

Merimiinojen tunnistus pohjakartoituskuvista MATINE hanke 2023

Prof. Jukka Heikkonen

Turun yliopisto, Tietotekniikan laitos

Hankkeelle myönnetty MATINE rahoitus: 94994 euroa

Turun yliopiston omarahoitus: 23 748

Hankkeen kesto: 1.2.2023-31.12.2024

Tutkimuksen tavoitteista

Tutkimuksessa kehitetään koneoppimismenetelmiä tunnistamaan pohjakartoituskuvista miinat (sodanaikaiset/harjoitusmiinat) ja erottamaan nämä luotettavasti Itämeren pohjalla makaavista muista kohteista (esim. kivet, kalliot, hylät)

Tutkimushanke tukee Merivoimien väylä- ja meriturvallisuuden kehittämisstrategiaan ja tälle tutkimukselle on selvä tarve **nopeuttamaan** miinanetsintää sekä tekemään se nykyistä paljon **kustannustehokkaammin** ja **luotettavammin**.

Tunnistamismenetelmiä tullaan testataan Merivoimien keräämiin uusiin pohjakartoituskuviin:

- Tuloksia verrataan miinanetsintäoperaattoreiden tunnistamistuloksiin tarkkuuden ja tunnistamisnopeuden suhteen.

Tutkimuksen taustaa

- Sodanaikaisia miinoja Itämeressä vielä arviolta yli 40000
- Iso osa vaarattomia
- Jos ankkuroidaan ja kalastetaan voi syntyä ongelmia
- Itämeren, matalan ja kivikkoinen ja olemassa olevat algoritmit toimivat huonosti:
 - **Varsinkin kivet tunnustetaan usein virheellisesti miinoiksi**
- Pohjamiina on profiililtaan usein sylinterimäinen, kosketusmiinan koho pallon tai ellipsin muotoinen ja kosketusmiinan ankkuri kulmikas.


Pohjakartoituskuvat

Kuvantamislaitteistona Klein 5500 viistokaikuluotain:

- Vedettävä
- Laite lähettää ääniaaltoja (5-20kHz) veteen ja rekisteröi niiden paluukaikut.
- Paluukaikujen perusteella laite luo kuvan vedenalaisesta ympäristöstä.
- 5 samanaikaista sädettä -> 100% peitto

Veden akustiset ominaisuudet vaikuttavat mittausten tarkkuuteen


Itämeren mataluus tuottaa häiriöitä, paluukaikuja tulee kivistä ja kallioista.




Tutkimuksessa käytettävä aineisto

- Kuvat pdf-formaatissa, kuvien kattama alue vaihtelee 28x28m (skaala 1:150) - 36x36m (1:200) välillä
- Kuvien pikselimäärä noin 2000 x 2000 pikseliä
- Kuvat jaettu neljään eri luokkaan
 1. Miinankaltaiset kohteet (MILCO) - 406 kpl
 2. Kivet - 711 kpl
 3. Hylyt - 84 kpl
 4. Miinat - 205 kpl
- Data annotoitu operaattorien toimesta.
- Kuvat eivät sisällä tietoa kohteiden tarkasta paikasta ja kuvissa suuriakin puutteellisuuksia (esim. vääristymiä ja kaikutietoja puuttuu).
- Lisätietoa käytettävissä (mm. kuvaussyvyys) joidenkin kuvien osalta


