



Aalto-yliopisto  
Perustieteiden  
korkeakoulu

# 3D konvoluutioneuroverkkojen soveltamisesta piikiekkoinaisten analyysissä

*Otto Pajunen*

*12.2.2024*

*Ohjaaja: DI Mikko Vaulanen*

*Valvoja: Prof. Pauliina Ilmonen*

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

# Tausta 1/2

- Kandidaatintyö Murata Electronics Oy:n toimeksiannosta
- Analysoidaan Muratan keräämää dataa valmistetuista piikiekoista
  - Piikiekon elementtejä käytetään kiihtyvyyssantureissa
  - Kyseisten kiihtyvyyssanturien yleisin käyttökohde on henkilöautojen ajonvakautusjärjestelmät
  - Viallisten piikiekkojen löytäminen tärkeää


# Tausta 2/2

- Yhdessä piikiekossa on 3300 elementtiä, joista kukin kuvaa kuinka monta kappaletta tiettyä vikaluokkaa kyseisessä koordinaatissa on havaittu
- Tässä työssä listamuotoinen data muunnetaan bittikartoiksi (kuviksi) ja muunnetulle aineistolle tehdään klusterianalyysi

# Tavoite

- Ensimmäisenä tavoitteena on dimension pienentäminen
  - Dimension pienennyksessä käytetään 1) pääkomponentti-analyysiä (PCA) ja 2) konvoluutioneuroverkkoa (CNN)
  - PCA:n ja CNN:n tuloksia vertaillaan
- Toisena tavoitteena on klusteroida alempaan dimensioon kuvatut aineistot

Bittikartasta selviää missä kohdissa erästä kiekkoa 'vikaluokkaa 20' havaittiin



# Rajaukset

- Datan analysointi ja luokittelu käyttäen vain PCA:ta ja neuroverkkopohjaista enkooderia, muita mahdollisia dimension pienennysmenetelmiä ei käytetä
- Data kuvataan kaksi- tai kolmiulotteiseksi
- Klusterointi tehdään k:n-keskiarvon-menetelmällä

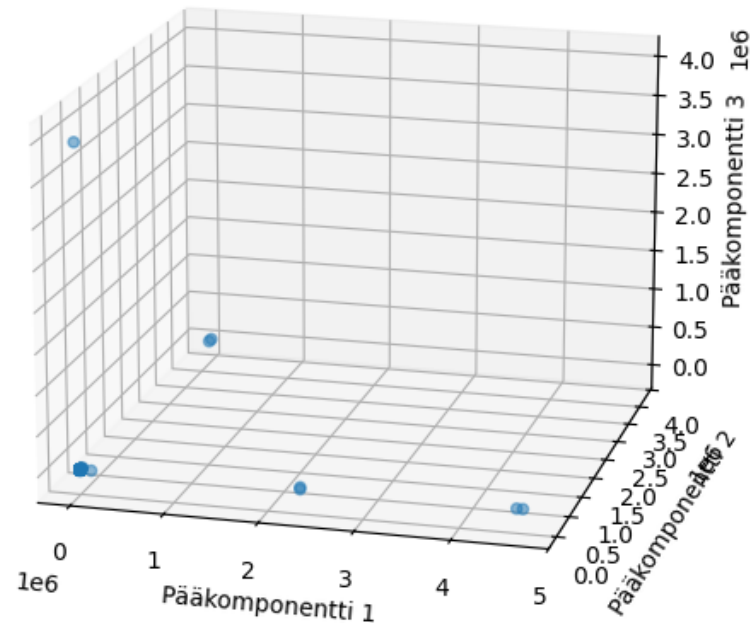
# Pääkomponenttianalyysi

- Aineisto skaalataan ja kanavien määrä muunnetaan yhdeksi
  - Datapisteitä muunnetaan niin, että aineiston keskiarvo on 0
  - Datapisteiden arvot jaetaan aineiston keskihajonnalla
- Pääkomponentit ovat vektoreita, jotka maksimoivat datakehikon varianssin suunnassa, johon ne osoittavat
- PCA on datakehikon projektio pääkomponenttien suuntaan

