

Suojateiden tunnistaminen ilmakuvista koneoppimisen avulla

Saska Lohi
Helsingin kaupunki, Kaupunkiympäristön toimiala
10.11.2022

Helsinki



Esityksen sisältö


- Taustaa
- Tekoälykokeilu ja sen eteneminen
- Mitä tämän jälkeen on tapahtunut

Tausta ja tarve

- Tiemerkintöihin liittyvä data on vanhentunutta (vuodelta 2014), eikä sitä enää ylläpidetä järjestelmällisesti resurssivajeen takia. 2022 on kuitenkin havahduttu tähän ja uusi päivitetty aineisto on valmisteilla
- Epäluotettava data ei ole hyvä lähtökohta toiminnalle, joten oli tarve saada tiemerkintädataa. Tuli idea siitä, että voisiko tätä louhia ilmakehän kuva-aineistoista
- Uuden tietöalustan kehitystyö on käynnissä, ja sille on tarkoitus tätä tiemerkintädataa jatkossa tallentaa ja ylläpitää
- Jos suojateiden tunnistaminen onnistuu, niin sen tuottamaa dataa voisi käyttää myös data-alustan testaamiseen
- Tavoitteena myös yleisemmin oppia tekoälyn hyödyntämisestä tällaiseen tiedon louhimiseen jo olemassa olevista tietöaineistoista, tässä tapauksessa ilmakehän kuvista
- Muotoiltiin haaste tekoälykokeiluksi kaupungin Kokeilukiihdyttämöön syksyllä 2019

Mikä tekoälykokeilu?

- 3 kuukautta aikaa
- 10 000 euroa budjettia
- Talvi 2020-21



Kokeilun eteneminen


- Kumppanina **Integrify** ja sen koodarikoululaiset
- Periaatteina ja lähtökohtina avoimuus ja läpinäkyvyys sekä molemminpuolinen oppiminen - hyödynnetään kaupungin avointa dataa ja avointa lähdekoodia
- Hyödynnettyinä aineistoina toimivat:
 - Ortoilmakuvat
 - Vääräväri-ilmakuvat
 - Inventoidut suojatievektorit (2014)
 - Muut karttapalvelusta saatavat kartta-aineistot

Helsinki



We develop code(rs)

We teach international talent software development and connect them with work.



Kokeilun eteneminen

HANKINTA

1. Datan kerääminen

2. Koneoppimisen mallin luominen

3. Mallin arviointi ja kehitys

AINEISTO
VISUALISOINTI


1. **Datan kerääminen.** Kartta.hel.fi kaupungin karttapalvelusta kerättiin ohjelmallisesti n. 3000 ilmakuvaa Helsingin alueelta. Mallin tarkkuuden parantamiseksi olisi ollut parempi jos saatavilla olisi ollut enemmän dataa. Tilannetta auttoi se, että pystyttiin hyödyntämään myös Espoon ja Vantaan kaupungin ilmakuvia. Mitä enemmän ja laadukkaampaa dataa on saatavilla, sitä parempi malli saadaan aikaiseksi.

2. Koneoppimisen mallin luonti: Data jaettiin opetusdataan ja testidataan. Opetusdataan eli jokaiseen ilmakuvaan merkittiin manuaalisesti suojateiden paikka.

Malli luotiin hyödyntämällä opetusdataa suojateiden tunnistamiseen eri koneoppimisen arkkitehtuurien avulla joita hienosäädettiin eri parametrien avulla. Näitä olivat RetinaNet, fast R-CNN ja Mask R-CNN. **Parhaan tarkkuuden tuotti RetinaNet.**

3. Mallin arviointi ja kehitys: Testidatan avulla mallin toimivuus validoitiin. Malli pystyy tunnistamaan suojatien noin 70-80% tarkkuudella. Tätä tarkkuutta voidaan parantaa opetusdatan määrän lisäämisellä.

Kokeilun eteneminen



Kokeilu käytännössä

- Pidimme säännöllisiä tapaamisia Integrifyn kehittäjien, opettajan ja liiketoimintakoordinaattorin kanssa
- Tapaamiset olivat todella opettavaisia! Vahva suositus



Kokeilu käytännössä

- KYMPin tiimi auttoi substanssiin liittyvien kysymysten ratkaisussa sekä opasti kaupungin avoimien datalähteiden äärelle
- Integrifyn tekoälykehittäjät vastasivat datan käsittelystä, mallien testaamisesta ja opettamisesta, Python-koodauksesta ym.
- Kuvantunnistukseen käytettiin RetinaNettiä, itse tuotantoputki rakennettiin Jupyter notebookeilla
- Datan labelointiin kului hyvin paljon aikaa Integrifyn opiskelijoilta
- Mallin opetus oli myös hidasta opiskelijoiden läppäreillä, mutta kun saatiin kokeilulle budjettia, niin pystyttiin ostamaan pilvestä laskentatehoa, ja kehitys nopeutui huomattavasti


