



Aalto-yliopisto  
Perustieteiden  
korkeakoulu

# Konvoluutioverkon suorituskyvyn vertailu HD-videon viantunnistuksesta käyttäen SD-videolla koulutettua mallia.

*Juuso Varho*

*01.12.2023*

Ohjaaja: Iikka Virkkunen

Valvoja: Nuutti Hyvönen

Työn saa tallentaa ja julkistaa Aalto-yliopiston avoimilla verkkosivuilla. Muilta osin kaikki oikeudet pidätetään.

# Tausta

- Ydinvoimaloiden turvallinen käyttö vaatii säännöllisen rakenteiden tarkastamisen
  - Esimerkkinä Loviisan ydinvoimala, jonka reaktoreille tehdään visuaalinen tarkastus joka 4. vuosi (1).
- Visuaalinen tarkastaminen tapahtuu usein tiukalla aikataululla usein ympärivuorokautisesti
  - Inhimillisistä tekijöistä johtuen, vianlöytämistodennäköisyys voi pienentyä
- European Network for Inspection Qualification (ENIQ) recommended practice (2)
  - todetaan koneoppimisen käytön soveltuvan hyvin viantarkastustilanteisiin, jossa data voidaan digitalisoida.
  - Koneoppimismallin käyttö lisää tarkastamisen tasalaatuisuutta ja toistettavuutta.

# Tausta

- Trueflaw Oy on projektiyhteistyössä yhdysvaltalaisen Electric Power Research Institute (EPRI) kanssa kehittämässä koneoppimisen käyttöä visuaalisessa tarkastamisessa
- Aiemmissä tarkastuksissa käytetty SD-laatuista kameraa
  - Aiempaa tarkastusvideota saatavilla paljon
- Tarkastuksessa käytettävä kamera halutaan vaihtaa HD-laatuiseen
  - Koneoppimismallin kehittämiseen tarvittavaa HD dataa ei siis saatavilla
- SD dataa mahdollista muuttaa HD kokoon eri metodeilla
- Tutkimuksen aiheena on selvittää onko SD dataa mahdollista hyödyntää HD mallin kehityksessä, ja onko HD malli parempi löytämään vikoja