# Pääkomponenttianalyysi

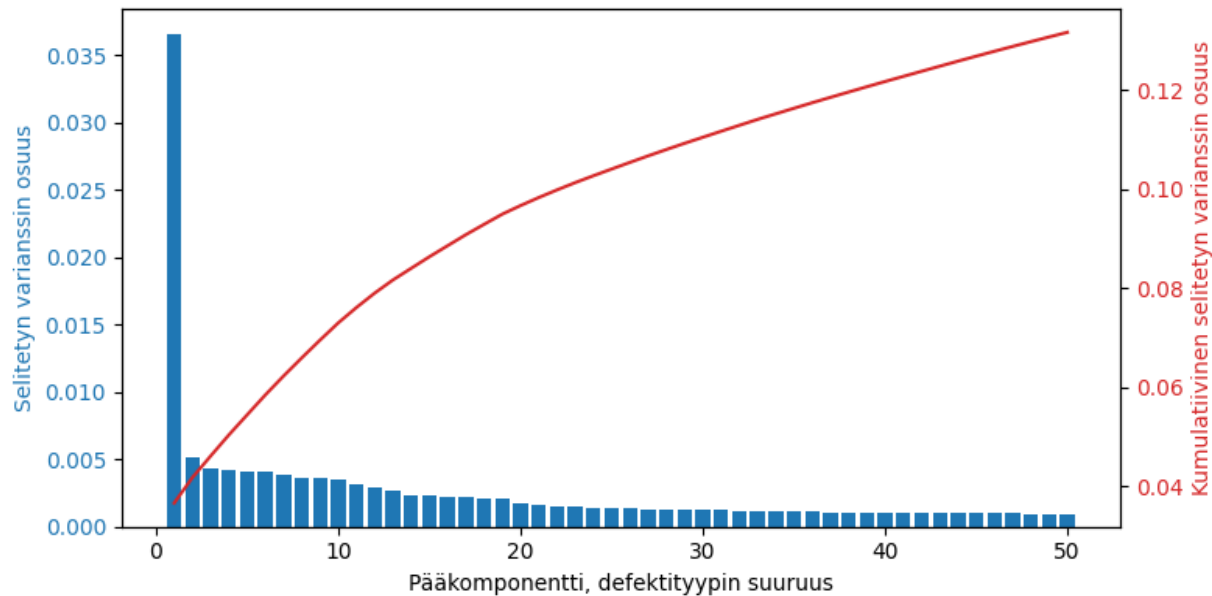
- Skaalaamaton tulos on käyttökelvoton

PCA: 3 komponenttia



# Pääkomponenttianalyysi

- Matala selitetty varianssi viittaa epälineaarisiin riippuvuuksiin






# Pääkomponenttianalyysi

- Projektiokoordinaattien kuvaus kahdessa ulottuvuudessa hukkaa liikaa tietoa

PCA: 3 komponenttia



# 3D konvoluutioneuroverkko

- Työn neuroverkko on monikanavainen
- Kanava sisältää kolmiulotteista dataa

Pehmustettu yksikanavainen "kuva"

0	0	0	0	0	0	0	0	0
0	5	0	8	7	8	1	0	0
0	1	9	5	0	7	7	0	0
0	6	0	2	4	6	6	0	0
0	9	7	6	6	8	4	0	0
0	8	3	8	5	1	3	0	0
0	7	2	7	0	1	0	0	0
0	0	0	0	0	0	0	0	0

1 x 1 x (6+2) x (6+2)

\*

0	1	0
1	-4	1
0	1	0

1 x 1 x 3 x 3


Askel = 1

=

Lopputulokset

-19	22	-20	-12	-17	11
16	-30	-1	23	-7	-14
-14	24	7	-2	1	-7
-15	-10	-1	-1	-15	1
-13	13	-11	-5	13	-7
-18	9	-18	13	-3	4


