



FFI-RAPPORT

21/00490

Maskinlæring og gruppeantennener i moderne radarsystemer

Jabran Akhtar
Kyrre Strøm

Maskinl ring og gruppeantennener i moderne radarsystemer

Jabran Akhtar
Kyrre Str m

Emneord

Radar
Deteksjon
Maskinl ring
Nullstyringsantenner

FFI-rapport

21/00490

Prosjektnummer

1440

Elektronisk ISBN

978-82-464-3332-5

Engelsk tittel

Machine learning and arrays in modern radars.

Godkjenner

B rge Torvik, *forskningsleder*
Trygve Sparr, *forskningsdirekt r*

Dokumentet er elektronisk godkjent og har derfor ikke h ndskreven signatur.

Opphavsrett

  Forsvarets forskningsinstitutt (FFI). Publikasjonen kan siteres fritt med kildehenvisning.

Sammendrag

Denne rapporten presenterer enkelte resultater fra siste del av FFI-prosjektet Operativ radarytelse II (OPRA II), hvor den potensielle anvendelsen av maskinlæring og nevralt nettverk i moderne radarsystemer er blitt studert. Maskinlæringsbaserte teknikker er demonstrert på problemstillinger innen sparse rekonstruksjon og deteksjon av mål.

Sparse rekonstruksjon er en teknikk som kan brukes på data som er samlet inn ved hjelp av en compressed sensing metodikk. De innsamlede dataene er derfor ikke punktprøvd regulært, men har gap. For å rekonstruere data må en ta i bruk sparse rekonstruksjonsteknikker som i hovedsak baserer seg på bruk av iterative numeriske metoder. I denne rapporten er det demonstrert hvordan en heller kan anvende et opptrent nevralt nettverk for dette formålet. Resultatene gjør det mulig å kjøre rekonstruksjonsteknikker effektivt ved hjelp av dedikerte grafikkort.

Deteksjon av mål er en viktig egenskap for en radar. Svake mål, flere nærliggende mål og clutter gjør blant annet at det er krevende å opprettholde høy deteksjonsevne samtidig som falskalararmraten holdes lav. For å forbedre den generelle deteksjonsytelsen er det implementert detektorer ved hjelp av maskinlæringsteknikker. Resultatene viser at det er mulig å opprettholde god deteksjonsytelse, mens falskalararmraten kan reduseres betraktelig i forhold til konvensjonelle deteksjonsmetoder.

I tilknytning til dette er array-prosessering en viktig del av moderne radarsystemer. Teorien bak mange av metodene som anvendes har vært kjent i lengre tid. Gruppeantennor med mange mottakskanaler gir bedre retningsinformasjon enn antenner med en enkelt kanal, og array-prosessering utnytter denne informasjonen. Men det stiller store krav til antennens maskinvareløsninger og til regneressurser for signalprosesseringen. Rapporten oppsummerer resultater fra ulike simuleringer og testforsøk knyttet til adaptive array-prosesseringsmetoder for bakkebaserte radarer. Resultatene indikerer at array-prosessering fungerer godt for bakkebaserte radarer som opererer i komplekse signalmiljøer. Adaptiv stråleforming gir bedre retningsbestemmelse og deteksjonsevne enn konvensjonell stråleforming under testmålinger med gruppeantennor utsatt for interferens.

Summary

This report presents some techniques and results from the OPRA II project. The presented methods investigate the use of machine learning and neural networks in a radar context. These techniques are applied for the cases of sparse reconstruction and target detection.

Data collected through compressed sensing methods will have gaps within and be incoherent. To reconstruct full data, sparse reconstruction methods need to be employed. These techniques rely on the use of numerical iterative methods. In this work, we show how one can instead use a neural network for this purpose. This opens up the possibilities for an efficient execution of reconstruction methods using e.g. dedicated graphical processing units.

Target detection is an important task for radar systems and becomes complicated in settings with weak targets, multiple closely spaced targets and the presence of clutter. This can make it difficult to sustain a high probability of detection with a low false alarm rate. To improve upon traditional detectors, the detection process is herein proposed implemented via machine learning based techniques. The results show that it is possible to sustain a good detection capability while the neural networks can significantly reduce the false alarm rate.

Array processing is another important and integral part of modern radar systems. The general theory behind many of the concepts applied in array processing is well developed. Array antennas with multiple receiver channels provide better directional information than single channel antennas, and array processing exploits this information. However, this places great demands on the antenna hardware solutions and on computational capabilities for the signal processing. This report gives a summary on various simulations and trials carried out during the project related to array processing. The results indicate array processing works well for ground-based radars operating in complex signal environments. Adaptive beamforming provides better direction of arrival estimates and detection capability than conventional beamforming during test measurements with array antennas exposed to interference.

Innhold

Sammendrag	3
Summary	4
1 Innledning: Maskinl�ring	7
2 Compressed sensing og sparse rekonstruksjon med maskinl�ring	8
2.1 Radar- og signal-modell	8
2.2 Treningssett	10
2.3 Evaluering	12
3 CFAR deteksjon med maskinl�ring	19
3.1 Treningssett	20
3.2 Evaluering	22
3.3 Utpr�ving p� ekte data	26
4 Oppsummering maskinl�ring	30
5 Innledning adaptiv str�leforming	31
6 Str�leforming og array-prosessering i OPRA II	33
6.1 Passiv radar m�linger	33
6.1.1 DVB-T passive radar dual polarisasjonsm�linger under p�virkning av sterk direktesignal-interferens. Konferanse proceeding IRS-2017, IEEE explore (Str�m et al., 2017)	34
6.1.2 Direktesignalundertrykking med adaptive str�leforming i DVB-T passiv radarm�linger. Konferanse-proceedings IRS-2018, IEEE explore (Str�m et al., 2018)	34
6.2 M�linger med kortholdsradar og interferens	35
6.2.1 Array-prosessering og interferens i m�linger med kortholdsradar. FFI-notat (Str�m & Norheim-N�ess, 2019)	35
6.2.2 Adaptiv str�leforming for interferensundertrykking i en flombelysende radar. FFI-rapport utkast (Str�m et al., To appear 2021)	36
6.3 Flombelysende kortholdsradar	37

6.3.1	Phase Only Pattern Synthesis for kortholdsradar. FFI-notat (Strøm, 2020)	38
6.4	Utvidelse av intern FFI-simulator	39
6.4.1	CoRaSim moduler for Array Prosessering og Sparse rekonstruksjon, Del 1. FFI-rapport (Strøm et al., 2020)	39
6.5	Kontrollert forfall av gruppeantenne	40
6.5.1	Gruppeantenner med ikke-fungerende elementer, en simuleringsstudie. FFI-rapport utkast (Strøm, To appear 2021)	40
7	Videre arbeid array-prosessering	42
	Acronyms	43
	Referanser	44

1 Innledning: Maskinlæring

Prosjekt OPRA II har hatt som ett mål å vurdere ytelsen til eksisterende og fremtidige operative radarsystemer sett i lys av den radarteknologiske utviklingen.

Nye metoder og algoritmer for deteksjon av vanskelige mål har vært et tema som skulle analyseres og lede til at metoder implementeres. Den teknologiske utviklingen muliggjør i dag utvikling og utprøving av kompliserte algoritmer som tidligere ble sett på som veldig ressurskrevende. Her er det maskinlæringsmetoder som står i en særstilling og som innen ulike fagfelt er blitt gjenstand for intensiv forskning de siste årene. De første kapitlene (2-4) av denne rapporten fokuserer på anvendelsen av maskinlæring i radarproblemstillinger knyttet til compressed sensing og deteksjon.