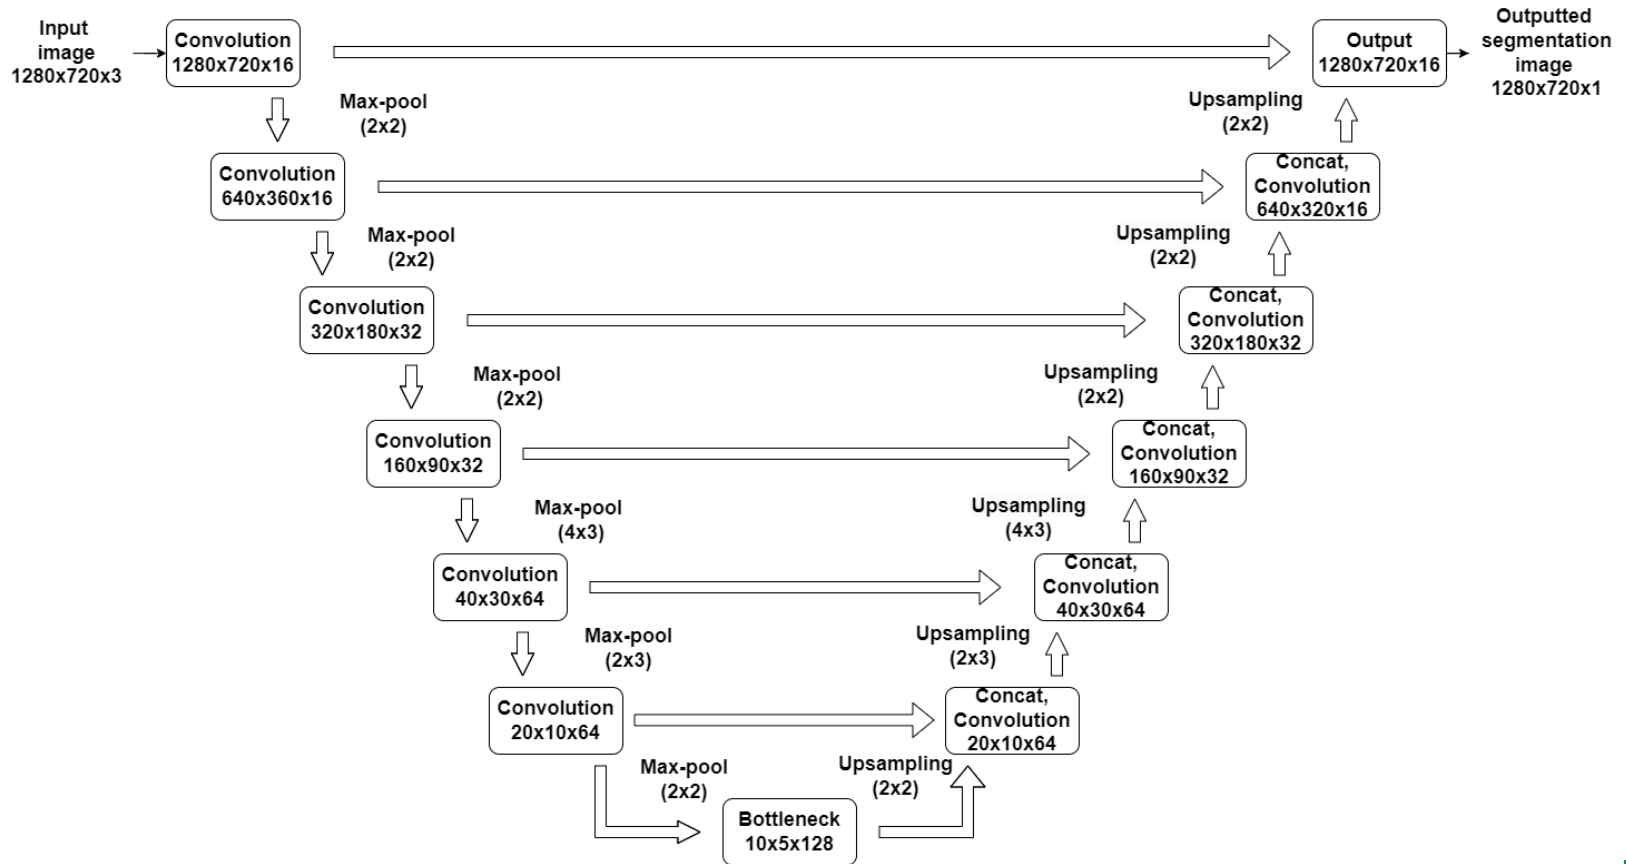
# Data

- Mallin kehitykseen on käytössä kolmenlaista data
  1. Tarkastusvideo
  2. Laboratorionäyte
  3. Virtuaalivika
- Kaikki käytössä oleva data SD kokoista
- Suurennetaan 3 eri tavalla
  1. Lisätään täytettä kuvan reunoille
  2. Suurennetaan kuva mahdollisimman isoksi
  3. Suurennetaan kuva satunnaiseen kokoon alkuperäisen ja suurimman väliltä

# Mallit

- Suurennustavoista saadaan 4 erilaista mallia
  1. Täytemetodi-malli (Padded only model)
  2. Suurin kokomuutos –malli (Max resize model)
  3. Satunnainen kokomuutos –malli (Random resize model)
  4. Täysi malli (Full model)
    - Käyttää jokaista mainittua kokomuutos metodia

