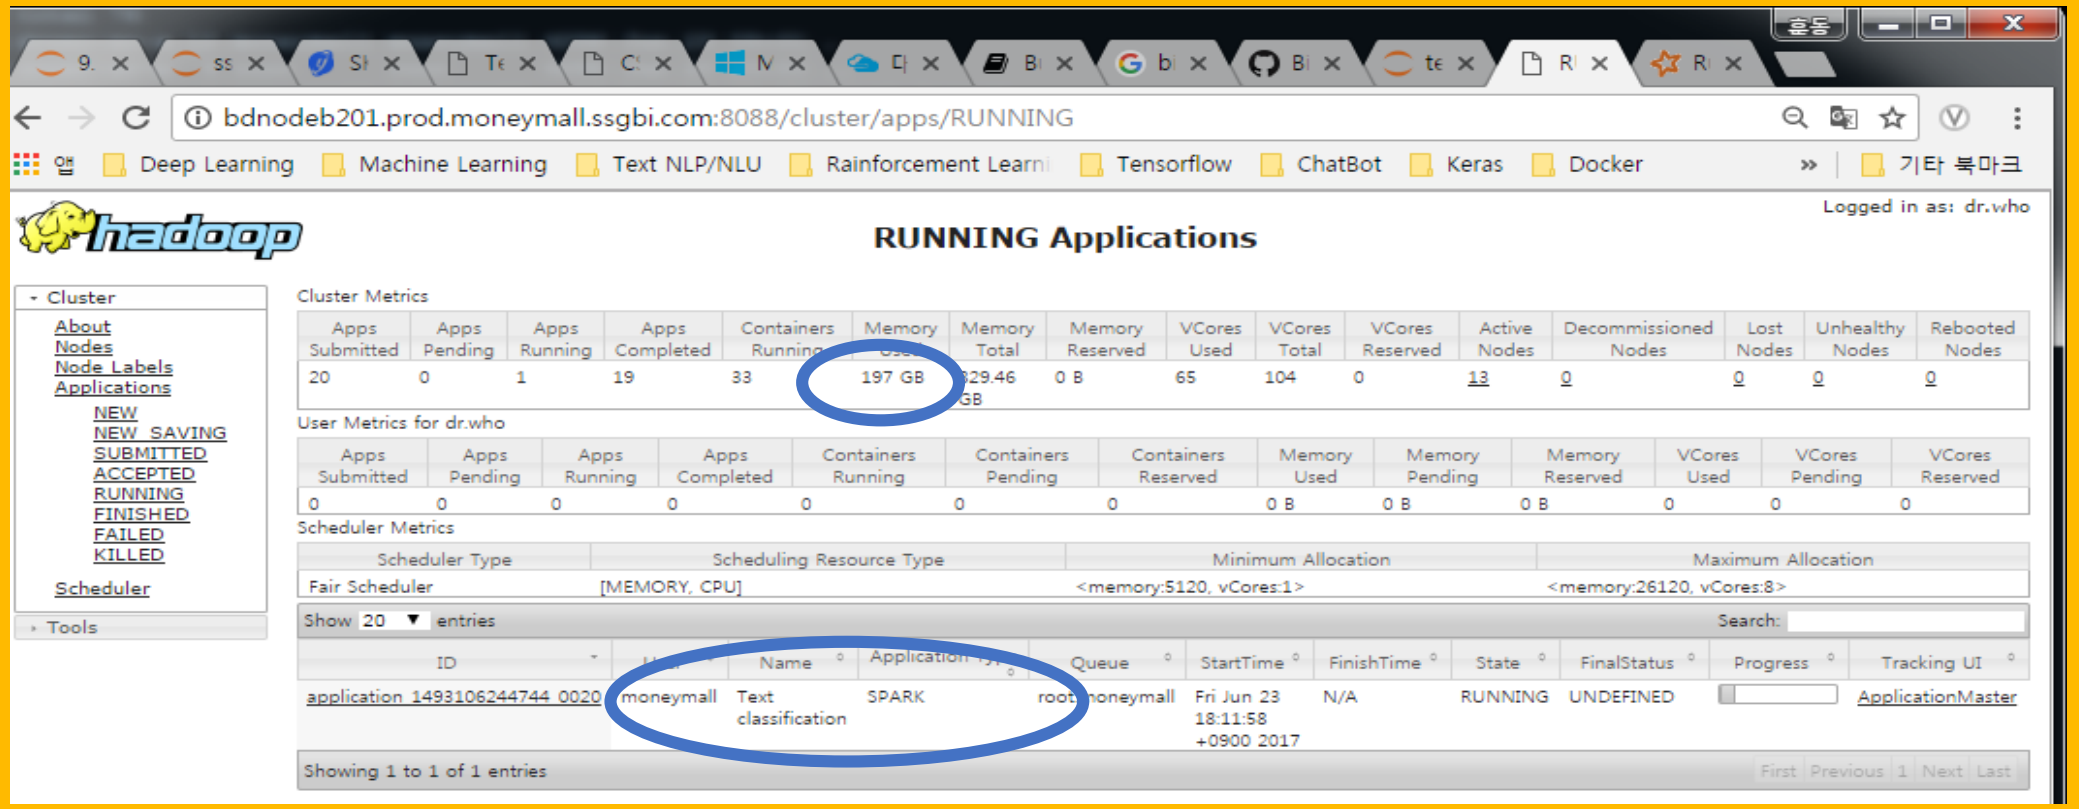

SSG.COM BigDL

MELTINGCON
COMMUNITY
ALLIANCE

GPU Memory Resource 가 문제될 때는 BigData Scale Large Cluster Parallel Deep Learning Approach with BigDL