Maskinlæring har i dag blitt et nyttig verktøy for å løse mange ulike typer problemstillinger. Grunnkonseptet bak maskinlæring er å anvende tilgjengelige data for å lære opp et nettverk og bruke det som utgangspunkt for en implementert løsning. Dette betyr at istedenfor å utvikle en dedikert algoritme for å løse et gitt problem kan en heller samle inn store mengder med data hvor sluttresultatet er kjent. Ved å trene på et slikt sett vil et nevralt nettverk selv klare å etablere en kobling mellom inn-dataene og ønsket resultat ut. For å få god generisk ytelse må nettverkene dog trenes opp på store mengder data slik at en dekker et bredt spekter av ulike situasjoner som kan oppstå. For praktisk implementasjon er dette viktig for at et trent nettverk også skal kunne håndtere sjeldne hendelser tilfredsstillende. Bruk av maskinlæring i en operativ radar-sammenheng er foreløpig veldig begrenset, men de innledende resultatene peker mot at en kan oppnå flere fordeler ved å ta i bruk slike teknikker i fremtidige systemer.

Denne rapporten har ikke til hensikt å gå inn i de tekniske aspektene bak maskinlæring og nevralt nettverk; for dette henvises det til den omfattende åpne litteraturen som i dag er tilgjengelig. Fokuset i denne rapporten er å demonstrere anvendelsen av maskinlæring i en radarkontekst og avdekke hvordan maskinlæring kan anvendes i enkelte problemstillinger og oppnå en forbedret ytelse.

I all hovedsak er de to problemstillingene som vurderes i denne rapporten relatert til maskinlæring. Den ene er compressed sensing beskrevet i kapittel 2, hvor et nevralt nettverk trenes opp til å utføre rekonstruksjonsprosessen. Bruk av compressed sensing kan for eksempel tillate en radar å kutte ned tidsbruken i en integrasjonsperiode uten tap av ytelse, men til gjengjeld krever dette mer ressurser i form av regnekraft. Ved å bruke maskinlæringsmetoder kan rekonstruksjonsproblemet løses på en alternativ måte hvor en kan unngå å kjøre krevende optimeringsalgoritmer. Den andre problemstillingen beskrevet i kapittel 3 anvendes nevralt nettverk i en annen kontekst for å erstatte en tradisjonell deteksjonsprosess med den hensikt å redusere falskalarmeraten.

2 Compressed sensing og sparse rekonstruksjon med maskinl ring

Betegnelsen Compressed Sensing (CS) angir en samplingmetodikk hvor en ikke sampler (punktpr ver) et signal regelmessig med to ganger den h yeste frekvensen i signalet (Nyquist-Shannon samplingsteorem). Teorien bak CS beskriver hvordan man kan, under visse betingelser, fravike samplingsteoremet ved   samle mindre mengder data i en tilfeldig rekkef lge og likevel gjenskape dataene eksakt. For   rekonstruere det opprinnelige signalet m  en s kalt sparse rekonstruksjonsprosess (SR) utf res. Det fins mange ulike teknikker for dette, men de fleste har det til felles at l sninger bestemmes ved hjelp av iterative numeriske metoder. Iterative metoder har den ulempen at de kan v re tidkrevende og dermed vanskelige   implementere i sanntidssystemer. Teorien bak CS, med henblikk p  radar, er ellers beskrevet i egen FFI-rapport. S  for en grundigere gjennomgang henvises det til FFI-rapporten (J. Akhtar, 2020a) og artikkelen (J. Akhtar & Olsen, 2016).

Denne delen av rapporten tar blant annet for seg en implementasjon av sparse rekonstruksjon ved hjelp av nevrale nettverk. En optimeringsprosess anvendt p  dataene vil da kunne kj res i en gitt bestemt tidsramme med mulighet for bruk av dedikerte grafikkprosessorer (GPU). Dette vil kunne gi st rre mulighet for anvendelse i operative sanntidssystemer. Artikkelen (J. Akhtar, 2020b) gir for  vrig en mer detaljert teknisk beskrivelse av denne prosessen, mens en kortere oppsummering er gitt nedenfor.

2.1 Radar- og signal-modell

F rst vil vi definere en modell for hvordan en enkel CS-basert radarmode kan konstrueres. Vi antar en pulset radar som sender et visst antall pulser med regelmessig intervall. De innkommende reflekterte ekkoene fra pulsene samples og det utf res en matched-filter operasjon. N slike pulser sendes og mottas i l pet av integrasjonsperioden (CPI). Deretter konstrueres et range-dopplerkart ved at de samlede dataene for hver avstandscelle multipliseres med en valgt vindusfunksjon og transformeres ved hjelp av en Fouriertransform. En transformasjon til frekvensdomenet gj r at energien til eventuelle m l blir konsentrert sammen i hastighetsdomenet og forbedrer deteksjonsevnen.

For en CS-basert radarmode kan vi for eksempel anta at radaren ikke sender alle N pulser rett etter hverandre i samme retning, men veksler mellom ulike retninger eller frekvenser i l pet av en CPI. I forhold til en gitt retning og frekvens samles det heller inn $M < N$ pulser i tilfeldig rekkef lge. Slike gap i dataene gj r at en ikke kan utf re en standard Fouriertransformasjon siden dataene ikke lenger er koherente. For   rekonstruere de opprinnelige dataene kan det likevel foretas en sparse rekonstruksjonsprosess s  fremt det ikke er for mange m l per avstandscelle. I tillegg til gap inne i integrasjonsperioden kan en ogs  anta at det er gap i ytterpunktene som kan ekstrapoleres p  samme vis. Dette kan  ke oppl sningen i dopplerdomenet og snevre inn m lene ytterligere. Vi kan derfor g  ut ifra at fra M m linger rekonstrueres $L \geq N$ antall sampler. Rekonstruksjonsprosessen kan dermed beskrives som et

minimeringsproblem med absoluttnorm gitt randbetingelse uttrykt matematisk på følgende måte:


$$\hat{\mathbf{D}}(T, \hat{\omega}) = \arg \min_{\mathbf{D}} \|\hat{\mathbf{D}}(T, \hat{\omega})\|_1$$

gitt betingelsene

$$\|\hat{\mathbf{F}}_R \hat{\mathbf{D}}(T, \hat{\omega}) - \bar{\mathbf{w}}(\tilde{u}) \tilde{\mathbf{r}}(T, \tilde{u})\|_2 \leq \varepsilon.$$

Her er \mathbf{D} med dimensjon $L \times R$ det rekonstruerte range-dopplerkartet, \mathbf{F} er den partielle $M \times L$ Fouriermatrisen, \mathbf{w} angir valgt vindusfunksjon, \mathbf{r} er innsamlede data fra den gitte avstanden og ε er akseptabel feil i løsningen.

For å rekonstruere hele kartet må prosessen gjentas for hver avstandscelle; avstandsindeksen T må derfor løpe fra 1 til \mathbf{R} hvor \mathbf{R} er maksimalt antall avstandsceller. \mathbf{W} angir indeksen for dopplerceller. Figur 2.1 illustrerer sparse rekonstruksjonskonseptet for en gitt avstandscelle (én profil) hvor 0 i inndataene representerer gap.




Figur 2.1 Sparse rekonstruksjonsprosess hvor slowtime data med gap og en tilhørende vindusfunksjon omgjøres til en dopplerprofil

For å løse det overnevnte problemet med absoluttnorm, også kjent som et *basis pursuit* problem, må det tas i bruk numeriske optimeringsmetoder som typisk er basert på iterative metoder. Med et nevralt nettverk vil dette potensielt kunne kjøres fortere og i en gitt tidsramme.