- MILCO




- Kivet




- Hylyt




- Miinat




- MILCO




- Kivet



- Hylyt



- Miinat



Operaattorien toiminta

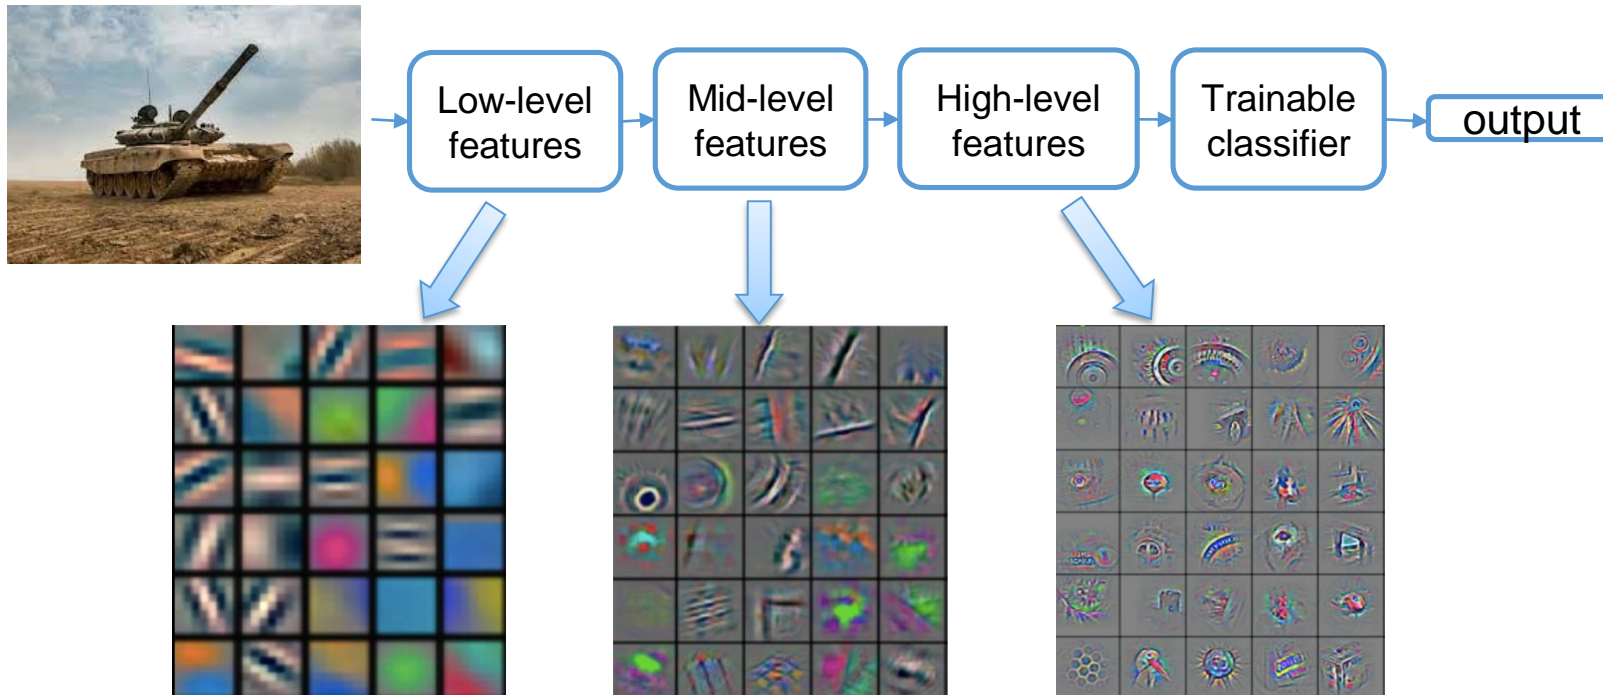
Haastattelun perusteella operaattoreiden kuvien tulkinta perustuu

- Kohteen kokoon
- Kohteen tuottamaan varjoon
- Kohteen muotoon ja rakenteeseen
- Voimakkuuteen (erottuvuuteen)
- Ympäristöön suhteuttuna

Työ aikaa vievää ja potentiaalisten miinakohteiden varmentaminen hidasta ja kallista.

Syväoppimismenetelmistä

- Syväoppimisessä pyritään oppimaan hierarkkisia representaatioita (eli ominaisuuksia) automaattisesti annetusta opetusaineistosta monivaiheisen oppimisprosessin avulla.
- Tekee epälineaarinen piirremuunnoksen matalamman tason piirteestä korkeamman tason piirteeseen
- Vaatii useinmiten laajan opetusaineiston (kiertotienä ns. siirto-opetus)
- Laskennallisesta haastava reaaliaikasovelluksissa



Konvoluutioverkko (CNN)

Käytetty siirto-opetusta:

- VGG16 + luokittelija

Kuvia augmentoitu
geometrisesti:

- Satunnainen kääntö (flip)
ja siirto (translaatio)

Luokittelutulokset

- 5-kerran ristiinvalidointi
- kokonaisluokittelu 77%
oikein

O\E	MILCO	KIVI	HYLKY	MIINA
MILCO	379	21	0	6
KIVI	17	593	11	90
HYLKY	3	32	43	6
MIINA	9	112	3	81

O\E	MILCO	KIVI	HYLKY	MIINA
MILCO	93	5	0	1
KIVI	2	83	2	13
HYLKY	4	38	51	7
MIINA	4	55	1	40

Epävarmuuden hyödyntäminen

Monet koneoppimismallit pystyvät ennustamaan todennäköisyyksiä tai todennäköisyysarvoja luokkaan kuulumiselle.

Luokittelijan epävarmuutta voidaan arvioida erilaisilla työkaluilla ja yksi näistä on ns. ROC-käyrä:

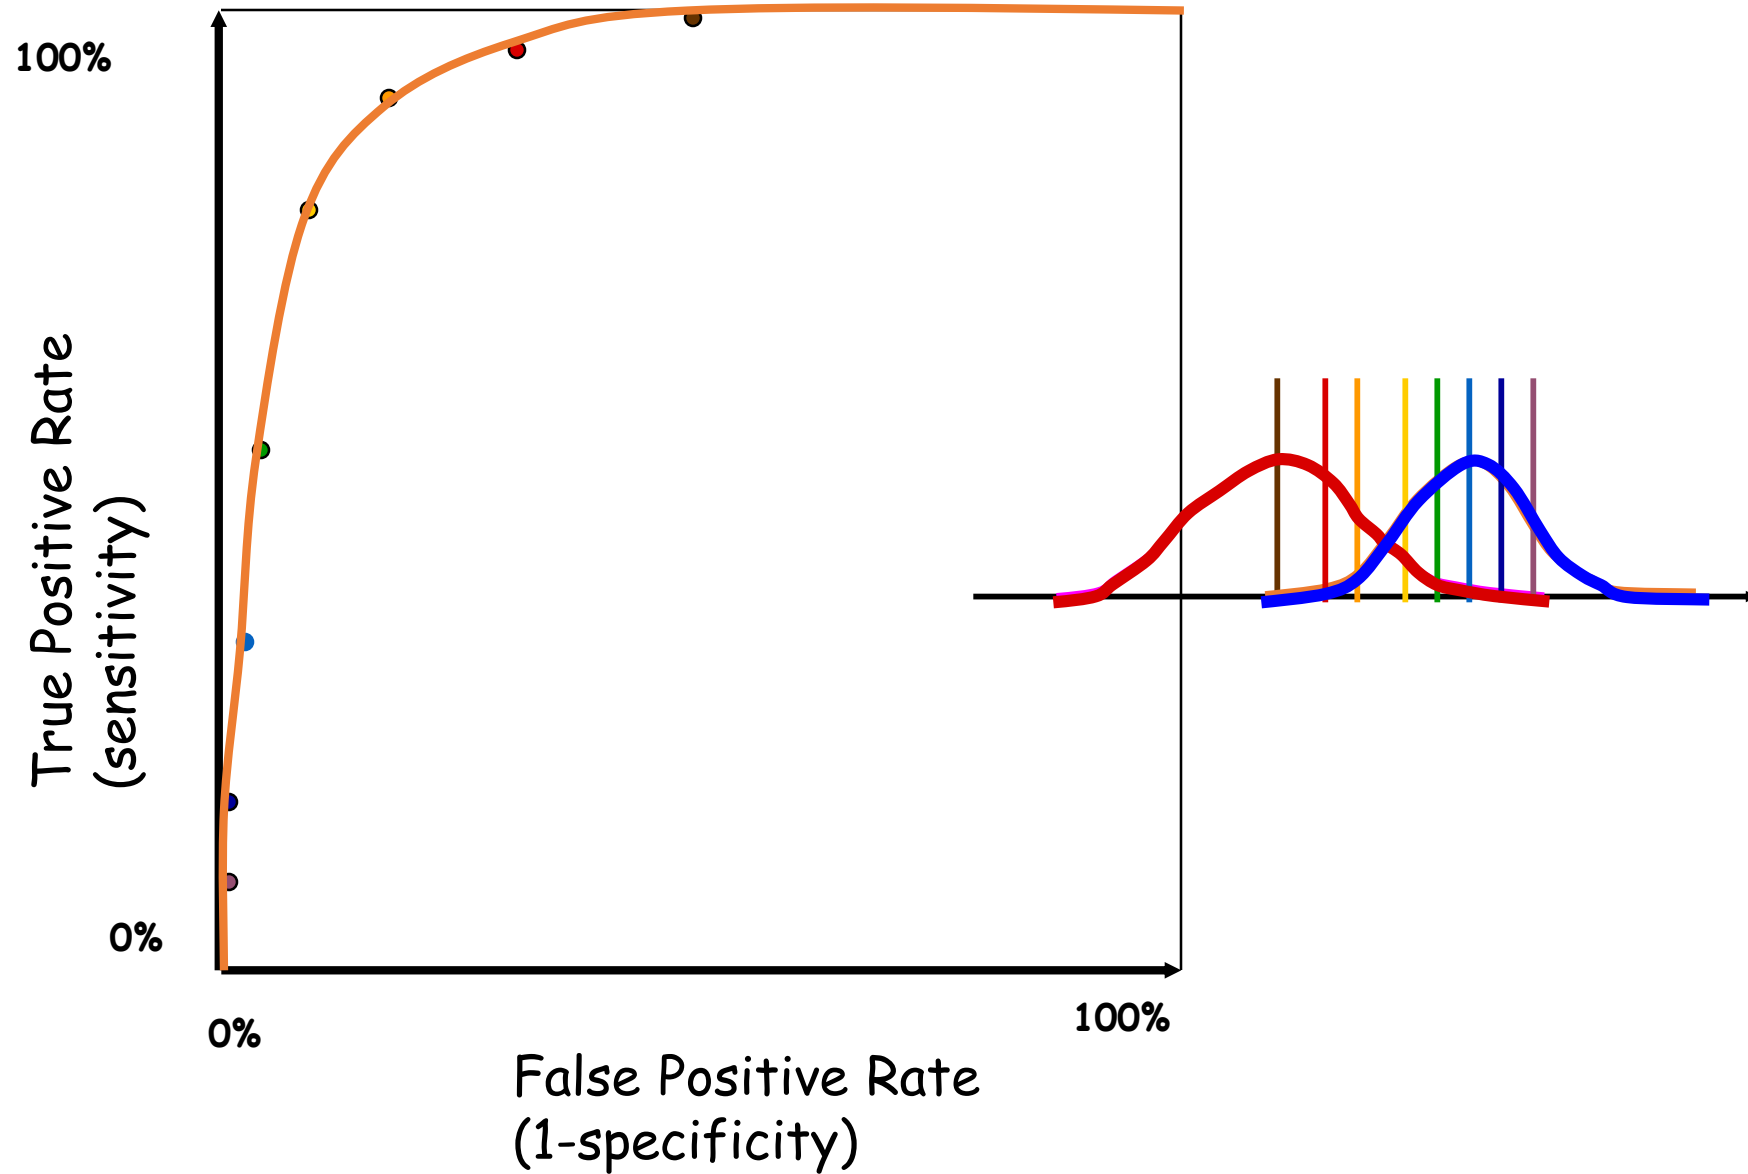
- ROC-käyrä (Receiver Operating Characteristic) havainnollistaa binäärisen luokittelumallin suorituskykyä esittämällä todellisten positiivisten tulosten osuuden ja väärin positiivisten tulosten osuuden eri luokittelukynnyksillä.