- BigDL Deep Learning Text Classification

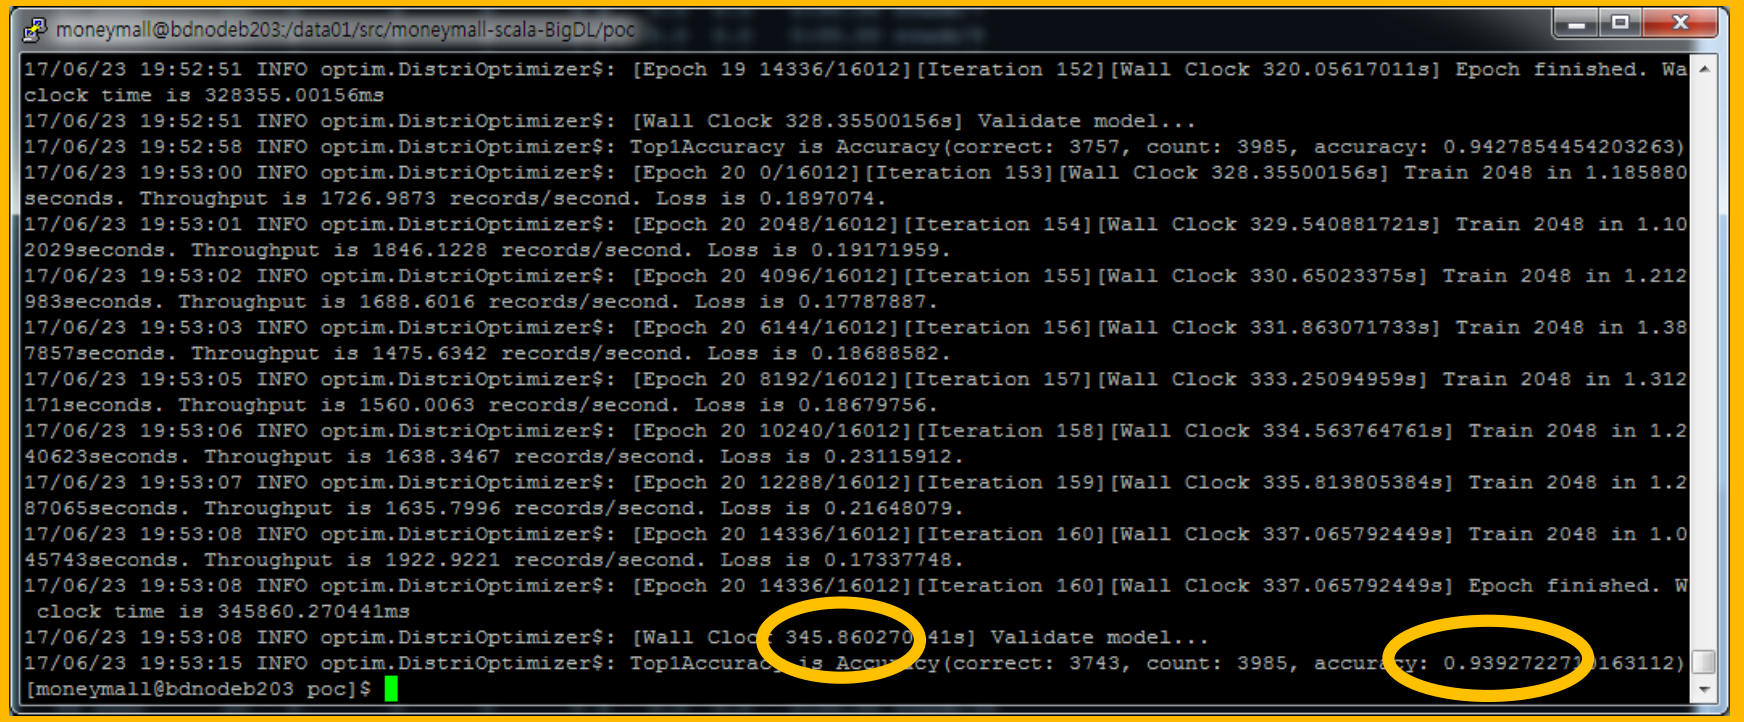

SSG.COM BigDL

MELTINGCON COMMUNITY ALLIANCE

GPU Memory Resource 가 문제될 때는 BigData Scale Large Cluster Parallel Deep Learning Approach with BigDL

- BigDL Deep Learning Job on Hadoop Yarn Manager (by Spark Job)

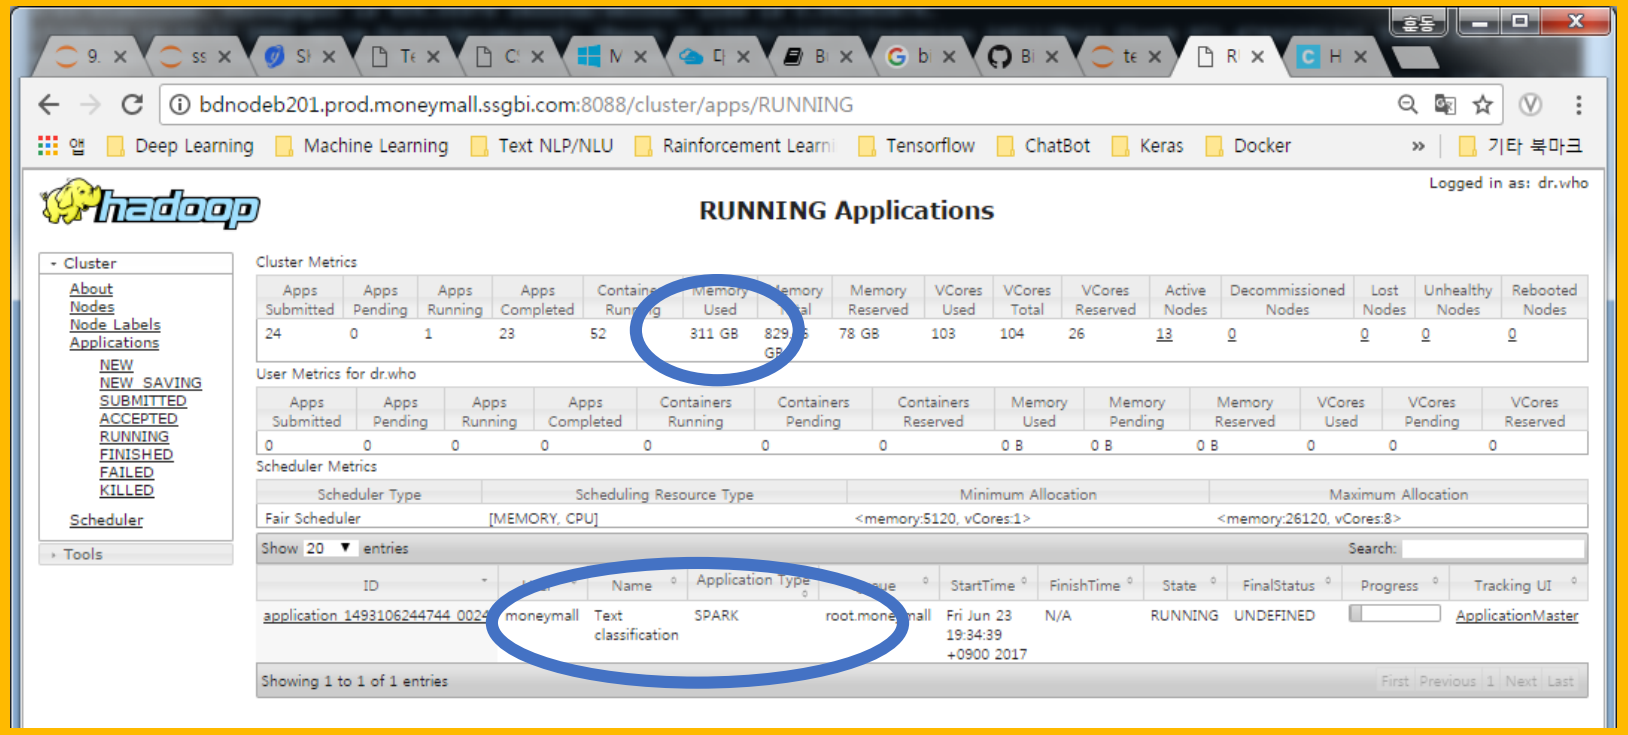

SSG.COM BigDL

MELTINGCON
COMMUNITY
ALLIANCE

GPU Memory Resource 가 문제될 때는 BigData Scale Large Cluster Parallel Deep Learning Approach with BigDL