For å foreta trening av et nevralt nettverk som kan utføre denne prosessen antas det at et treningssett av dataene er tilgjengelig hvor inn-verdiene og resultatet ut er tilgjengelig. Dette tilsvarer mange ulike sett av typen som illustrert i Figur 2.1. Her må det videre antas at N , M or L er konstante for et gitt oppsett og siden inn- og ut-dataene er komplekse splittes de i to og behandles som to reelle verdier. Normal praksis i maskinlæring er å normalisere dataene med min-max eller z-score normalisering. Dette har vist seg ikke å fungere tilfredsstillende for denne problemstillingen, vi har derfor brukt en alternativ normalisering hvor man normaliserer i forhold til den største absoluttverdien i inn-dataene. Absoluttverdien til den største verdien inn til nettverket vil dermed alltid være «1», mens den laveste verdien forblir udefinert. Dette gjør at rekonstruksjonsprosessen blir uavhengig av de absolutte verdiene, men forholder seg kun til relative verdier. En fouriertransformasjon er videre en lineær prosess og denne normalisering kan derfor korrigeres etter at dataene er blitt prosessert, enten direkte ved hjelp av en sparse rekonstruksjonsalgoritme eller av et nevralt nettverk.

For nevrale nettverk foreslår vi å bruke *fully connected feedforwarding* nettverk, hvor alle nodene er koblet mot hverandre på neste nivå, med samme antall noder i hvert lag som antall utverdier. Hver node anvender en *tanh* arkiveringsfunksjon for å prosessere inn verdiene. Nettverket skiller ut 2L verdier som settes sammen til L komplekse tall. Prosessen er visualisert i Figur 2.2.



Figur 2.2 Illustrasjon på nevral nettverksoppsett

For å få god ytelse er man avhengig av å ha et stort nok sett med treningsdata slik at nettverket blir i stand til å skape en solid kobling mellom inn- og ut-dataene, hvis det lar seg gjøre. I dette tilfellet er det to parametere, målenes hastighet og RCS-verdi, som er de viktigste faktorene bak trening og god rekonstruksjon. I tillegg må nettverket også kunne håndtere situasjoner med kun støy og da kun returnere null-verdier.

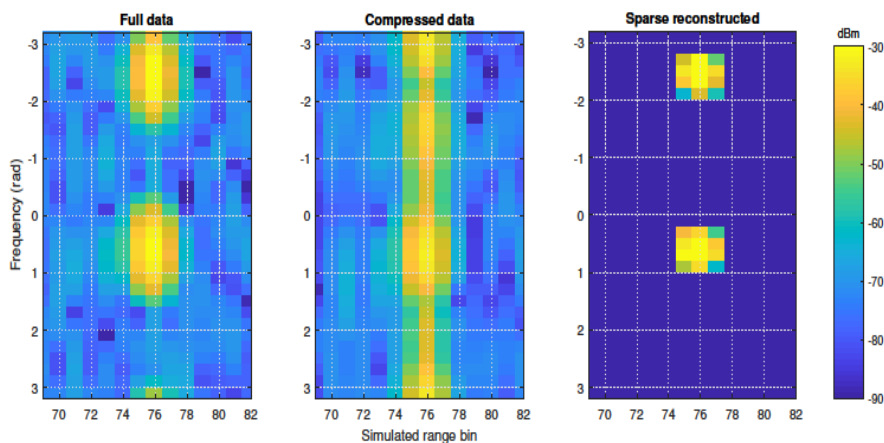
Et slikt treningssett kan genereres ved å ta mange simulerte range-dopplerkart hvor målene fluktuerer tilfeldig i både hastighet og reflektivitet. Et tilfeldig utvalg av profiler kan danne fundamentet for trening.

Her er det viktig å peke på at de fleste sparse rekonstruksjonsmetoder er i stand til å returnere eksakte null-verdier når en løsning blir bestemt. Dette er antageligvis vanskelig for et nevral nettverk å få til hvor de siste nodene mer sannsynligvis kommer til å returnere ganske små, men likevel ikke-null, elementer ut. Disse verdiene vil dermed videre bli skalert opp etter en denormaliseringsprosess.

2.2 Treningssett

For å generere et treningssett for det overnevnte problemet ble det simulert et enkelt radarscenario med integrasjonstid på $N=16$ pulser. Det ble simulert to uavhengige mål på en utvalgt avstandscelle, men med tilfeldige ulike hastigheter og tilfeldig RCS valgt fra en

Swerling-1 fordeling. Målene ble gitt to sidelober i avstand hver på henholdsvis -20dB og -26dB og støyen i oppsettet var satt til hvit gaussisk støy. Her ville det også ha vært mulig å trene ved å anta at det kun finnes en enkelt reflektor på en gitt avstandscelle, men nettverket hadde da også blitt trent opp til å kun gjenkjenne ett mål per avstandscelle. Dette er i utgangspunktet i tråd med sparse-rekonstruksjon hvor det må antas at dopplerprofilen som skal rekonstrueres skal være sparse. Det å ha opptil to mål er likevel innenfor kravene og ved å trene på to mål som fluktuerer tilfeldig vil man kunne dekke et bredere spekter av situasjoner. Vi antar videre at enten tre ($M=13$) av pulsene blir utelatt ved posisjonene 4, 9 og 11 eller at seks ($M=10$) av pulsene blir utelatt ved posisjonene 2, 4, 9, 11, 14 og 15. Dette tilsvarer en gevinst i forhold til redusert tidsbruk på henholdsvis 18.75% og 37.5%. Tid er en begrenset ressurs som en radar kan bruke på for eksempel andre gjøremål som å sende pulser i andre retninger eller med andre frekvenser. For rekonstruksjon ekstrapoleres det videre med åtte pulser både før og etter pulstoget, dette gir $L=32$ ut-celler i hastighetsdomenet.



Figur 2.3 Utsnitt av range-dopplerkart, venstre: fulldata, midten: data med gap, høyre: rekonstruert dopplerprofil

Et eksempel på et simulert range-dopplerkart brukt som datagrunnlag for trening er gitt i Figur 2.3 for $M=13$. På figuren ytterst til venstre vises deler av et fulldata range-dopplerkart med to kraftige mål med ulik hastighet, men på samme avstand. Det er blitt brukt en Blackman vindusfunksjon i forbindelse med dopplerprosesseringen, dette har dog ingen direkte betydning for sluttresultatene.

I den midterste figuren kan en se hva resultatet ville ha vært hvis en tar dataene med tre gap og likevel gjennomfører en dopplerprosesseringen. Målene har nå spredt seg vesentlig ut i hastighet og energinivået har også forverret seg noe. Helt til høyre er resultatet fra sparse rekonstruksjon basert på dataene med gap med tillagt ekstrapolasjon. Her ble det brukt standard *basis pursuit denoising* metode med feilmargen på

$$\varepsilon < \rho^{-1} \cdot 10^{-3}.$$

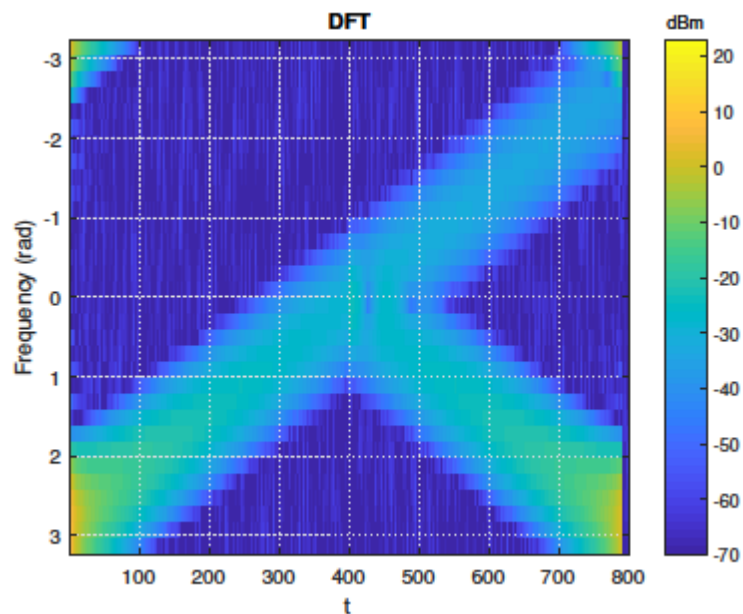
Målene er nå godt lokalisert i hastighet, oppløsningen er blitt forfinet og støyen er også blitt filtrert bort slik at vi står igjen med et sparse resultat. Utgangspunktet for treningssettet er slowtime datatene med gap i midten av figuren og det rekonstruerte resultatet til høyre.