ROC analytiikka mahdollistaa asettaa luokittelijalle ”oikean” todennäköisyyskynnysarvon luokkien määrittämiselle


Epävarmuutta voidaan myös hyödyntää ns. Bayesialaisessa päätöksenteossa jossa luokittelutulokseen asetetaan kustannus:

- Minimoidaan esimerkiksi luokitteluvirheestä aiheutuneita kustannuksia:
 - Kustannus kiven luokittelusta miinaksi? (FP)
 - Kustannus miinan luokittelusta kiveksi/muuksi kohteeksi? (FN)

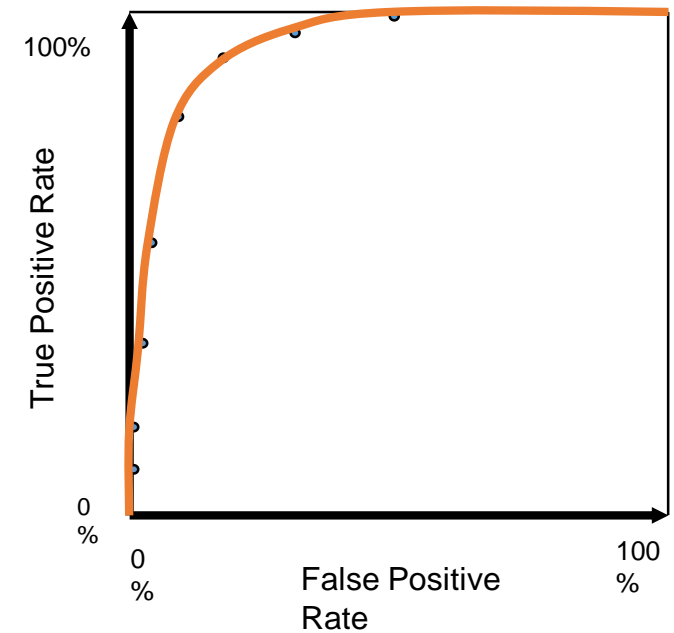
ROC käyrä




ROC analytiikka



Hyvä malli:



Huono malli:



ROC analytiikka

Miina vastaan muut luokat


Paras threshold: 92%

=> kokonaistarkkuus: 72%

CM kun threshold on 92%:

O \ E	Ei miina	Miina
Ei miina	836	365
Miina	24	181

O \ E	Ei miina	Miina
Ei miina	70	30
Miina	12	88



Lisäinformaatio

Osalle kuviin käytössä seuraavat tiedot

- Kohteen leveys, pituus ja korkeus (operaattorin arvio, ei tarkistettu)
- Kohteen syvyys (aluksena antama tieto)
- Syvyysmallin antama merenpohjan syvyys (interpoloitu) kohteen kohdalla

Lisätieto käytössä noin 90% kuvista ja osa tiedoista puutteellista

Lisäinformaation käyttö

Hyödynnetään lisätieto konvoluutioverkon päätöskerroksessa:

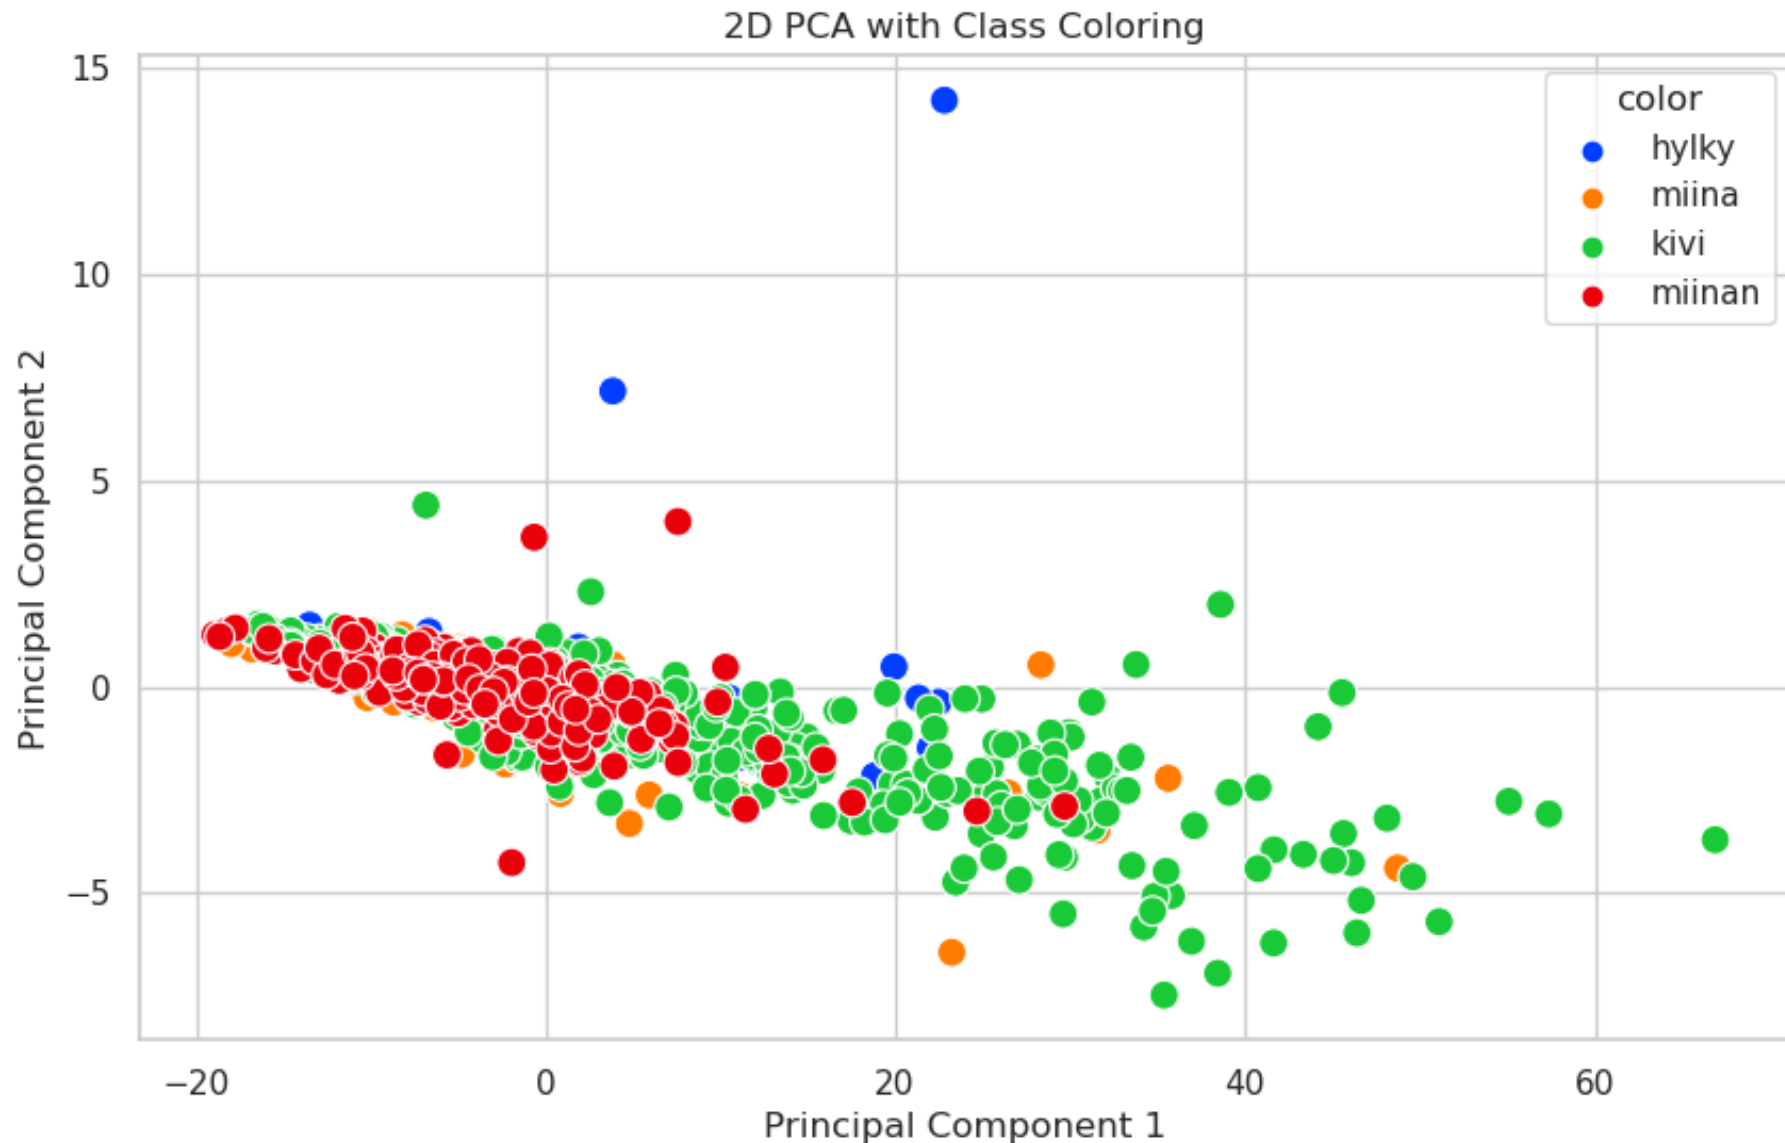

- Päätöskerrosta edeltäville syötteille (25000) tehdään PCA muunnos ja projisoidaan syötteet pienempään dimensioon pääkomponenteille
- Opetetaan XGBoost Random Forest malli sekä PC projektioilla ja lisäinformaatiolla

Miksi XGBoost?

- Hyvä kyky käsitellä puuttuvat lisätiedot (NaN arvot)
- Antaa tiedon syötteiden tärkeydestä -> selittävä malli

PCA

Valitaan kriteeriksi
90% alkuperäisen
aineiston varianssin
säilyvyys -> 50
pääkomponenttia



Luokittelu lisäinformaatiolla

XGBoost Random
Forrest menetelmä,
(lisäinformaatio + PC(50)) data

Kokonaisluokittelu

Tulosten arviointi ristiinvalidoinnilla
kokonaistulos 83% oikein

Pääjohtopäätökset:

- Kivien tunnistus parani
- Miinojen tunnistus heikkeni

CNN tulokset
77% oikein

O\E	MILCO	KIVI	HYLKY	MIINA
MILCO	379	21	0	6
KIVI	17	593	11	90
HYLKY	3	32	43	6
MIINA	9	112	3	81

XGBoost RF
83% oikein

O\E	MILCO	KIVI	HYLKY	MIINA
MILCO	373	31	1	1
KIVI	8	678	3	23
HYLKY	1	34	48	1
MIINA	2	129	3	71

Luokittelu lisäinformaatiolla


- Sisäkkäisellä ristiinvalidoinnilla saadut binääriluokittelun tulokset:
- Paras threshold: 52%