1 x 1 x 6 x 6



\*



=



Konvoluutio 2x2x2 maskilla, askel = 2

Pistetulo

9	5	0
0	2	4
7	6	6

x

0	1	0
1	-4	1
0	1	0

=

0	5	0
0	-8	4
0	6	0

Elementtien summa on 7

# 3D konvoluutioneuroverkko

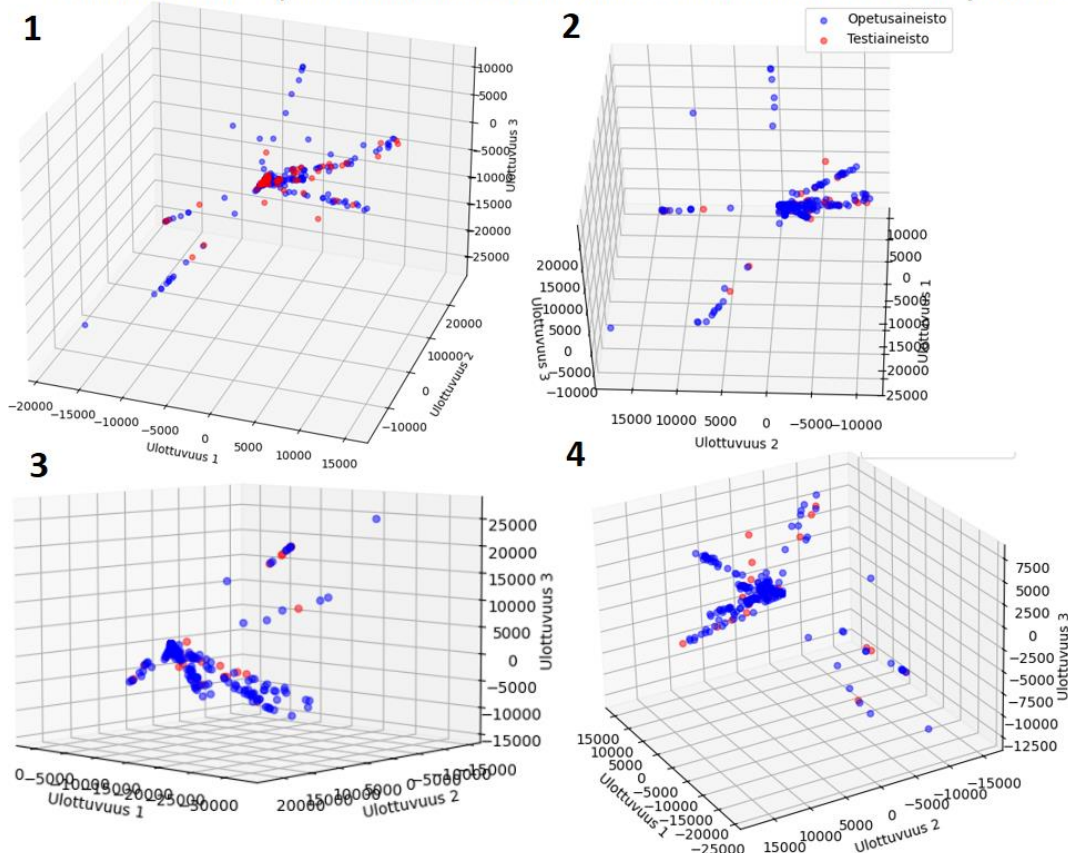
- Enkooderi eristetään koulutusvaiheen jälkeen

Kerros	Kanavat sisään → ulos	Dimensio ulos ( $z, x, y$ )	Maski, Askel
<b>Enkooderi</b>			
Konv1	14 → 32	$2 \times 109 \times 74$	$3 \times 3 \times 3, 1$
Konv2	32 → 64	$2 \times 55 \times 37$	$2 \times 3 \times 3, 2$
Norm1	64 → 64	$2 \times 55 \times 37$	-
Konv3	64 → 128	$2 \times 55 \times 37$	$3 \times 3 \times 3, 1$
Konv4	128 → 256	$1 \times 28 \times 19$	$2 \times 3 \times 3, 2$
Norm2	256 → 256	$1 \times 28 \times 19$	-
Lin1	256 → 1	$1 \times 256 \times 1$	-
Lin2	1 → 1	$1 \times 3 \times 1$	-
<b>Dekooderi</b>			
LinK1	1 → 1	$1 \times 256 \times 1$	-
LinK2	1 → 256	$1 \times 136192 \times 1$	-
KonvT1	256 → 128	$2 \times 55 \times 37$	$2 \times 3 \times 3, 2$
KonvT2	128 → 64	$2 \times 55 \times 37$	$3 \times 3 \times 3, 1$
KonvT3	64 → 32	$2 \times 109 \times 73$	$2 \times 3 \times 3, 2$
KonvT4	32 → 14	$2 \times 109 \times 74$	$3 \times 3 \times 3, 1$