For å få et stort treningssett ble 30.000 slike tilfeldige range-dopplerkart generert. Fra hvert kart ble profilene fra avstandscellen med selve målet, de to nærmeste nabocellene til høyre og venstre med sidelobene samt en tilfeldig avstandsprofil med kun støy tatt inn i treningssettet. Treningssettet bestod til slutt av 120.000 ulike profiler. De to målene på samme avstand hadde som nevnt tilfeldig utvalgt energinivå, men for halvparten av tilfellene i treningssettet ble energinivået satt til å være lik for begge målene. Årsaken til dette er at hvis begge målene følger uavhengige verdier vil det oppstå situasjoner hvor det ene målet er veldig mye svakere enn det andre, noe som kan føre til at bare det sterke målet blir rekonstruert. Dette kan unngås ved å sørge for at det trenes også en god del på situasjoner hvor begge målene er like kraftige.

2.3 Evaluering


Flere ulike typer nevrale nettverk har blitt trent opp med de samme treningsdataene. Nettverkene bestod av enten 64 eller 192 noder i hvert lag med ulik dybde. 64 noder tilsvarer 32 komplekse tall som igjen representerer $L=32$ ut-verdier fra nettverket.

For å evaluere resultatene ble det simulert et range-dopplerkart lignende scenario hvor ett mål sveiper frekvensspekteret over simulert avstand samtidig som energinivået gradvis blir redusert. Det introduseres også et annet mål midtveis i dataene som sveiper med motsatt frekvens og opplever en økning i energinivået. Dette gjør at en kan evaluere ytelsen fra et trent nevralt nettverk både for enkelt og dobbeltmål med ulike signal-til-støy forhold. Det fulldata evalueringsskartet er gjengitt i Figur 2.4.




Figur 2.4 Fulldata range-dopplerkart med ett eller to simulerte mål per avstandscelle

En koherent integrasjonsperiode på $N=16$ pulser er relativt liten og målene sprer seg noe i dopplerdomenet, men er likevel enkle å oppdage. Fjerner vi tre pulser fra dataene og likevel gjennomfører en standard dopplerprosessering får vi resultatet som er gjengitt i Figur 2.5. Målene er nå utsmørt i dopplerdimensjonen.



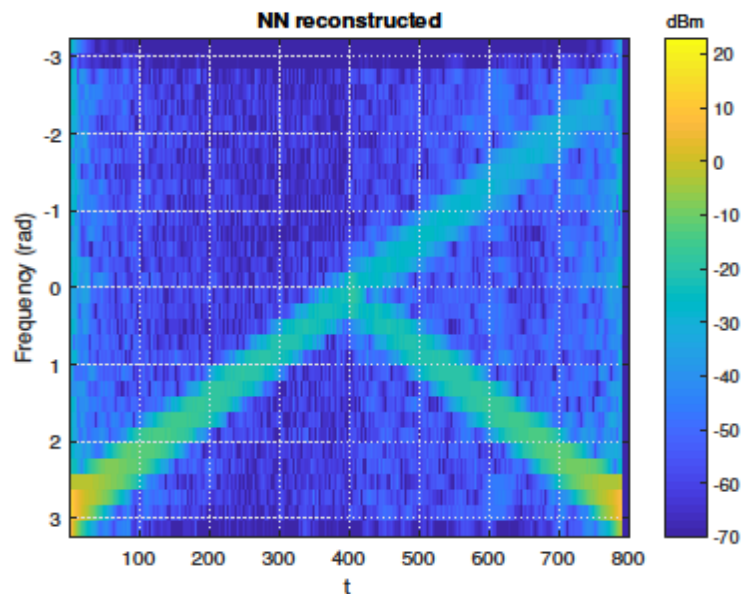
Figur 2.5 Range-dopplerkart med redusert data

Disse dataene med gap er rekonstruert ved hjelp av standard sparse rekonstruksjon med ekstrapolasjon og resultatet er vist i Figur 2.6 . Målene er nå godt lokalisert i doppler og det er heller ingen utfordringer med å skille ut de to målene.

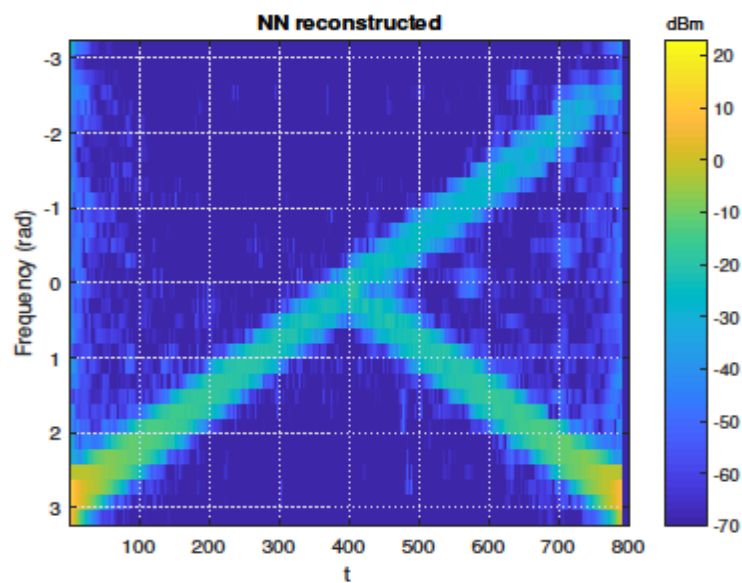


Figur 2.6 Rekonstruert range-dopplerkart ved hjelp av standard sparse rekonstruksjon

Mater man de samme slowtime-dataene inn i det trente nettverket med størrelse 64x2 får vi resultatet vist i Figur 2.7. Nettverket har klart å gjennomføre en dopplerprosessering og isolert ut de to målene som også er godt lokalisert. Resultatet bærer imidlertid preg av vesentlig støy i bildet og kan dermed ikke kategoriseres som helt sparse. Resultatene fra det større 192x2 nettverket er derimot bedre og kan sees i Figur 2.8. Her er støyen mye mer dempet og man kunne med fordel sette en filtreringsterskel slik at alle små verdier under en viss verdi ble satt til null. Støynivået på det opprinnelige bildet ligger på -70dBm, for det rekonstruerte 64x2 bildet er det -50dBm mens for 192x2 kommer en ned på -70dBm.



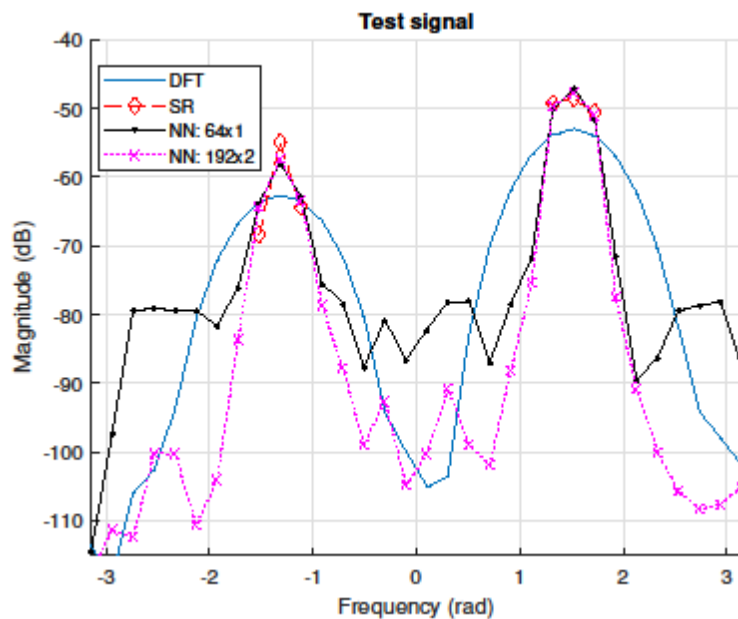
Figur 2.7 Range-dopplerkart rekonstruert ved hjelp av 64x2 nevralt nettverk



Figur 2.8 Range-dopplerkart rekonstruert ved hjelp av 192x2 nevralt nettverk

Figur 2.9 gir et utsnitt av dataene tatt ved $t=600$. Resultatet fra sparse rekonstruksjon skiller seg ut fordi den kun returnerer tre ikke-null verdier for hvert av målene angitt i magenta. Den blå kurven representerer standard dopplerprosessering. Resultatet fra 64x2 nettverket, angitt med svart, viser igjen at nettverket ikke klarer helt å dempe ned støyen, mens for det større 192x2 nettverket er den i samsvar med standard prosessering (blå).