- => paras kokonaistarkkuus: 89%
- CM kun threshold on 52%:

O \ E	Ei miina	Miina
Ei miina	1182	20
Miina	137	68

LKM

O \ E	Ei miina	Miina
Ei miina	98	2
Miina	67	33

%



Johtopäätökset tuloksista

- Tehtävä haasteellinen, erityisesti kivien ja miinojen erottamisesta toisistaan
- Lisäinformaatio parantaa hieman tuloksia
- Väärät positiiviset luokista MILCO, KIVI ja HYLKY saadaan suhteellisen hyvin eliminoitua
- Luokittelijan epävarmuustietoa voidaan hyödyntää kustannusfunktion kautta:
 - Kuinka paljon maksaa kiven luuleminen miinaksi? (FP)
 - Kuinka paljon maksaa miinan luuleminen kiveksi/muuksi kohteeksi? (FN)

Tutkimuksen jatko

- Oman syväoppimismallin tuottaminen
 - Siirto-opetusmallit tehty RGB kuville, pohjakartoituskuvat ”harmaasävykuvia”
- CNN verkon aktivaatioiden hyödyntäminen päättelemään missä kohtaa kuvaa tunnistettava kohde sijaitsee todennäköisemmin:
 - Voidaan hyödyntää ns. aluepohjaisia CNN verkkoja
- Klein marinen kanssa neuvotellaan parhaillaan mahdollisuudesta hyödyntää raakasignaalia:
 - Kivi ja miina erilaista materiaalia, joten on oletettavaa että raakasignaali paljastaa heijastuneiden paluukaikujen erot