# Käytetty u-net malli



# Segmentaatiometriikka

- Valitut segmentaatiometriikat ovat
  - Tarkkuus (Precision)
    - Kuinka suuri osuus ennustuksista oikein
  - Takaisinkutsu (Recall)
    - Kuinka suuri osa todellisesta maskista ennustettu oikein
  - F1
    - Harmoninen keskiarvo tarkkuudesta ja takaisinkutsusta
  - Leikkauksen suhde unioniin (Intersection Over Union (IOU))
    - Kertoo kuinka tarkasti ennustettu maski vastaa todellista annotointia


# NDT-metriikka

- Löytämisosuus (Hit percentage)
  - Kuinka suuri osuus kuvan säröistä löytyi
- Löytämättömät (Misses)
  - Kuinka moni kuvan säröistä jäi löytämättä
- Virhelöytö (False call)
  - Kuinka monta löytöä ennustettiin väärin
- Virhelöytö suuruus (False call size)
  - Kuinka monta pikseliä virhelöytö sisälsi
- Virhelöytöjen määrän ja suuruden tulo (Product of false call size and amount)
  - Virhelöytöjen määrän ja suuruuden yhteisvaikutuksen arviointiin käytettävä mittari



# Käsiannotoinnin vaikutus tuloksiin

- Testikuvat annotoitu käsin 6 pikselin levyisellä sivellintyökalulla (brush tool)
- Vertailussa käytettävä 'totuus'-maksi liian suuri, joka pienentää segmentaatiotuloksia
- Tuloksia mahdollista vertailla, koska tulokset ovat relatiivisia



# Testikuvien suurennus

- Jotta SD mallin ja HD mallin tulokset ovat vertailtavissa, tulee testidatan olla mahdollisimman samanlaista
- Testikuvat suurennetaan kahdella tapaa:
  1. Suurin kokomuutos
    - HD malleille SD kuvat suurennetaan 'bicubic' funktiolla mahdollisimman suureksi
    - SD mallille kuvalle ei tehdä muutoksia
  2. Lisätty täyte
    - HD malleille SD kuvien reunat täytetään nolla-pikseleillä, joka luo mustan reunuksen SD kuvan ympärille
    - SD mallille kuviin ensin lisätään täytettä jotta vastaavat HD kuvia, tämän jälkeen kuvaa pienennetään 'nearest neighbour' menetelmällä SD kokoon

# Segmentaatiotulokset

- Suurin kokomuutos:

Model	Precision	Recall	IOU50	IOU90	F1
Full model	0.673	<b>0.436</b>	<b>0.323</b>	<b>0.215</b>	<b>0.445</b>
Padded only model	0.667	0.394	0.316	0.204	0.438
Random resize model	0.667	0.368	0.299	0.172	0.418
Max resize model	0.636	0.374	0.288	0.176	0.402
SD model	<b>0.830</b>	0.315	0.301	0.086	0.404

- Lisätty täyte:

Model	Precision	Recall	IOU50	IOU90	F1
Full model	0.640	<b>0.570</b>	0.390	0.280	0.530
Padded only model	0.690	0.530	0.390	<b>0.290</b>	0.520
Random resize model	0.670	0.500	0.370	0.240	0.500
Max resize model	0.700	0.460	0.330	0.210	0.460
SD model	<b>0.844</b>	0.496	<b>0.444</b>	0.061	<b>0.601</b>

# NDT-metriikka

- Suurin kokomuutos:

Model	Hit percentage	Misses	False call average amount	False call average size	Product of false call size and amount
Full model	0.61	3.13	4.40	8.66	38.09
Padded only model	0.64	2.93	6.73	5.64	37.97
Random resize model	0.52	3.00	1.53	7.72	11.84
Max resize model	0.50	4.00	<b>0.87</b>	7.07	<b>6.13</b>
SD model	<b>0.83</b>	<b>1.47</b>	3.87	<b>3.64</b>	14.06

- Lisätty täyte:

Model	Hit percentage	Misses	False call average amount	False call average size	Product of false call size and amount
Full model	0.784	1.733	10.867	8.277	89.939
Padded only model	0.795	1.600	14.667	14.736	216.127
Random resize model	0.574	2.467	4.067	4.932	20.056
Max resize model	0.580	3.467	<b>0.800</b>	<b>4.890</b>	<b>3.912</b>
SD model	<b>0.886</b>	<b>1.000</b>	3.467	8.253	28.612