Vi ser også at sparse-metodene og nevrale nettverk har klart å øke energinivået noe samtidig som målene er snevret inn grunnet tillagt ekstrapolasjon av pulser.



Figur 2.9 Utsnitt av dopplerprofil fra range-dopplerkart

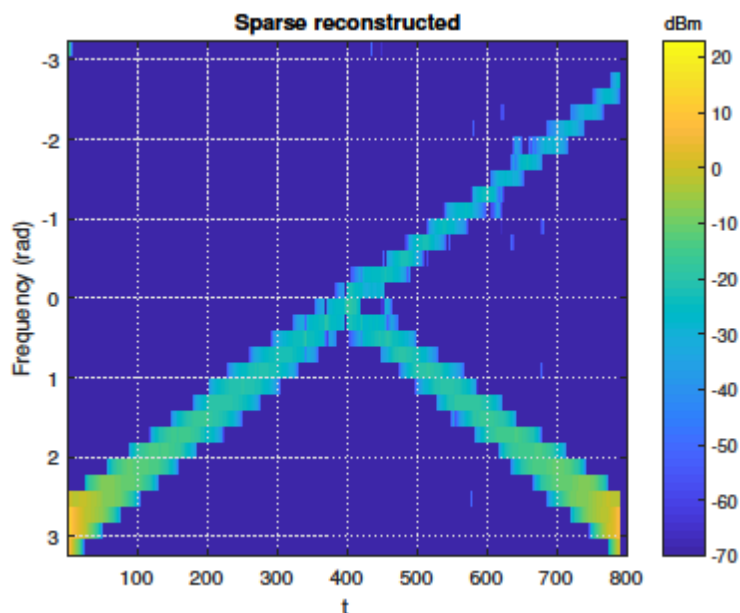
Nettverk størrelse	Treningsfeil	Avvik mellom SR og NN bilde	Bildedynamikk (dB)
64x1	0.2580	0.2758	138.23
64x2	0.1040	0.1919	141.75
64x6	0.0671	0.1976	144.75
192x2	0.0411	0.1875	156.15

Tabell 2.1 Ytelse av ulike nettverk basert på størrelse


Tabell 2.1 ovenfor gir noen kvantitative resultater fra trening over ulike typer nevrale nettverk. Treningsfeil i andre kolonne angir avvik etter at nettverkene ble trent over samme datasett med en million epoker. I tredje kolonne blir det angitt relativ to-norm avvik mellom evalueringbildene rekonstruert fra sparse rekonstruksjon mot bildene fra nevralt nettverk rekonstruksjon. Den siste kolonnen gir bildedynamikk som representerer differansen mellom den største og minste verdien i nevralt nettverksrekonstruksjonen. Dette kan sees på som et mål på hvor mye støy det eksisterer i bildet. Som referanse kan det oppgis at i det opprinnelige fulldata bildet kommer dette tallet på 146dB. Fra tabellen kan en observere at treningsfeilen blir generelt mindre med større nettverk, men vi ser også at avvikene mellom bildene er relativt små og på omtrent samme nivå. Dette indikerer at de dominante egenskapene i bildene blir approksimert like bra. Resultatene fra 192x2 nettverket gir best bildedynamikk noe som også er visuelt lett å observere.

Denne trening og evalueringsprosessen ble også gjennomført med $N=10$, hvor seks av pulsene blir utelatt fra integrasjonsperioden. Figur 2.10 angir resultatet fra sparse rekonstruksjon på evalueringdataene som i hovedsak fortsatt evner å rekonstruere begge mål. Resultatene fra det trenete nevrale nettverket på størrelse 192x2 er gitt i Figur 2.11. Rekonstruksjonen fra nettverket

er også av god kvalitet og begge målene er blitt isolert ut tilfredsstillende selv med begrensede data. Støynivået er litt høyere enn tidligere resultater med en bildedynamikk på 153.5dB.



Figur 2.10 Rekonstruert range-dopplerkart ved hjelp av standard sparse rekonstruksjon



Figur 2.11 Range-dopplerkart rekonstruert ved hjelp av 192x2 nevralt nettverk

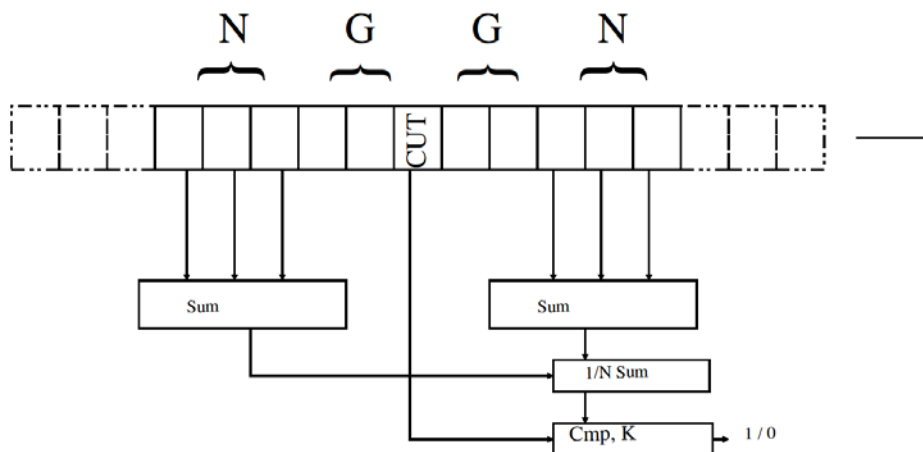
Resultatene fra dette kapitlet viser at selv om sparse rekonstruksjon blir sett på som en regnekrevende prosess, så kan dette implementeres og prosesseres ved hjelp av nevrale nettverk

også i radarsammenheng. Dette samsvarer godt med resultater som er blitt presentert i litteraturen fra andre fagfelt og indikerer ulike utradisjonelle bruksområder hvor nevralt nettverk kan tas i bruk.

3 CFAR deteksjon med maskinlæring

Deteksjon av mål i radardata er en grunnleggende problemstilling som er blitt forsket på i flere tiår. Dette er en utfordrende oppgave siden det er mye variasjon i hvordan målene fremstår og de kan være påvirket av miljøet rundt i form av ulikt clutter. Det er videre andre krevende områder som å detektere stealth mål med lav RCS. Det kan være enkeltmål eller situasjoner hvor flere mål befinner seg nær hverandre. Disse problemstillingene er blitt ytterligere aktualisert i de siste årene ved at bruk av mindre autonome droner har blitt vanlig. Flere droner som flyr nær hverandre kan gjøre deteksjonsprosessen enda mer utfordrende. Forut for alle deteksjonsmetoder ligger en hovedutfordring at man ønsker høy deteksjonsevne (P_d) samtidig som falskalarmraten (P_{fa}) må holdes lav og helst også konstant.