- BigDL Deep Learning Text Classification

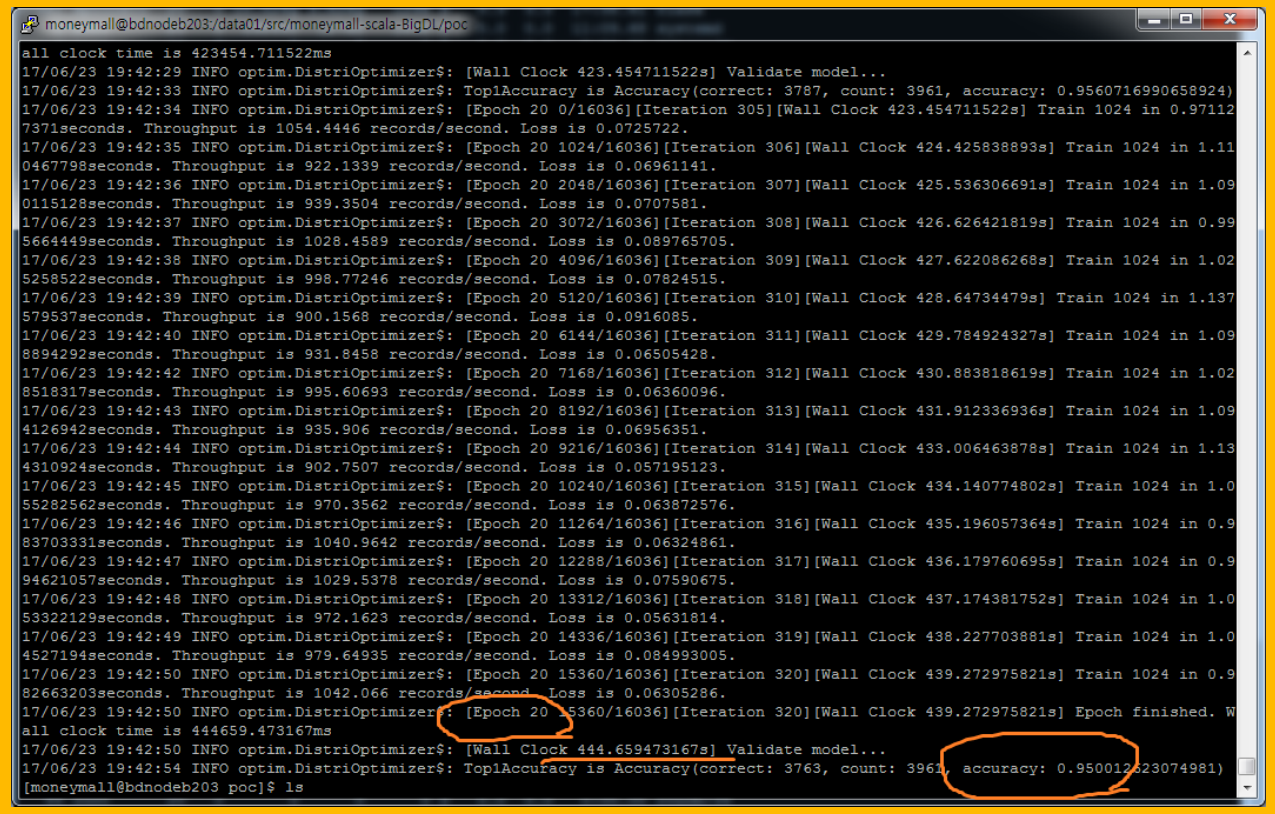

SSG.COM TensorflowOnSpark

Tenosrflow 의 Legacy 를 활용한 BigData Scale Deep Learning 은?

MELTINGCON COMMUNITY ALLIANCE

- TensorflowOnSpark 수행 결과

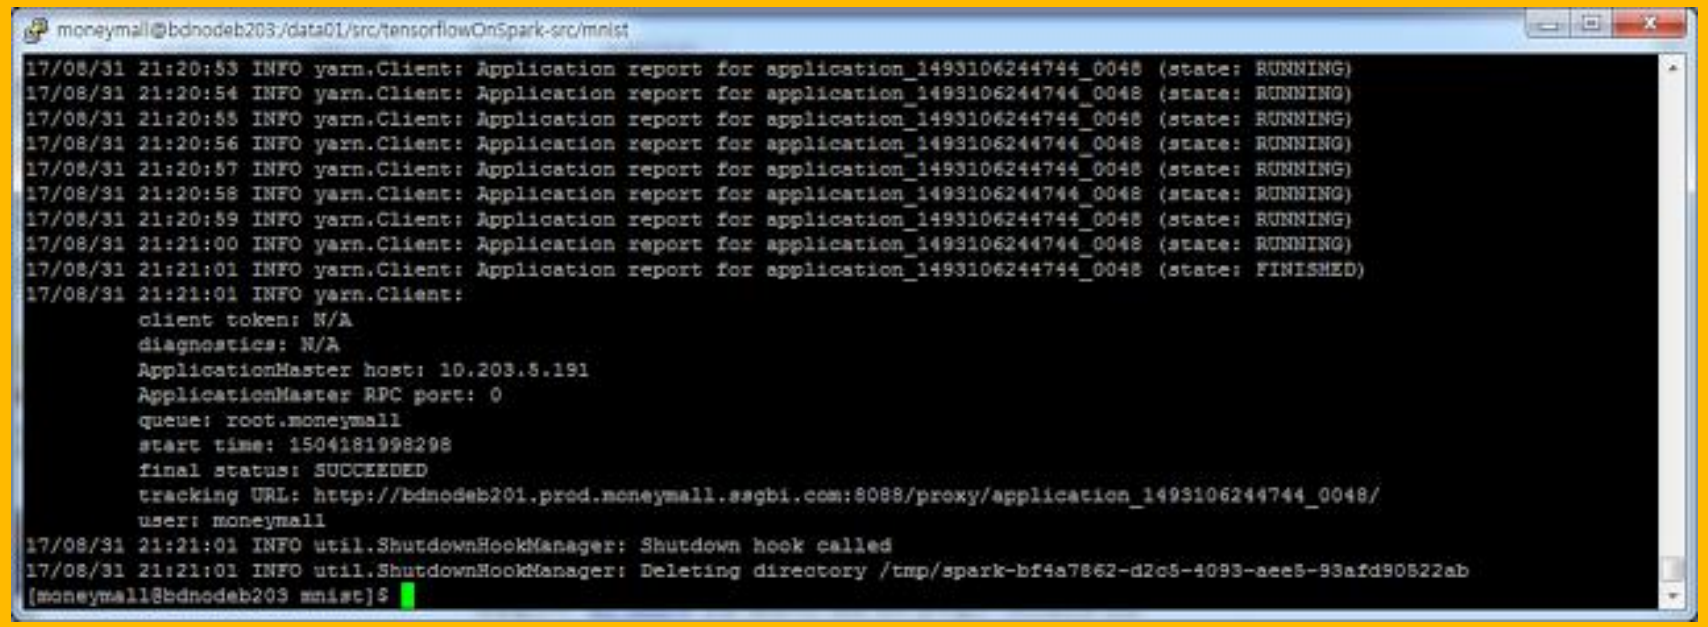

BigDL vs TensorflowOnSpark

MELTINGCON COMMUNITY ALLIANCE

What is BigDL

BigDL is a distributed deep learning library for Apache Spark; with BigDL, users can write their deep learning applications as standard Spark programs, which can directly run on top of existing Spark or Hadoop clusters.

- **Rich deep learning support.** Modeled after Torch, BigDL provides comprehensive support for deep learning, including numeric computing (via Tensor) and high level neural networks; in addition, users can load pre-trained Caffe or Torch or Keras models into Spark programs using BigDL.
- **Extremely high performance.** To achieve high performance, BigDL uses Intel MKL and multi-threaded programming in each Spark task. Consequently, it is orders of magnitude faster than out-of-box open source Caffe, Torch or TensorFlow on a single-node Xeon (i.e., comparable with mainstream GPU).
- **Efficiently scale-out.** BigDL can efficiently scale out to perform data analytics at "Big Data scale", by leveraging Apache Spark (a lightning fast distributed data processing framework), as well as efficient implementations of synchronous SGD and all-reduce communications on Spark.

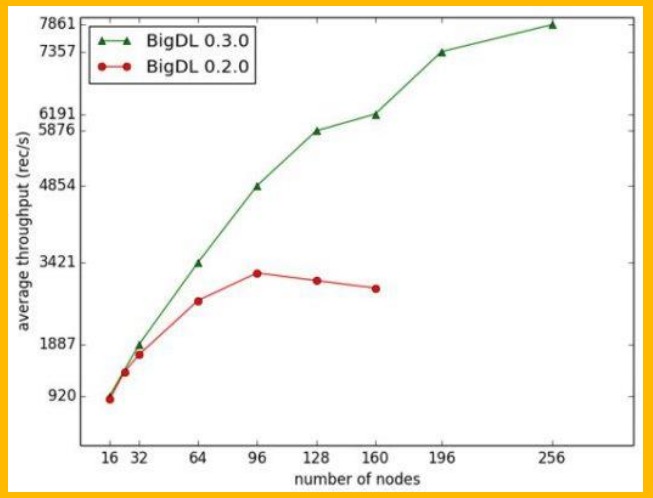

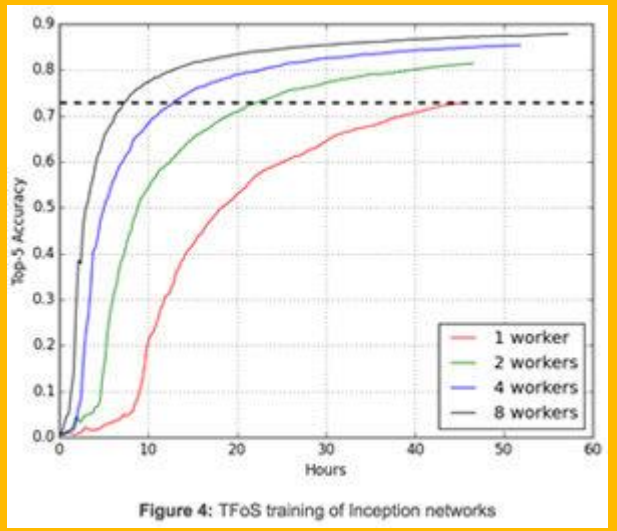

Figure 4: TFoS training of Inception networks

Why TensorFlowOnSpark?