# Puhtaat testikuvat

- Suurin kokomuutos:

Model	IOU50	IOU90	F1	False call average amount	False call average size	Product of false call size and amount
Full model	0.99965	<b>0.99996</b>	0.99982	11.79	82.48	972.29
Padded only model	0.99947	0.99982	0.99973	23.21	55.12	1279.47
Random resize model	0.99954	0.99986	0.99977	11.09	<b>35.17</b>	<b>390.08</b>
Max resize model	<b>0.99973</b>	<b>0.99996</b>	<b>0.99986</b>	<b>6.00</b>	74.84	449.01
SD model	0.9985	0.9997	0.9993	19.61	43.74	857.56

- Lisätty täyte:

Model	IOU50	IOU90	F1	False call average amount	False call average size	Product of false call size and amount
Full model	0.9981	0.9995	0.9991	18.12	47.09	853.38
Padded only model	0.9977	0.9991	0.9989	30.88	64.78	2000.3
Random resize model	0.9981	0.9993	0.9990	13.67	28.09	383.9
Max resize model	<b>0.9990</b>	0.9997	<b>0.9995</b>	<b>6.94</b>	30.88	<b>214.25</b>
SD model	0.9985	<b>0.9998</b>	0.9993	23.12	<b>22.80</b>	527.14

# Diskussio

- HD mallien suoriutumiskyvyssä huomataan suurta vaihtelua kuvansuurennusmenetelmästä riippuen
- Huomataan HD malleissa herkkyseroja
  - Max resize –mallilla keskivertoa vähemmän virhelöytöjä, mutta löytää myös vähemmän oikeita vikoja
  - Padded only –malli hyvä löytämään ja segmentoimaan vikoja, mutta tuottaa enemmän virhelöytöjä
- Testikuvat SD laatuksia
  - Kuvansuurennusmenetelmät vaikuttavat kuvien laatuun

# Diskussio

- HD mallien suorituskyky parempaa täytetyillä testikuvilla
  - Kuvien suurentaminen voi heikentää vikojen terävyyttä, joka voi heikentää niiden löytämistä
- SD malli kykeni löytämään viat parhaiten kummallakin kuvansuurennustekniikalla
- Ero HD mallien suoriutumisessa ei estä SD datan hyödyntämistä tulevissa HD malleissa
- Kun HD laatuista tarkastusdataa on saatavilla, SD datan käyttö tulee uudelleenarvioida

# Johtopäätökset

- SD datalla kehitetty HD malli ei kyennyt löytämään vikoja paremmin kuin alkuperäinen HD malli
- HD mallit kuitenkin kyvykkäitä löytämään vikoja lähes yhtä hyvin kuin SD malli
- SD dataa on mahdollista käyttää tulevien HD mallien kehityksessä
  - Mallin suoriutumiskykyä mahdollista parantaa tulevissa versioissa
- SD datan vaikutus HD mallien suoriutumiskykyyn tulee tarkastaa uudelleen, kun HD laatuista tarkastudataa on saatavilla



# Tietolähteet/Aineistot

- (1.) Pirinen, J., Seppälä, P., Paussu, R., & Luostarinen, P. (2013). Remote Visual Inspections of RPV and Reactor Internals. 9th International Conference on NDE in Relation to Structural Integrity for Nuclear and Pressurized Components, May 22-24, 2012 - Seattle, Washington, USA. <https://www.ndt.net/?id=14744>
- (2.) Virkkunen, I., Bolander, M., Myöhänen, H., Miorelli, R., Johansson, O., Kicherer, P., ... & Martin, O. (2021). Qualification of Non-Destructive Testing Systems that Make Use of Machine Learning: ENIQ Recommended Practice 13.
- (3.) Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18 (pp. 234-241). Springer International Publishing.