I prosjektet er det blitt utført forsøk med å implementere CFAR (Constant False Alarm Rate) deteksjonsmetoder ved hjelp av nevrale nettverk. For en noe grundigere teknisk gjennomgang henvises det for øvrig til (J. Akhtar, 2020c; J Akhtar & Olsen, 2018; J. Akhtar & Olsen, 2019). Disse teknikkene må betraktes som på et eksperimentelt nivå, men resultatene viser at gode deteksjonssegenskaper kan oppnås ved hjelp av trente nevrale nettverk. Dette ser særlig ut til å være mest relevant for SO (Smallest Of) –CFAR. SO-CFAR er en deteksjonsmetode som kan gi høy deteksjonsevne, men resulterer også i forholdsvis høy falskalarmrate i scener som ikke kun består av støy. I dette prosjektet er det blitt demonstrert at ved hjelp av nevrale nettverk kan falskalarmraten reduseres betraktelig, mot et moderat tap i deteksjonsevnen. Dette vil kunne muliggjøre en operativ bruk av SO-CFAR baserte deteksjonsmetoder implementert via nevrale nettverk.

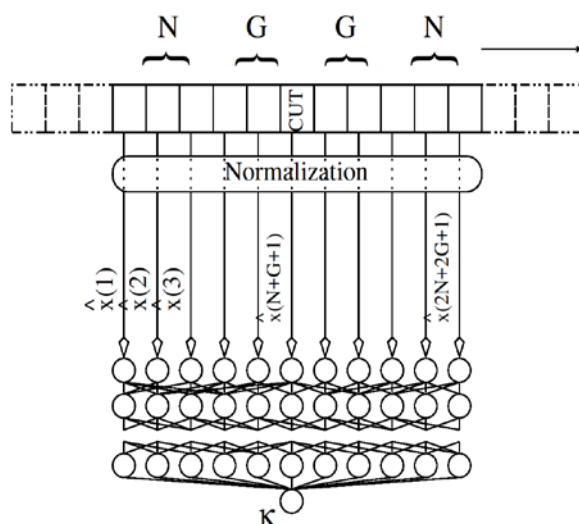


Figur 3.1 Illustrasjon på CFAR deteksjonsprosess

I dette kapittelet definerer vi en radar- og signal-modell som beskrevet i forutgående kapittel. Radaren sender ut et antall pulser i løpet av en integrasjonsperiode og prosesserer fram et range-dopplerkart. I deteksjonsprosessen løper en algoritme igjennom hver enkelt celle (CUT – celle under test) i kartet og sammenligner energinivået med et gjennomsnitt av energien i nabocellene. Hvis nivået i CUT overstiger energien til referansenivået med et gitt forhold, blir

det definert som en deteksjon. Prosessen er illustrert i Figur 3.1. Referansenivået kan regnes ut på ulike måter. I CA-CFAR (Cell Averaging-CFAR) regnes det ut som et gjennomsnitt av alle tilgjengelige $2N$ celler, mens i GO-CFAR (Greatest Of-CFAR) regner man ut to gjennomsnittsverdier til høyre og til venstre for CUT basert på N verdier. Den største verdien blant de to blir valgt som referansenivå. GO-CFAR gir ofte en mer robust deteksjon med lavere falskalarmrate siden referanseverdien alltid blir overvurdert noe. Det kan være en fordel hvis det er ekstra mye støy eller clutter, på den ene siden av CUT.


I den alternative varianten, SO-CFAR (Smallest Of-CFAR), velger man den minste av de to tilgjengelige verdiene. Ulempen med dette er at interferensen alltid vil bli undervurdert noe som kan gi betydelig høy falskalarmrate. Fordelen ligger imidlertid i at det er mulig å detektere mål selv hvis det skulle befinne seg et mål eller clutterkant på den ene siden av CUT. På grunn av høy falskalarmrate blir SO-CFAR lite anvendt; vi skal likevel foreslå en metodikk for å kunne ta denne detektoren i bruk for implementasjon via nevralt nettverk. Nettverket skal spesielt bli trent opp på å gjenkjenne falske deteksjoner i en gitt scenario og redusere dem til et mer akseptabelt nivå.



Figur 3.2 Illustrasjon på CFAR-prosess implementert via nevralt nettverk

3.1 Treningssett

Treningsmetodikken vi skal anvende baserer seg på å samle inn ulike typer CFAR-blokker hvor ønsket resultat ut, er definert på forhånd. Målenes eksakte posisjon i avstand og doppler må derfor vært kjent. Det antas videre at et relativt stort sett av range-dopplerkart er tilgjengelig hvor målene har varierende refleksjonsverdi og ulik hastighet. Kartene må også simulere effekten av clutter med skiftende intensitet for å dekke et spekter av ulike tilfeller. Et eksempel på et slikt kart er gitt i Figur 3.3.



Figur 3.3 Simulert range-dopplerkart med clutter og ulike måltyper

Her simuleres K-fordelt clutter i første halvparten av cellene og totalt syv mål er definert fra T til Z. Målene T og W befinner seg i clutterkanter, U og V er i et område dominert av clutter, mens de andre målene X, Y og Z blir kun påvirket av støy. Alle målene varierer tilfeldig i hastighet mellom -60m/s til 60m/s unntatt de som befinner seg i clutterområdet (T,U,V,W) der er tilfeldige utvalgte hastigheter begrenset til mellom -45m/s til 45m/s. Videre er målene U,V og X,Y plassert i nærheten av hverandre med en tilfeldig avstand varierende mellom 3 og 10 celler. Disse målene kan tenkes å illustrere tettflyvende droner, hvor X og Y for eksempel flyr høyt og er kun støybegrenset mens U og V flyr lavt og blir påvirket av clutter.

Målene er videre simulert slik at for halvparten av tilfellene sprer de seg utover en nabocelle som simulerer range-walk og alle mål har sideløber med et nivå på -20dB i nabocellene.

Et slikt sett av range-dopplerkart kan brukes for å generere et stort utvalg av situasjoner som en detektor vil kunne oppleve i et ikke-statisk miljø. Basert på tilgjengelige data må nettverket lære seg å gjenskape samme type oppførsel som treingsdetektoren og forsøke å forbedre det. Her poengteres det at en CFAR-test kun ser på de relative verdiene og det samme vil være tilfelle for et nevralt nettverk hvor inn-dataene normaliseres. Gjentakende situasjoner som vil gi positive eller falske deteksjoner vil derfor i stor grad være uavhengig av de absolutte verdiene i scenarioet. De mer spesifikke parameterne, som må justeres for ulike nevrale nettverk, vil være CFAR-relaterte parametere, radar-parametere som avstandsoppløsning, den antatte clutterfordelingen og ikke minst modellert målrespons med tilhørende prosesserings-sideløber.

Treningskriteriet som nettverket trenes etter er definert som

$$\hat{k} = \begin{cases} 1, & \text{SO-CFAR positiv og mål i CUT} \\ 0, & \text{ellers.} \end{cases}$$

Det trenede nettverket skal dermed i prinsippet kun returnere et positivt resultat hvis SO-CFAR også ville ha gitt et positivt resultat, men dette skal bare forekomme hvis det samtidig befinner seg et ekte mål i CUT. I alle andre tilfeller skal nettverket lære seg å returnere null.

For det illustrerende scenarioet som er avbildet i Figur 3.3 ble deteksjonsterskelen til SO-CFAR satt til 14dB med $G=3$ guardceller og $N=9$ referanseceller. Tre ulike typer nettverk ble trent med ulike treningsforutsetninger. Alle nettverkene er *fully-connected feedforwarding* nettverk hvor alle nodene er koblet mot hverandre på neste nivå. Størrelsen på nettverket ble satt til 75 noder i to lag med *tanh* som aktiveringsfunksjon.