TensorFlowOnSpark provides some important benefits (see our blog) over alternative deep learning solutions.

- Easily migrate all existing TensorFlow programs with <10 lines of code change;
- Support all TensorFlow functionalities: synchronous/asynchronous training, model/data parallelism, inferencing and TensorBoard;
- Server-to-server direct communication achieves faster learning when available;
- Allow datasets on HDFS and other sources pushed by Spark or pulled by TensorFlow;
- Easily integrate with your existing data processing pipelines and machine learning algorithms (ex. MLlib, CaffeOnSpark);
- Easily deployed on cloud or on-premise: CPU & GPU, Ethernet and Infiniband.

Batch Size에 대하여(무조건 mini Batch가 좋은가???)

MELTINGCON
COMMUNITY
IANCE

Sigle Host GPU vs Multi Host GPU vs Super Multi Host CPU

```
Epoch 18/200
34447/34447 [==============================] - 71s 2ms/step - loss: 0.1010 - acc: 0.9873 - val_loss: 0.0797 - val_acc: 0.9762
Epoch 19/200
34447/34447 [==============================] - 71s 2ms/step - loss: 0.0999 - acc: 0.9873 - val_loss: 0.0859 - val_acc: 0.9760
Epoch 20/200
34447/34447 [==============================] - 70s 2ms/step - loss: 0.1017 - acc: 0.9877 - val_loss: 0.0855 - val_acc: 0.9767
Epoch 21/200
34447/34447 [==============================] - 70s 2ms/step - loss: 0.0989 - acc: 0.9877 - val_loss: 0.0842 - val_acc: 0.9765
Epoch 22/200
34447/34447 [==============================] - 71s 2ms/step - loss: 0.0972 - acc: 0.9882 - val_loss: 0.0841 - val_acc: 0.9774
```

- Single Host GPU : 64 batch size. 71초 * 22 epoch(Auto Early Stopping) = 1562 초

- Multi Host GPU : 1024 batch size. 6초 * 58 epoch(Auto Early Stopping) = 348 초

```
Epoch 53/200
34447/34447 [==============================] - 6s 166us/step - loss: 0.0899 - acc: 0.9882 - val_loss: 0.0725 - val_acc: 0.9779
Epoch 54/200
34447/34447 [==============================] - 6s 166us/step - loss: 0.0902 - acc: 0.9878 - val_loss: 0.0730 - val_acc: 0.9776
Epoch 55/200
34447/34447 [==============================] - 6s 166us/step - loss: 0.0911 - acc: 0.9878 - val_loss: 0.0730 - val_acc: 0.9774
Epoch 56/200
34447/34447 [==============================] - 6s 168us/step - loss: 0.0899 - acc: 0.9869 - val_loss: 0.0738 - val_acc: 0.9781
Epoch 57/200
34447/34447 [==============================] - 6s 166us/step - loss: 0.0909 - acc: 0.9880 - val_loss: 0.0734 - val_acc: 0.9766
Epoch 58/200
34447/34447 [==============================] - 6s 166us/step - loss: 0.0875 - acc: 0.9880 - val_loss: 0.0731 - val_acc: 0.9782
```

그렇다면, Super Multi Host CPU 클러스터는?

MELTINGCON
COMMUNITY
ALLIANCE

그런데…

BigData Scale
Deep Learning Training

TensorflowOnSpark 는 Parallel Inference 도 제공하지만…
Batch System 으로는 적당할 것 같은데…

MELTINGCON
COMMUNITY
ALLIANCE

그런데…

Parallel Inference 의 Production 에 대한 고민…

개인화는? (Not batch, On the fly Model)
Model 에 즉각적인 최신성 반영은?
운영 중 즉각적인 무 중지 배포는?
Auto Scale Out / Auto Scale Down 은?

MELTINGCON
COMMUNITY
ALLIANCE

BigData Scale Deep Learning!
Drill down~~

4. 최근에 시도한 방식(serverless public cloud)

국내 상위 쇼핑몰 정도 트래픽,
요즘 트랜디한 개인화 추천 정도 하려고 해도...

MELTINGCON
COMMUNITY
ALLIANCE

- 더 이상 Analytics 자체는 경쟁력이 아니다.
- 더 이상 Machine Learning 자체는 진입 장벽이 아니다.
- Deep Learning 은 아직까지는 경쟁력이나, 점점 툴이 막강해지고, 쉬워지고 있다.
- BigData Scale Machine Learning 도 경쟁력이다. (최신성 + Big Scale + 개인화)
- 더 더 어려운 문제는 **Advanced Analytics** 의 결과물을 **개인화** 하여 노출하고, 그 **반응**을 다시 **실시간**으로 모델에 리턴 하여, 그로부터 즉각적인 **선순환 시스템을** 만든 것 이다. (예, 고객 실시간 검색 히스토리, 클릭 스트림 에 반응하는 Dynamic 한 개인화 추천. 개인화 된 Dynamic Pricing 모델, Enterprise Full Stack Chatbot 등)
- **Machine Learning / Deep Learning 시스템에 있어서 Serving Layer 의 중요성**

BigData + MicroService + DevOps + Auto Scale Out Training + Auto Scale Out Serving 은
목표 Motive 를 달성하기 위해서는, 선택이 아닌 필수

국내 상위 쇼핑몰 정도 트래픽,
요즘 트랜디한 개인화 추천 정도 하려고 해도…

MELTINGCON
COMMUNITY
ALLIANCE

- RDBMS -> 현존 최고 HW 로 Oracle 5 Node 로도…

- MariaDB 샤딩 시스템. 수천대. Select 부하분산.
- 큰 테이블 Data 는? Insert & Update 는?

- NoSQL + RDBMS 샤딩(R) + RDBMS Master for (CUD)
  + Kafka (Message Queue for Data Sync)
- 복잡한 RDBMS 로직 SQL => NoSQL 로 마이그레이션 불가???

- NoSQL + RDBMS 샤딩(R) + RDBMS Master for (CUD)
  + Kafka (Message Queue for Data Sync) + Redis(Memory Cache)
  + MicroService (Scale Out WAS for 복잡한 Business Logic 의 Application layer 처리)
  + Machine Learning/Deep Learning Training/Serving Layer Auto Scale Out Infra 구성
    (예, Tensorflow Serving PaaS 혹은 flask Serverless Microservice) + 기타(Docker, DevOps…)

Training Layer
와,
Serving Layer
는 아키텍처가
또 다름.

MELTINGCON
COMMUNITY
ALLIANCE

우리가 추가로 했던 시도 들...

Horovod(by uber) with Tensorflow, Keras

MELTINGCON COMMUNITY ALLIANCE

Why not traditional Distributed TensorFlow?

The primary motivation for this project is to make it easy to take a single-GPU TensorFlow program and successfully train it on many GPUs faster. This has two aspects:

1. How much modifications does one have to make to a program to make it distributed, and how easy is it to run it.
2. How much faster would it run in distributed mode?

Internally at Uber we found the MPI model to be much more straightforward and require far less code changes than the Distributed TensorFlow with parameter servers. See the Usage section for more details.