Kokeilu käytännössä

- Tutkimme myös itse Jupyter-notebookeja
- Asensin työkoneelle virtuaalikoneeseen Linuxin jossa pystyin ajamaan notebookeja ja testailemaan itsekin

```
In [3]: from owslib.wms import WebMapService
import matplotlib.pyplot as plt
import os
from PIL import Image
import numpy as np
```

```
In [4]: im = Image.open("miscel_images/center_2.png")
imgar = np.array(im)
plt.imshow(im)
```

```
Out[4]: <matplotlib.image.AxesImage at 0x26ade335748>
```



```
In [5]: imgar.shape
```

```
Out[5]: (500, 500, 4)
```

```
In [6]: image_coordinate=[24.941622,24.942265,60.170725,60.171073]
```







```
In [7]: ##calculating width of a patch in terms of Latitude and Logitude
x_coordinate_interval=image_coordinate[1]-image_coordinate[0]
y_coordinate_interval=image_coordinate[3]-image_coordinate[2]
```

```
In [8]: #pedestrian crossing found with two bounding boxes
bb1=[344,390,491,479]
bb2=[333,291,484,365]
```

```
In [9]: ##calculating the ratio of coordinate to image size
image_size=(500,500)
one_ybounding_translation=y_coordinate_interval/image_size[0]
one_xbounding_translation=x_coordinate_interval/image_size[0]
print(one_ybounding_translation)
print(one_xbounding_translation)
```

```
6.960000000049149e-07
1.286000000003425e-06
```


Kokeilun tuotokset



Listataan koneoppimismallin tunnistetuista suojateistä tunnistuskehysten koordinaatit

	gml_id	id	vaylatyyppi	luokka	featurecode	html_color	min_x	max_y	max_x
0	klinj_suojatie.16704	16704	Suojatie	Suojatiet	12	400040	2.549730e+07	6672929.268	2.549730e+07
1	klinj_suojatie.16713	16713	Suojatie	Suojatiet	12	400040	2.549717e+07	6673374.486	2.549718e+07
2	klinj_suojatie.16741	16741	Suojatie	Suojatiet	12	400040	2.549733e+07	6672931.001	2.549733e+07
3	klinj_suojatie.16908	16908	Suojatie	Suojatiet	12	400040	2.549736e+07	6672770.811	2.549735e+07
4	klinj_suojatie.16910	16910	Suojatie	Suojatiet	12	400040	2.549735e+07	6672758.490	2.549734e+07
...	...	...	...	...	...	...	...	...	...

- Eteen tulleita haasteita kokeilun edetessä oli:
 - Kuvantunnistusmallien luotettavuus: esim. Vaaleat kattomateriaalit tunnistettiin virheellisesti suojateiksi – aineiston rajaamista esim. rakennusten osalta pohdittiin
 - Opetusdataa ei saatu tarpeeksi, jotta luokittelua olisi voitu tehdä luotettavasti.
 - Kokeilun alkuvaiheeseen kannattaa varata tarpeeksi aikaa. Erityisesti datan valmistelua ja nimiöintiä varten.

Tekninen ympäristö:

MALLIN LUOMINEN: Python – ohjelmointikielen työkalut:
RetinaNet, faster-R-CNN ja mask R-CNN syväoppimisen arkkitehtuureja.

DOKUMENTOINTI: **Jupyter Notebook –applikaatio**

MALLIN HARJOITTAMINEN:
Amazon EC2 – pilvipalvelun avulla.

Opit resursoinnista

- Aikaa kokeiluun meni **n. 4 kk**
- Opetusdatan luomiseen meni yllättävän paljon aikaa, mitä ei ehkä alussa osattu ottaa huomioon. Kaikkia tavoitteita ei saavutettu, sillä opetusdataa ei saatu nimettyä tarpeeksi.
 - Datan keräämisessä mukana pääsääntöisesti **3 henkilöä**
 - Koneoppimisen mallin luonti
 - Datan manuaalinen nimeäminen kesti **n. 5 päivää. Mukana n. 20 henkilöä.**
 - Koneoppimisen mallin kehittämisessä mukana **3 henkilöä**
 - Mallin arviointi ja kehitys
 - Mallin kouluttamiseen **n. 200 h.**
- Alkuvaiheeseen kannattaa varata tarpeeksi aikaa. Erityisesti datan valmistelua ja nimiöintiä varten.