Det første nettverket (case 1) ble trent på 200.000 blokker med ekte deteksjoner og 200.000 tilfeldige blokker hvor SO-CFAR ikke ga deteksjon. Dette nettverket trenes dermed ikke på falske deteksjoner. Det andre nettverket (case 2) ble i tillegg til dataene for case 1 trent på 40.000 falske deteksjoner fra SO-CFAR, mens for det tredje nettverket (case 3) ble antall falske deteksjoner økt til 600.000. Siden det første nettverket ikke trenes på falske deteksjoner kan en antageligvis heller ikke forvente noen spesiell reduksjon i falske deteksjoner, men heller at nettverket skal konvergere mot standard SO-CFAR. Det siste nettverket trenes med betydelig antall falske deteksjoner og bør kunne gjenkjenne situasjoner som resulterer i feilaktige deteksjoner i mye større grad. Dette vil nok komme med en kostnad i form av reduksjon i deteksjonssannsynlighet. Hvis denne reduksjonen ikke er betydelig, vil dette likevel være en forholdsvis forbedring overfor den opprinnelige CFAR deteksjonsmetoden. Case 2 befinner seg i mellom de ulike ekstremsituasjonene og kan sees på som et kompromiss.

3.2 Evaluering

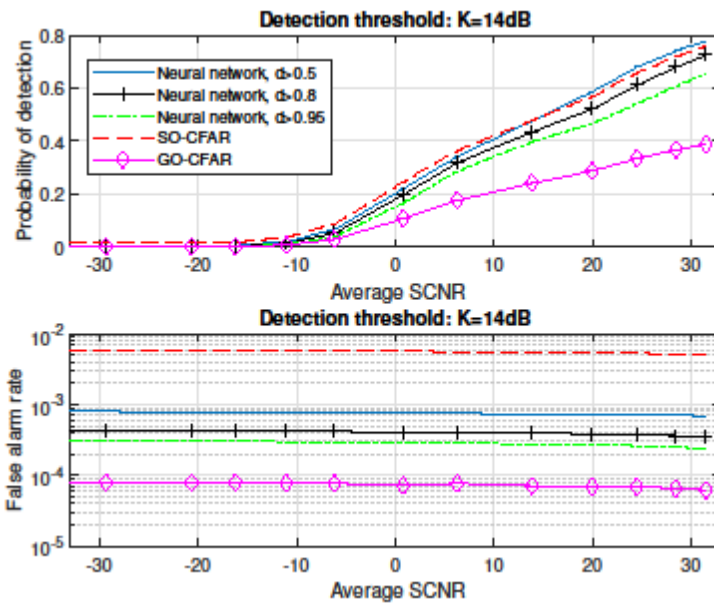
Etter en gjennomført trening må nettverkene evalueres på et annet datasett enn det som er anvendt for trening. Det ble derfor generert nye tilfeldige 6400 range-dopplerkart med samme type oppsett som tidligere, men nå med en gitt gjennomsnittlig SNR. Disse ble bedømt ved hjelp av SO-CFAR, GO-CFAR og med de trente nevrale nettverkene. Deteksjonsterskelen for nevrale nettverk ble satt til 0.5, 0.8 og 0.95. En lav terskel vil typisk gi god deteksjonsevne, men også føre med seg en høyere falskalartrate. Resultatene fra kjøring over case 1 kan sees i Figur 3.4. Figur 3.5 angir resultatene fra case 2, mens case 3 er visualisert i Figur 3.6. Den rosa kurven angir deteksjonsytelsen med GO-CFAR mens for SO-CFAR vises dette i rødt. Resultatene fra kjøringen av nevrale nettverk er gitt i blå (deteksjonsterskel på 0.5), svart (deteksjonsterskel på 0.8) og grønn (deteksjonsterskel på 0.95). En kan observere at GO-CFAR har gjennomgående lav falskalartrate, men har til gjengjeld lav deteksjonsevne. Denne metoden sliter med å identifisere mål i clutterkantene (mål T og W) og nærliggende mål som U, V og X, Y i Figur

3.3. SO-CFAR gjør det derimot ganske så bra og har høy deteksjonsevne, men dog med høy falskalarmrate.

Når det gjelder det trente nevralt nettverket har den rett og slett konvergert mot standard SO-CFAR og gir identisk ytelse, litt avhengig av hvor deteksjonsterskelen settes. Dette er med på å bekrefte at treningsmetoden og datagrunnlaget er et godt utgangspunkt for videre trening med ilagte falske deteksjoner.

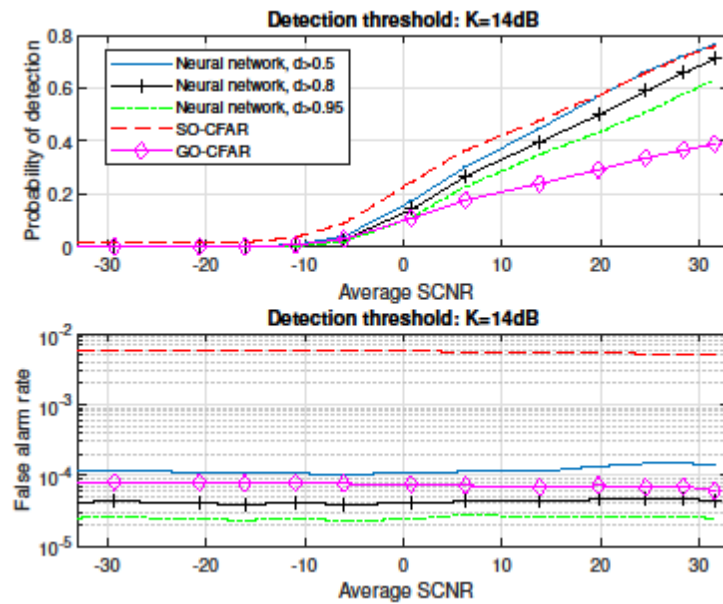


Figur 3.4 Deteksjonsytelse og falskalarmrate for case 1



Figur 3.5 Deteksjonsytelse og falskalarmerate for case 2

Resultatene fra case 2 i Figur 3.5 viser at trening på falske deteksjoner hjelper til med å redusere falskalarmeraten. Falskalarmeraten er nå vesentlig lavere. Deteksjonskurvene har likeledes også beveget seg noe nedover, men gir bare et moderat tap i forhold til SO-CFAR. Case 3 resultatene i Figur 3.6, hvor man trener vesentlig på falske deteksjoner, gir et enda tydeligere bilde hvor nettverket har, i snitt, klart å komme på samme falskalarmerate-nivå som GO-CFAR. Deteksjonsevnen er derimot fortsatt klart bedre enn GO-CFAR. En kan derfor konkludere med at nettverket evner å gi en ytelsesforbedring over de mer tradisjonelle detektorene.



Figur 3.6 Deteksjonsytelse og falskalarmsrate for case 3

De overnevnte resultatene, særlig fra case 3, er gode, men representerer likevel gjennomsnittlige verdier over det scenarioet som er blitt modellert. For en dypere forståelse er det mulig å gjøre analyser hvor en evaluerer deteksjonsevnen og falskalarmsraten med kun utvalgte mål og da med og uten clutter. Dette kan gi pekepinn på hvor nettverket gjør det bra og ikke så bra.