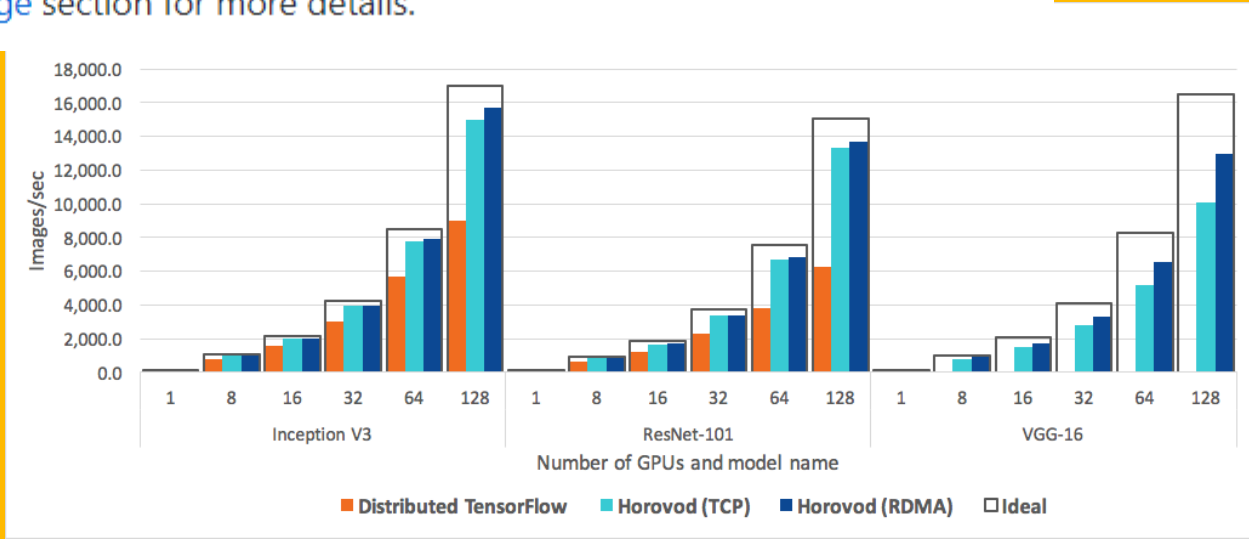

Keras Scale Up vs. Horovod Scale Out

MELTINGCON COMMUNITY ALLIANCE

http://hoondongkim.blogspot.kr/2018/01/deep-learning-multi-host-multi-gpu_11.html

GPU Scale Up (with tensorflow + Keras)	수행시간
1Node 1GPU	150
1Node 2GPU	127
1Node 4GPU	82

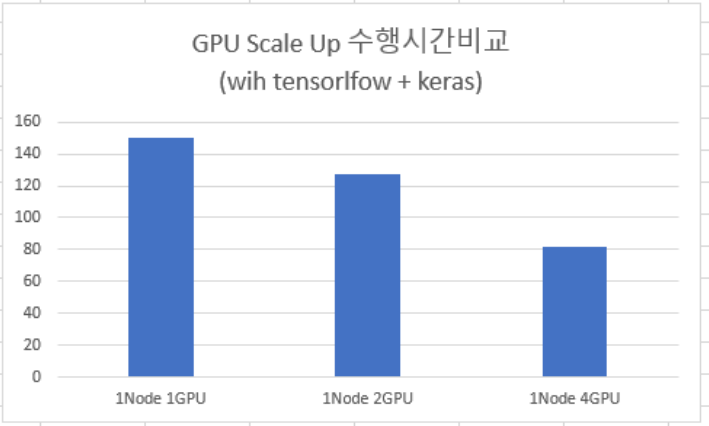

GPU Scale Out (with tensorflow + keras + Horovod)	수행시간
1GPU 1Node	166
1GPU 2Node	143
1GPU 4Node	89

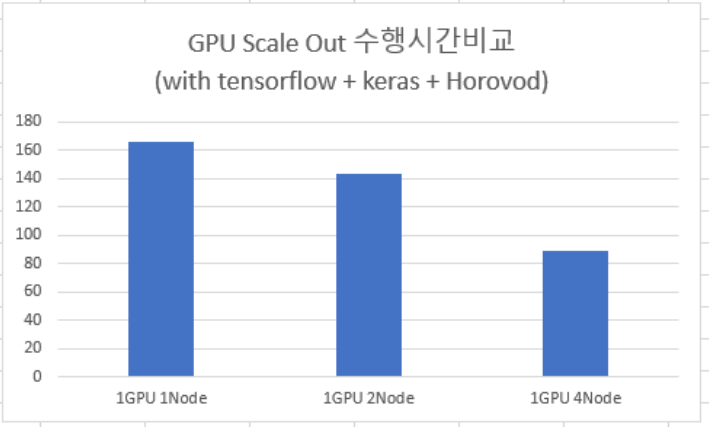

Deep Learning Online Inference
CPU vs GPU (1 time Inference. BatchSize=1)

MELTINGCON
COMMUNITY
ALLIANCE

http://hoondongkim.blogspot.kr/2017/12/deep-learning-inference-serving.html

동접 테스트

CPU Serving : 1 Machine 265 TPS
GPU Serving : 1 Machine 16 TPS

CPU 1000 Times Serial Execution

```
In [40]: %%time
         for i in range(0,1000):
             model.predict_classes(predictTokenizer('비밀 번호를 잃어버렸어요 그래서 로그인이 안되요'),verbose=0)
```

executed in 21.6s, finished 05:49:06 2017-12-16

```
CPU times: user 1min 7s, sys: 20.6 s, total: 1min 28s
Wall time: 21.6 s
```

```
In [41]: %%time
         token = predictTokenizer('비밀 번호를 잃어버렸어요 그래서 로그인이 안되요')
         for i in range(0,1000):
             model.predict_classes(token,verbose=0)
```

executed in 20.0s, finished 05:49:32 2017-12-16

```
CPU times: user 1min 4s, sys: 21 s, total: 1min 25s
Wall time: 20 s
```

GPU 1000 Times Serial Execution

```
In [46]: %%time
         for i in range(0,1000):
             model.predict_classes(predictTokenizer('비밀 번호를 잃어버렸어요 그래서 로그인이 안되요'),verbose=0)
```

```
CPU times: user 58.3 s, sys: 2.06 s, total: 1min
Wall time: 59 s
```

```
In [45]: %%time
         token = predictTokenizer('비밀 번호를 잃어버렸어요 그래서 로그인이 안되요')
         for i in range(0,1000):
             model.predict_classes(token,verbose=0)
```

```
CPU times: user 57.8 s, sys: 1.96 s, total: 59.8 s
Wall time: 58.2 s
```

Deep Learning Online Inference
CPU vs GPU (1 time Inference. BatchSize=1)

MELTINGCON
COMMUNITY
ALLIANCE

http://hoondongkim.blogspot.kr/2017/12/deep-learning-inference-serving.html

1. Async + Auto Scale Out
을 추가!

2. 속도가 받쳐주면, Model 을 Fix 하지 않아도 된다.

3. [궁극에는] Online Training + Realtime Inference 를
한번에

MELTINGCON
COMMUNITY
ALLIANCE

Engineering Art!

Async & Auto Scale Out

for
양방향 Inference Layer!

Inference Layer 가 사용자 세션 타임 내에 원순환 구조로 Online Training??? 을?

Engineering Art!