Opit tekoälyn mahdollisuuksista

- Helsingin kaupungilla on paljon avointa dataa jota kannattaa hyödyntää palveluiden kehittämisessä. Jo pienillä panostuksilla voidaan saada tuloksia. Kokeilut ja haastekilpailut ovat helppo ja nopea tapa näiden mahdollisuuksien selvittämiseksi.
- Tärkeintä ehkä tässä kokeilemisessä on se, että se haastaa muuttamaan yhteisiä kaupungin sisäisiä toimintatapoja ja antanut uutta tietoa prosessin laadusta ja haasteista datan hyödyntämisestä läpi organisaatiorajojen. Kaupunkiympäristöön liittyvän tiedon tallentamisessa, seurannassa, analysoinnissa ja arvioinnissa on haasteensa.

Kokeilun jälkeen

- Kokeilu poiki yhden gradun Aalto-yliopistoon
- Tutkimuksessa vietiin hommaa vielä vähän pidemmälle ja pyrittiin kuntoluokittelemaan suojateitä




Figure 12: Example of category 1 zebra crossing.

Road marking condition monitoring and classification using deep learning for City of Helsinki

Dana Tokmurzina

School of Science

Thesis submitted for examination for the degree of Master of Science in Technology.

Espoo 26.09.2020

Thesis supervisor:


Prof. Alexander Jung

Thesis advisor:

M.Sc. Saska Lohi

Kokeilun jälkeen

- Kuva gradun mallin tekemistä luokituksista



Kokeilun jälkeen

- [Blogaus HRI.fi:ssä](#)



PAIVÄMÄÄRÄ

4.5.2020

KATEGORIAT

AJANKOHTAISTA

BLOGIT

AJANKOHTAISTA

Suojateiden tunnistaminen ilmakuvista koneoppimisen avulla – Helsingin kaupungin tekoälykokeilu

Helsingin kaupunki järjesti työntekijöilleen Kokeilukiihdyttämö-nimisen kokeilukampanjan syksyllä 2019. Kiihdyttämön puitteissa rahoitettiin seitsemää erilaista tekoälykokeilua, joiden tematiikka vaihteli kaupunkistrategian viestinnän tulkinnasta kulttuuripalvelujen suosittelevaan sekä suojateiden tunnistamiseen ilmakuvista.

Tässä artikkelissa tutustutaan hieman tarkemmin tähän viimeksi mainittuun kokeiluun, sillä siinä käytettiin lähtötietoina avointa dataa, ja sen tuottama aineistokin on tarkoitus saattaa jakoon avoimesti. Se myös osoittaa, kuinka valmiista tietoa-aineistoista hieman jatkojalostamalla voidaan irrottaa uusia aineistoja, suoraan käyttötarkpeeseen vastaten.

Kokeilun lähtötilanne

Helsingin kaupungin kaupunkiympäristön toimialalla on käynnissä liikenteenohjauslaitteiden (esim. tiemerkinnät, liikennemerkit, opasteet) tiedonhallintaan liittyvän alustan kehitystyö. Alusta olisi tulevaisuudessa myös suojateihin liittyvien tietojen tietovarasto. Nykyinen suojatieaineisto perustuu kaupunkimittauspalvelun keskilinja-aineistoon. Aineiston ylläpito on lopetettu vuonna 2014, joten esimerkiksi sitä uudempien kaupunginosien suojateista ei ole kattavaa aineistoa. Onkin siis ilmeinen tarve ajantasaiselle suojatieaineistolle.

Nykyään konenäköä hyödynnetään yleisesti liikennemerkkien tunnistamisessa katunäkymistä, joten tuli idea, että kenties tiemerkintöjä, kuten suojateita, pystyisi tunnistamaan ilmakuvista. Suojatiethän ovat ilmakuvissa varsin selkeästi tiestä erottuvia kohteita. Näin saataisiin suojatieaineisto ajan tasalle – sekä samalla dataa tiemerkinnöistä tekeillä olevan alustan testaamiseksi. Katunäkymiin verrattuna ilmakuvia oli saatavilla laajemmalla alueella, ja vieläpä avoimena datana.

Teköälyn tunnistamia suojateita Helsingistä.

Kiitoksia!

Erityisesti
Kokeilukiihdyttämölle
ja kokeilutiimille!

Suojateiden
tunnistaminen
koneoppimisen avulla
-tilanneraportti 24.1.2020

Helsinki

Fanny Minna Saska
Esko Virpi Katja