# Enkooderi

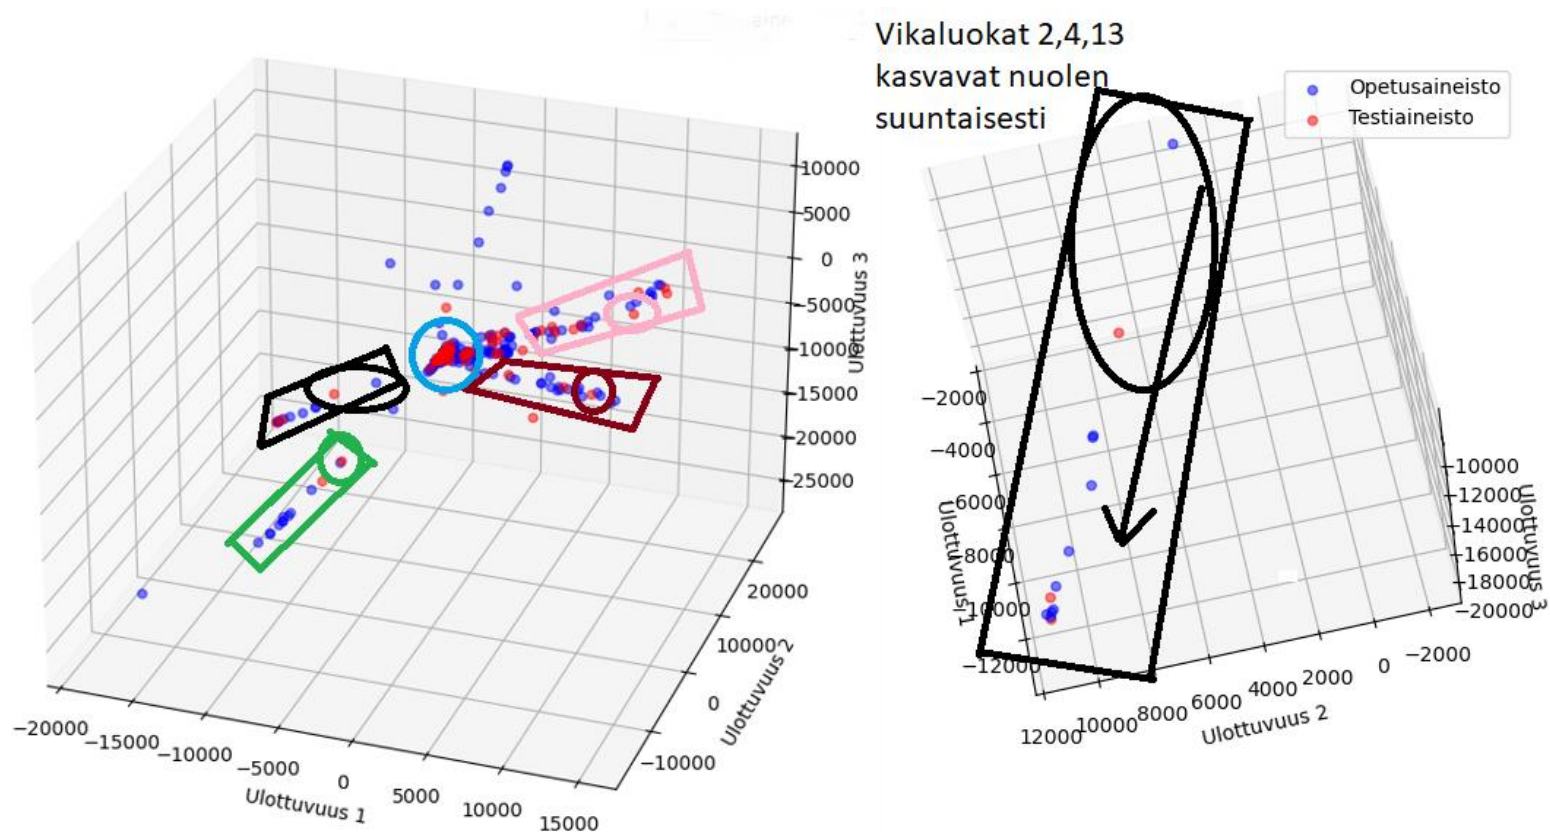
- Tulos vaihteli koulutuskertojen välillä