MELTINGCON COMMUNITY ALLIANCE

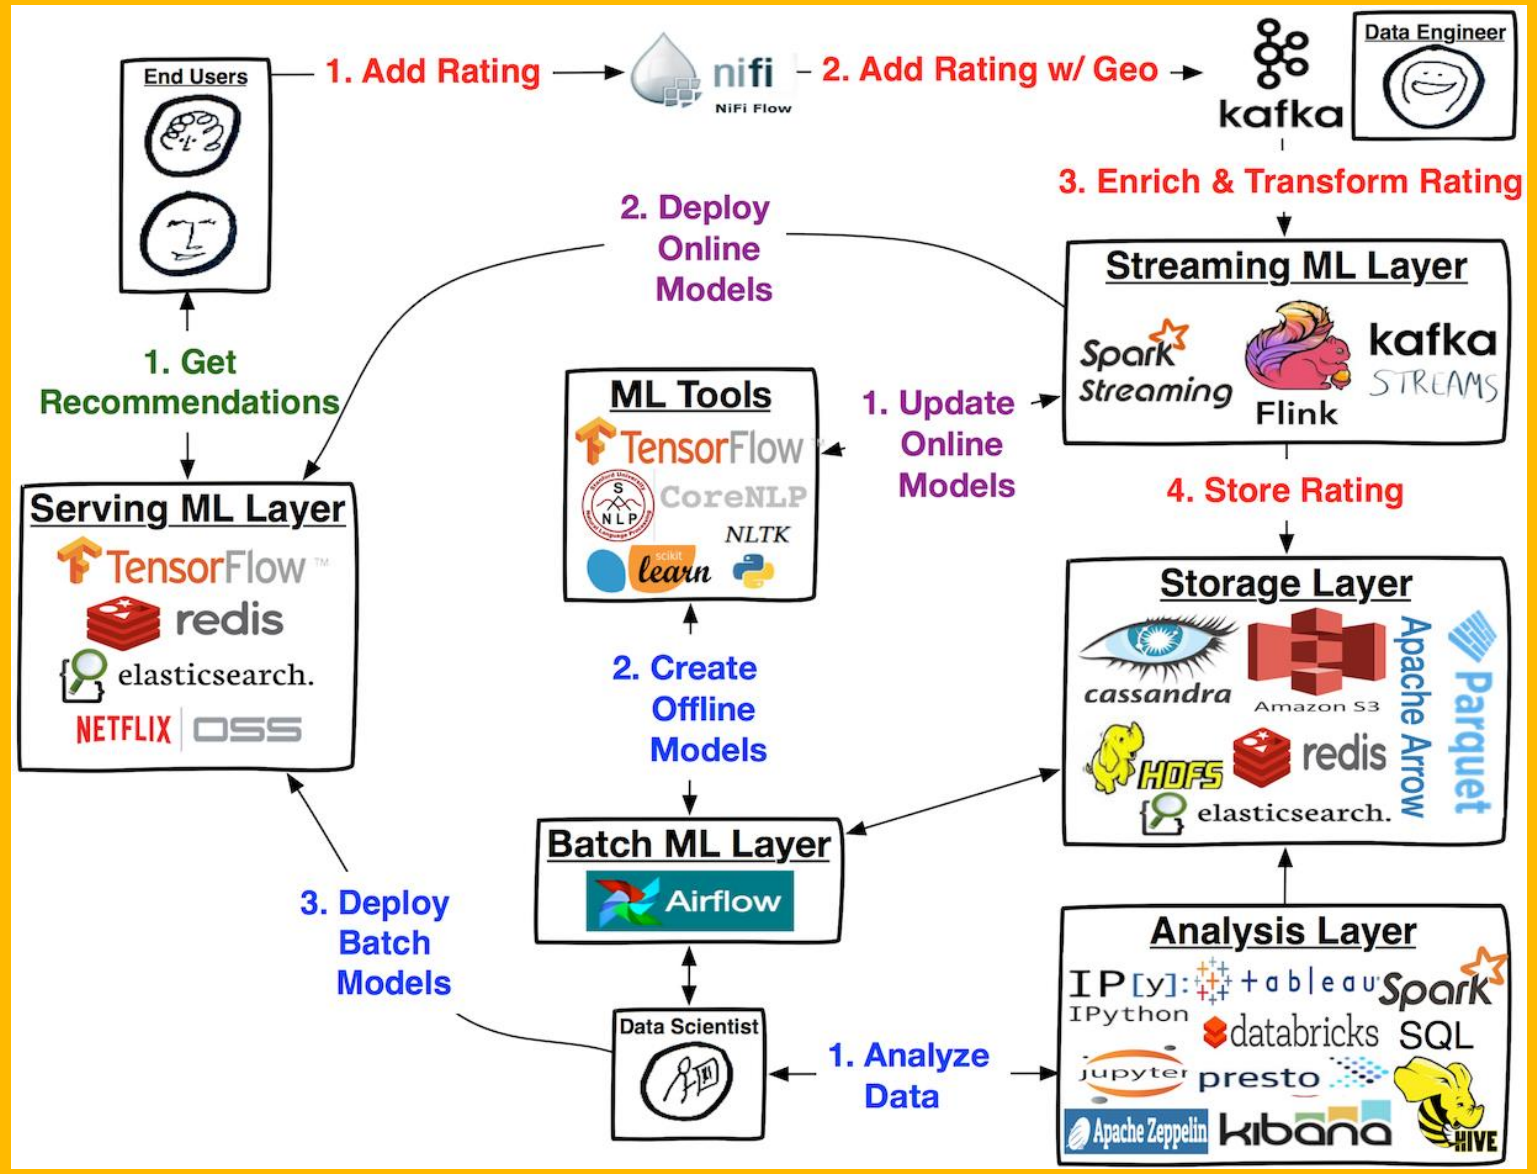

Auto Scale Out
Deep Learning Training On Cloud PaaS

MELTINGCON
COMMUNITY
ALLIANCE

http://hoondongkim.blogspot.kr/2018/01/deep-learning-multi-host-multi-gpu.html

Tensorflow + Keras + Horovod + Azure Batch AI

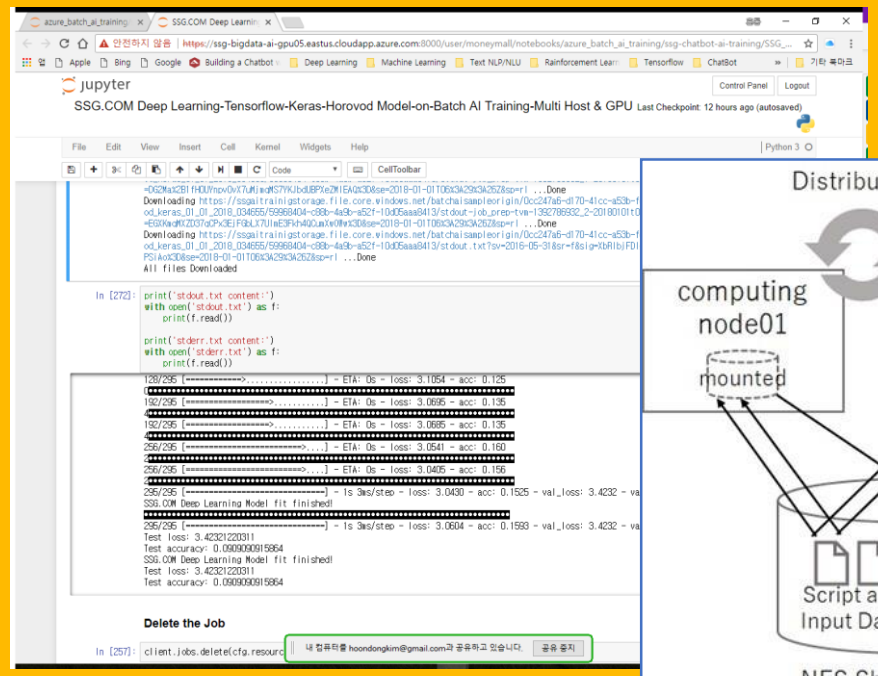

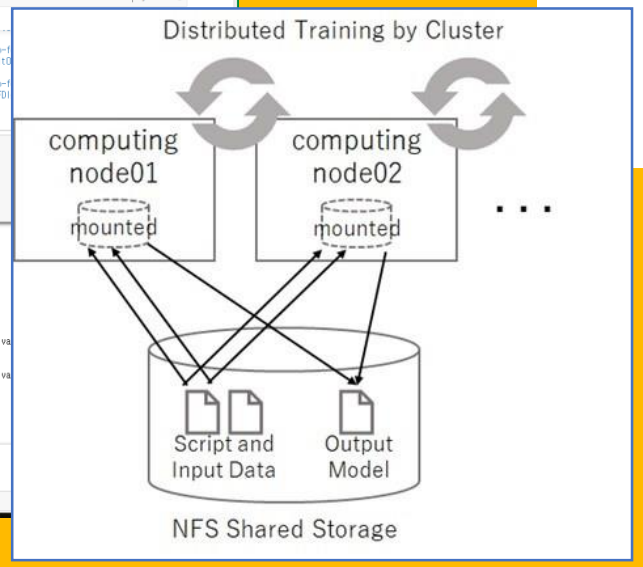

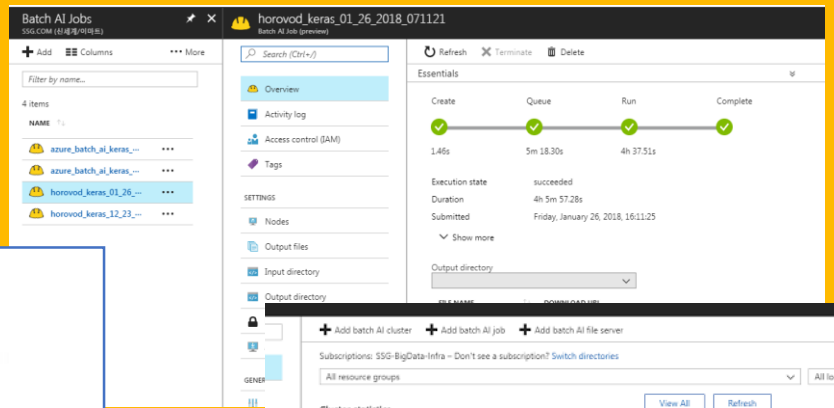

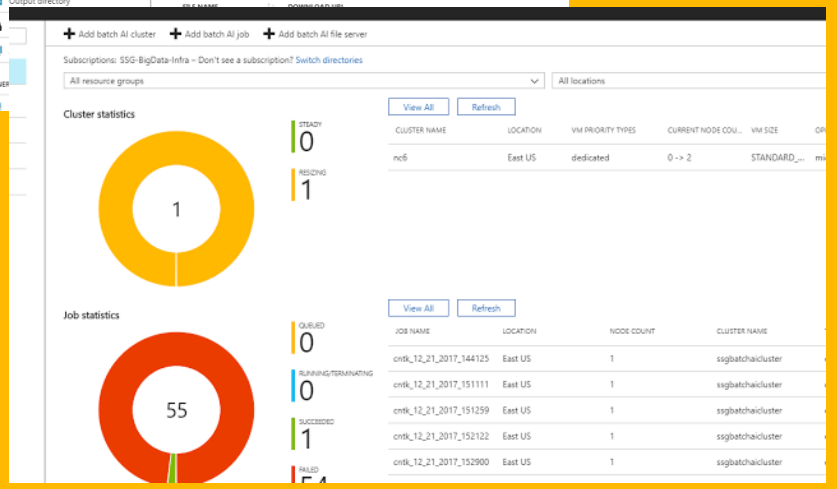

Serverless Architecture AI Service 구성

MELTINGCON
COMMUNITY
ALLIANCE

Serverless Architecture (For BigData Scale Deep Learning AI Production On Azure)

- **BaaS (Backend as a Service)**
  - **Web App :** Web 및 Admin 관리
  - **Web App for Linux Container :** Container 를 커스터마이징 할 수 있으나, Container 관리는 위임.
  - **Azure Batch AI**
  - **Azure Batch**
- **FaaS (Function as a Service)**
  - **Azure Function**
  - **Logic App**
- **기타, Serverless PaaS 및 SaaS**
  - **Cosmos DB**
  - **Application Insight**
  - **Container Registry**
  - **Conatiner Web Hook**
- **CI/CD PaaS**
  - **Team Service**
  - **Github Enterprise**

Why Not Tensorflow Serving?

MELTINGCON
COMMUNITY
ALLIANCE

1.Over the GRPC
    1.이를 Web Service 화 하기 위해서는 별도의 Tier 가 필요하다.
    2.이에 대한 방법론은 뒤에서 다시 언급…
2.Over the Tensorflow. (Keras , CNTK , Spark ML , BigDL, Deep Learning 4j, etc …)
    1.물론 Keras 를 Serialize 및 Tensorflow Graph 로 Model Export 하고, 이를 로딩하는 Client 를 만드는 경우 Keras 를 Tensorflow Serving 하는 것이 불가능 하진 않음.
