



A hálózat- és szolgáltatásmenedzsment legújabb irányai

Dr. Varga Pál

BME

Távközlési és
MédiaInformatikai Tanszék

SmartComLab

6. Magyar Jövő Internet Konferencia

Áttekintés

- Motiváció
- A funkcionális komplexitás kihívásai
- Az adatsebesség-növekedés kihívásai
- Igény az egyszerűsítés felé – Zero Touch Provisioning
- A Mesterséges Intelligencia bevetése
- Konkrét példa: Hálózati késleltetések előrejelzése Deep Learning segítségével

A funkcionális komplexitás kihívásai



1916-17 – Jenny JN-4
Cockpit




Airbus A380 cockpit

A hálózat- és szolgáltatásmenedzsment legújabb
irányai

Varga Pál

A funkcionális komplexitás kihívásai - válasz



A régi jó FCAPS model
(Telecommunications
Management Network)


A hálózat- és szolgáltatásmenedzsment legújabb
irányai

Varga Pál


Az adatsebesség-növekedés kihívásai

- 100Gbit/s Ethernet: üzenetek 6.7ns-onként
- 10 ms alatt milliós nagyságrendű üzenet-darabszám
- Mit tehetünk nagy adatsűrűségű adatközpontban, IPX-ben?
- Speciális hardware-követelmények
 - Helyben (a NIC-en) történő elő-feldolgozás
 - FPGA-alapú gyorsítás


Példa Hit-and-Run DDoS támadásra – és ms-nagyságrendű kiszűrésére



Példa: mennyi támadó-forgalom jut át végül...?



Gyors támadás-sorozatok kiszűrése




A hálózat- és szolgáltatásmenedzsment legújabb irányai

Varga Pál

Zero-Touch Provisioning – Hálózati eszközök

- Egy régi álom válik valóra (?)
- One-touch provisioning
 - Csak elindítani kell...
- Zero-touch provisioning
 - Csak áramot kell neki adni...
 - Felismeri a hálózatot
 - „Megszerzi” a saját konfigurációját
 - „Felkonfigurálja” önmagát
 - Elindul az új konfigurációval



A Mesterséges Intelligencia alkalmazásai a hálózat-menedzsmentben...

- Néhány példa a közelmúltból...
 - Intrusion Detection System by *Autoencoders*
 - IDS by *Edge Machine Learning*
 - Traffic Modeling by *Generative Adversarial Neural Networks*
 - Data Clustering by *Sparse Autoencoders*
 - *Predicting* RTT-distributions by *ML*
 - Real-Time Traffic Generation for 5G powered by *ML*
 - NFV Resource Allocation with *Deep Reinforcement Learning*
 - *Learning* NFV Deployment Models
 - ...

A hálózat- és szolgáltatásmenedzsment legújabb irányai

Deep Learning alkalmazás-példák


a'la FCAPS

DEEP LEARNING APPLICATION EXAMPLES OF FCAPS TASKS IN THE MOBILE TELECOMMUNICATIONS DOMAIN

Management area	Prediction	Anomaly Detection	Clustering or Classification
Fault management	Fault Prediction; Automated Mitigation	Fault Detection; Root Cause Analysis	Alarm Correlation
Configuration management	Resource Optimization (SDN, Base Station power adjustment, Cloud resource allocation)	Configuration pattern recognition	Realizing similarities or differences in node configs
Accounting management	Churn prediction; Service utilization prediction	Misuse or Fraud	Traffic characterization; Usage profiling
Performance management	Utilization prediction (feeding Config. mgmt.)	Detecting under- or over-utilization of segments	Resource Planning QoS and QoE correlation
Security management	Intrusion Prevention	Detection of suspicious activities DDoS Detection	Intrusion Detection

Esettanulmány: **hiba-predikció** a hívásfelépítés szakasz-késleltetése alapján

- Cél: VoLTE hívásfelépítési hiba-gócok előrejelzése
- Megtanulni a korrelációt a hálózati csomópontok késleltetése és a következő időszak hibái között
- Megmutatni „időjárás-jelentési” előrejelzést – merrefelé várjunk miféle hiba-viharokat



A hálózat- és szolgáltatásmenedzsment legújabb irányai

Adat


- **64,538,731** bejegyzés
- **38,051,225** session az adatsorban. Az egy-elemű session-ök eldobásra kerültek. 27,065,354 ilyen volt; eldobásuk után
- 37,473,377 bejegyzés és
- **10,985,871** session maradt.
- Az időkülönbség minden kommunikációs lépésben, minden session-ra kiszámolásra került. Az első elemek eldobva.
- Eredmény: **26,487,506** bejegyzés.

Minden „hop” bemenő bejegyzése:

- Timestamp,
- Source IP,
- Destination IP,
- CSID,
- Status code of the response message to the INVITE.

Példa emenet: time-steps (60), feaures (5), category pairs (10)


Features: mean, standard deviation, minimum,
maximum and median of time differences



Melegebb
színek:
Magaabb érték


Sötétebbek:
alacsonyabb.

Az alkalmazott deep convolutional neural network architektúra



A hálózat- és szolgáltatásmenedzsment legújabb
irányai

Ground truth (blue) and predictions on test dataset (red) of the # of errors in the next time step for each node category pairs (1 sec. resampling)



Y axis (different scales):
moving average of the number of errors in
the next time step (window size: 100).

X axis: time

Összefoglalás

- A funkcionális komplexitás kihívásai
- Az adatsebesség-növekedés kihívásai
 - Intrusion Prevention System példa
- Igény az egyszerűsítés felé
 - Zero Touch Provisioning
- A Mesterséges Intelligencia bevetése
- Konkrét példa: Hálózati késleltetések előrejelzése Deep Learning segítségével

Köszönöm a figyelmet!



Pal Varga

pvarga@tmit.bme.hu