Enkooderin tulokset, kun CNN:ää koulutettiin satunnaisesti valituilla aineiston osajoukoilla



# Enkooderi


- Enkooderi onnistuu erottelemaan vikakategorioita



# Enkooderi

- Vikaluokan 1 tarkastelu

Pinkki ryhmittymä



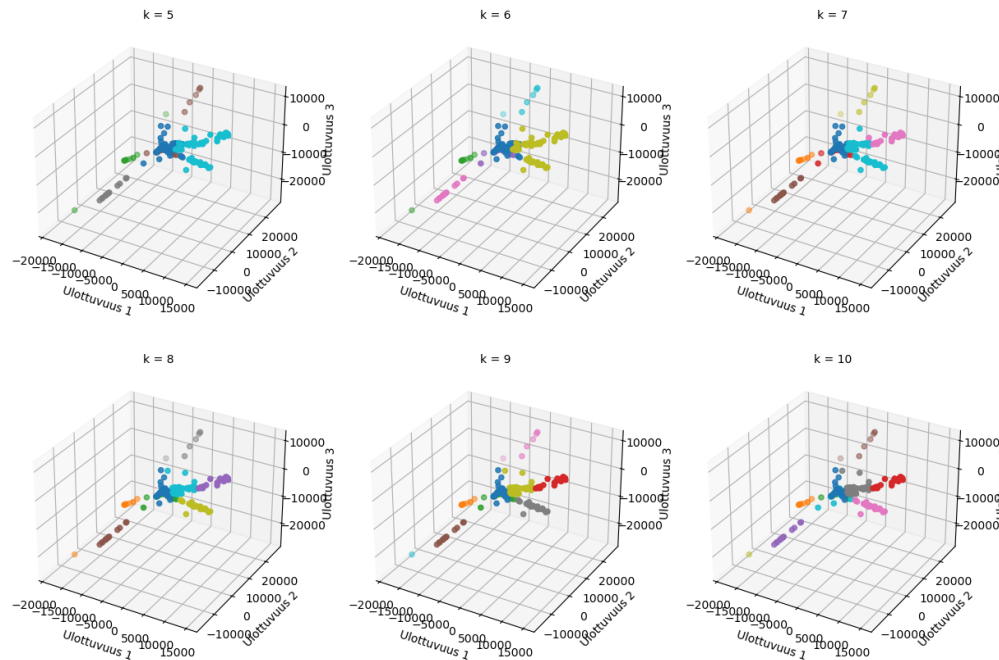
Punainen ryhmittymä



# Klusterointi

- K:n-keskiarvon-menetelmä
- Perustuu pisteiden välisten etäisyyksien eroihin

Klusteroitu enkoodattu data



# Työkalut

- Python
  - Pandas
  - PyTorch
  - NumPy
  - Matplotlib
- Laskenta Nvidian GTX2080-näytönohjaimella



# Tietolähteet ja aineistot

- Valmistetuista piikiekoista kerätty data, Murata Electronics Oy
- M. Vaulanen. Specialist, Quality Control. Murata Electronics Oy. Myllykivenkuja 6, 01620 Vantaa. Haastattelu 17.9.2024.