3.Tesorflow Serving is only published for Python2
    1.물론 수동 빌드로 Python3에서 구동하는 것이 불가능하진 않지만…
4.Training 과 Serving 을 동시에??
    1.물론 이 시나리오는 Serving 최적화를 포기해야만 가능.
    2.Scale Out 모델에서, 성능이 어느 정도 나온다면…

On-premise Docker 가 아닌 Serverless PaaS 상의 자동 관리 Docker 라고 한다면, 구성이 무겁거나 복잡한 것보다, 가볍고 단순하며, Debug가 유리한 것이 더 현실적임.

MELTINGCON
COMMUNITY
ALLIANCE

SSG닷컴, MS 애저 기반 AI 챗봇 서비스 구축

한편 이번 챗봇 서비스는 신세계에서 오픈소스 기술로 자체 개발한 AI 모델을 적용해 개발했다. 이는 MS 클라우드 서비스 '애저'에서 제공되는 다양한 플랫폼 기술을 활용해 가동된다. 고객 접점에서 사용자 요청을 1차 처리하는 부분에는 서버리스 기술인 애저 펑션, AI 트레이닝에 필요한 GPU 자원과 작업을 관리하는 기술은 애저 배치 AI 서비스, 사용자 질문의 의도를 분석하고 처리하는 작업은 애저 PaaS와 도커 기술 상에서 구현됐다.

"사진만 찍었는데 잇템 찾아준다"… 신세계몰, 이미지 검색 서비스 '쓱렌즈' 시작

딥러닝 이미지 검색, 1:1 챗봇 등 유통업계에서도 인공지능 바람

진범용 기자 프로필보기 | 최종편집 2018.05.08 09:21:19

글자크기

▲쓱렌즈 화면 캡처. ⓒ신세계백화점

성능에 대하여 …

MELTINGCON
COMMUNITY
ALLIANCE

http://hoondongkim.blogspot.kr/2017/12/deep-learning-inference-serving.html

Azure Data Science VM	12 vCore CPU * 112gb Memory * 1 VM	Tesla K80 * 2 GPU * 112gb Memory * 1 VM
Flask + tensorflow	270 TPS	16 TPS
Flask + ****** + tensorflow	883 TPS	17 TPS
**** + Flask + ***** + ****** + tensorflow	2633 TPS	15 TPS

Azure Web App for Linux Docker	4 vCore * 1 Docker	4 vCore * 5 Docker	4 vCore * 10 Docker
Flask + tensorflow	132 TPS	634 TPS	1281 TPS
Flask + ****** + tensorflow	485 TPS	2260 TPS	4627 TPS
**** + Flask + ***** + ****** + tensorflow	1207 TPS	5538 TPS	11529 TPS

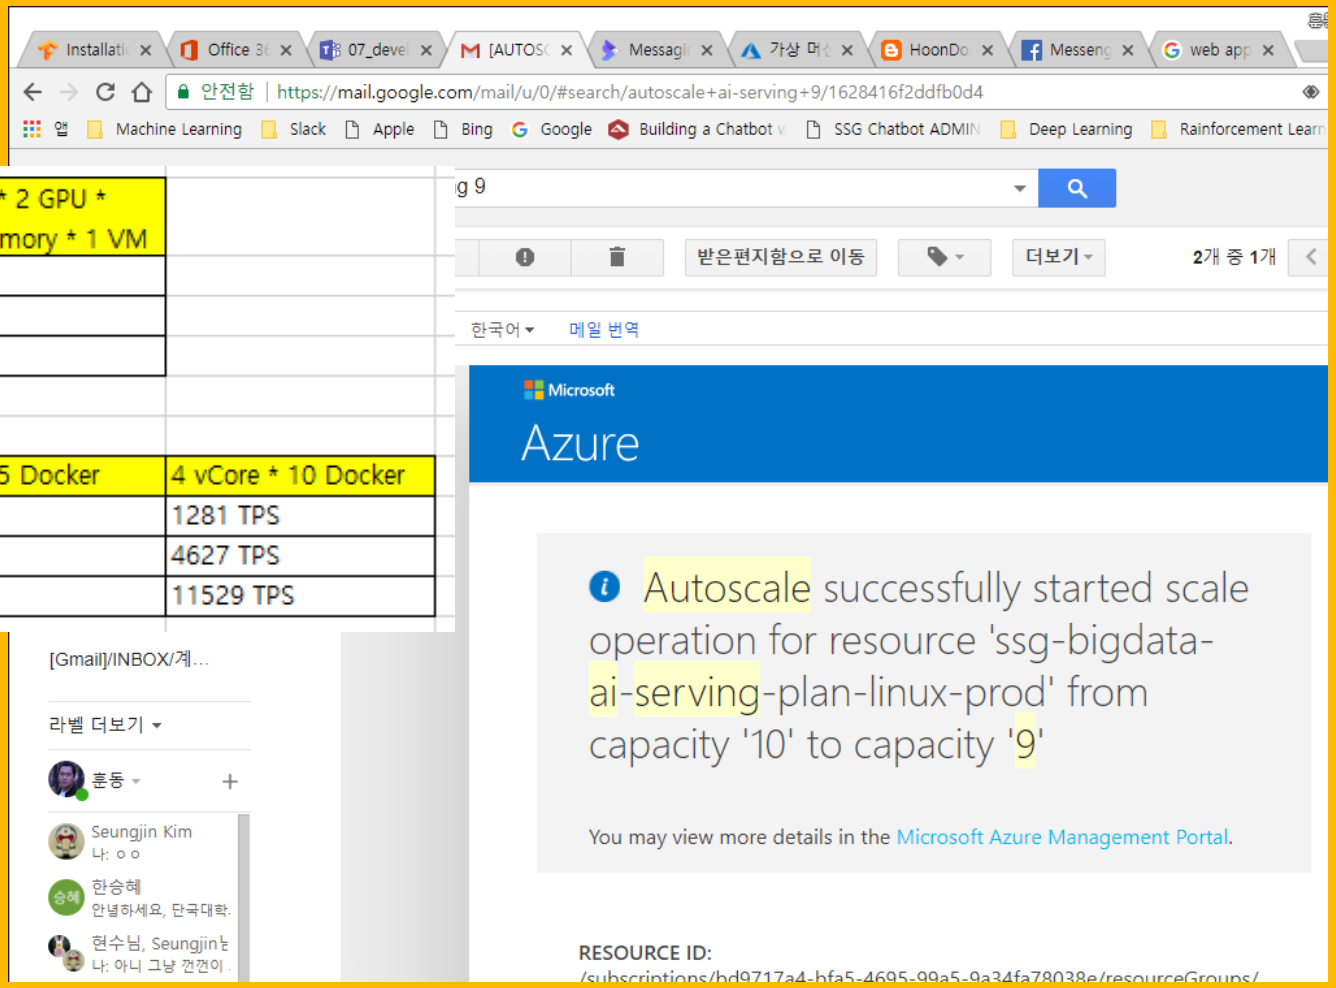

MELTINGCON
COMMUNITY
ALLIANCE

Conclusion!

결론!

[1]~[3] 각 레이어의 관계는?

MELTINGCON
COMMUNITY
ALLIANCE

- [1] RDB Sharding, Web, App, Front Tech… 는 기본 중에 기본.
- [2] BigData, NoSQL, Microservice, Analytics 는?
- [3] AI(Machine Learning, Deep Learning) 는?

각각 경쟁관계가 아님.
상호 보완 관계이고,
장단점이 극명 함.

Production 으로 가면..

종합 예술이다!

Engineering Art 다!

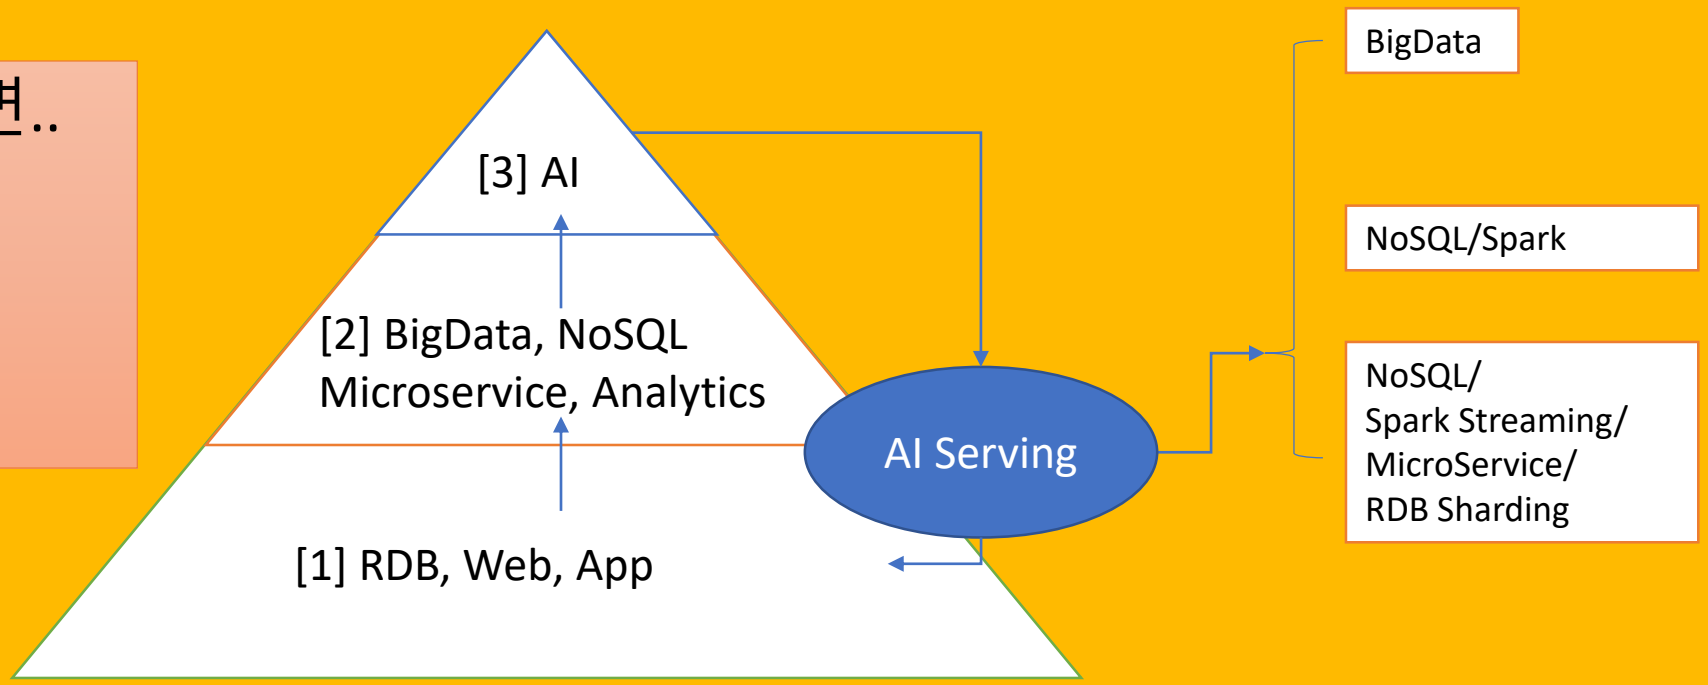

다 직접 개발하는 것이 능사는 아니다!

MELTINGCON
COMMUNITY
ALLIANCE

집단 지성의 힘!
검증된 것들을 Mesh Up!
핵심경쟁력이 아닌 것은 빠르게 하는 것이 더 좋음....
(Over Engineering 방지)

(Open Source + Cloud PaaS)

요즘 가장 Hot 한 Develop 방식이 추구하는 것들...

- No-Ops (or Dev Ops)
- Scale
- Low Cost
- Performance

AI 시대에 임하는 자세!

MELTINGCON
COMMUNITY
ALLIANCE

- Think Big.
  - 길게 보고 Plan을 세우자.
  - 당장의 효과에 연연하지 말자.
- Bottom Up! (Not Top Down!)
  - 유행에 편승해서, 혹은 윗 분들의 지시에 의해서가 아닌,
  - 실무자들에 의해 기획하고,
  - 내부 개발자 내재화를 고려하며 개발하도록 하자.
- 작게 그리고 빠르게 시작하자.
  - 금년에 시작한다면, 10살 수준이고, 2~3년이 지나야 15살 수준이 될 수도 있지만, 1~2년 뒤에 시작하면, 평생 경쟁사보다 동생일 수 있음.
- Mesh Up 하고, 결합 Merge 하고, 반복 개선 시키자.

ServerIsee PaaS , Cloud 의 많은 기술을 응용하면, AI도 BigData 도, BigData가 결합된 AI도, INFRA, Framework 의 많은 부분을 추상화 하여, 빠른 진입이 가능하다.

Thank You

MELTINGCON
COMMUNITY
ALLIANCE

- 기타 문의는...
- http://hoondongkim.blogspot.kr
- https://www.facebook.com/kim.hoondong