Mål	NN $\kappa > 0.5$	NN $\kappa > 0.8$	NN $\kappa > 0.95$	SO	GO
Alle, ingen clutter	0.83	0.78	0.69	0.76	0.40
T, W, Z ingen clutter	0.82	0.79	0.74	0.81	0.78
U, V, X, Y ingen clutter	0.83	0.77	0.66	0.81	0.16
Alle, med clutter	0.79	0.73	0.65	0.78	0.41
U med clutter	0.70	0.67	0.62	0.70	0.66
U, V med clutter	0.74	0.68	0.57	0.72	0.15
T med clutter	0.76	0.72	0.66	0.78	0.65

Figur 3.7 Deteksjonsytelse for ulike oppsett

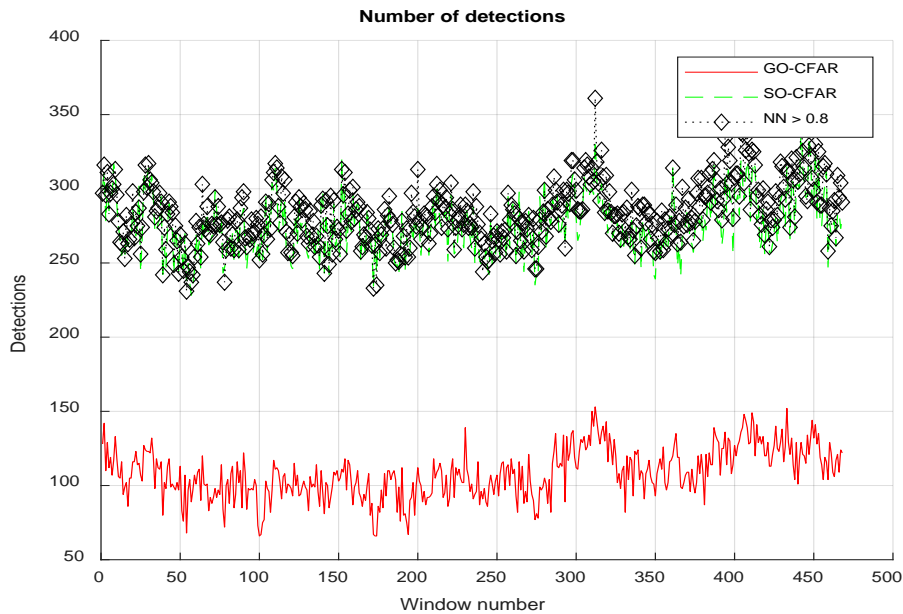
Mål	NN κ >0.5	NN κ >0.8	NN κ >0.95	SO	GO
Alle, ingen clutter	1.13·10 ⁻⁴	3.25·10 ⁻⁵	1.79·10 ⁻⁵	9.39·10 ⁻⁶	7.69·10 ⁻⁵
T, W, Z ingen clutter	2.85·10 ⁻⁴	1.11·10 ⁻⁵	7.42·10 ⁻⁶	1.12·10 ⁻⁵	3.71·10 ⁻⁵
U, V, X, Y ingen clutter	8.75·10 ⁻⁵	2.89·10 ⁻⁵	1.70·10 ⁻⁵	1.19·10 ⁻⁵	3.74·10 ⁻⁵
Alle, med clutter	1.90·10 ⁻⁴	6.95·10 ⁻⁵	3.72·10 ⁻⁵	5.08·10 ⁻³	6.39·10 ⁻⁵
U med clutter	1.34·10 ⁻⁴	6.49·10 ⁻⁵	3.82·10 ⁻⁵	5.96·10 ⁻³	6.98·10 ⁻⁵
U, V med clutter	1.55·10 ⁻⁴	6.90·10 ⁻⁵	4.17·10 ⁻⁵	6.00·10 ⁻³	6.29·10 ⁻⁵
T med clutter	1.00·10 ⁻⁴	4.95·10 ⁻⁵	2.92·10 ⁻⁵	4.97·10 ⁻³	6.88·10 ⁻⁵

Figur 3.8 Falskalarmsrate for ulike oppsett

Tabellen i Figur 3.7 angir deteksjonsytelsen, mens falskalarmsraten over varierende SNR er gitt i Figur 3.8. De tre øverste radene angir ytelse i situasjoner uten clutter, mens de fire andre inkluderer clutter som modellert tidligere. «Alle» indikerer at alle målene er inkludert i analysen. Ser man på ytelsen fra SO-CFAR eller GO-CFAR i de to ytterste kolonnene til høyre, er det åpenbart at både SO og GO evner å gi lav falskalarmsrate når det er snakk om kun støybegrenset deteksjon. Dette er som forventet. GO sliter riktignok med en lavere deteksjonsytelse og dette er særlig merkbart ved at nærliggende mål, indikert i rad tre med U, V eller X, Y som mål, ikke blir detektert. SO-CFAR har gjennomgående god deteksjon, men får høy falskalarmsrate når en legger til situasjoner med clutter. Sammenligner en de resultatene med ytelsene fra nevnte nettverk ser man et langt mer konsistent bilde i forhold til falskalarmsrate med langt mindre variasjon. Verdiene er omtrent på samme nivå om man ser på deteksjon i støy eller clutter og med ulike situasjoner. De trente nettverkene yter en deteksjonsevne som er særlig forbedret sett i forhold til GO-CFAR, men når ikke helt opp til SO-CFAR. Dette samsvarer med treningsmetodikken som vil gi et visst tap i Pd mot en større gevinst med en redusert Pfa. Vi kan også observere at nettverkene har noe høyere falskalarmsrate i støy sammenlignet med for eksempel SO-CFAR. Dette er momenter som man eventuelt kunne vektlegge mer i et treningsoppsett.

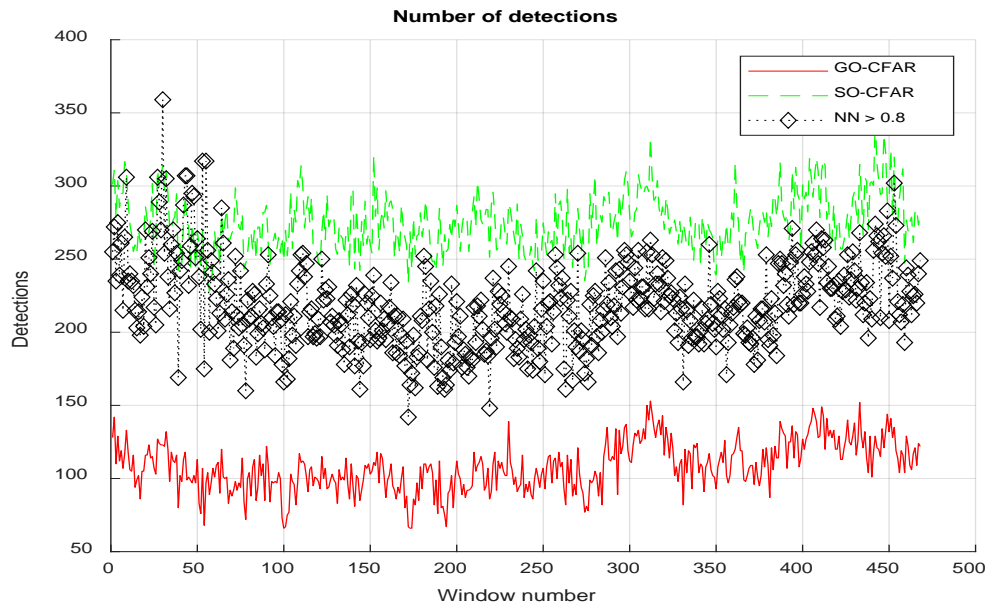
3.3 Utprøving på ekte data

Nettverkene i dette kapittelet er trent på simulerte data med visse antagelser om målenes sideløber i avstand og doppler (angitt indirekte av vindusfunksjon) i en clutterbakgrunn med en gitt fordeling. Det er dermed interessant å vurdere hvordan ytelsen vil være under utprøving med ekte innsamlede data. For å teste dette, ble dataene fra NeXtRad-systemet benyttet fra et feltforsøk fra 2017. Figur 3.9 illustrerer oppsettet for målingene hvor den gule pilen angir stedet for monostatisk transmisjon og mottak. De røde pilene angir bistatiske mottakere som ikke vurderes i denne sammenheng. Et fyrtårn er i scenen angitt med grønn sirkel. Et unormalisert range-dopplerkart fra denne scenen konstruert ved hjelp av 24 slowtime-pulser er vist i Figur 3.10. Under målekampanjen var det to flyvende droner samtidig som andre objekter som båter og fugler ble observert. Det ble generert 470 range-dopplerkart over tid som ble evaluert av de trente nettverkene samtidig med at de også ble analysert med standard GO- og SO-CFAR. Det bemerkes at de trente nettverkene ikke vil samsvare med de eksakte radarparameterene for NeXtRad og videre er det også ukjent hva som vil kunne defineres som riktig og falsk

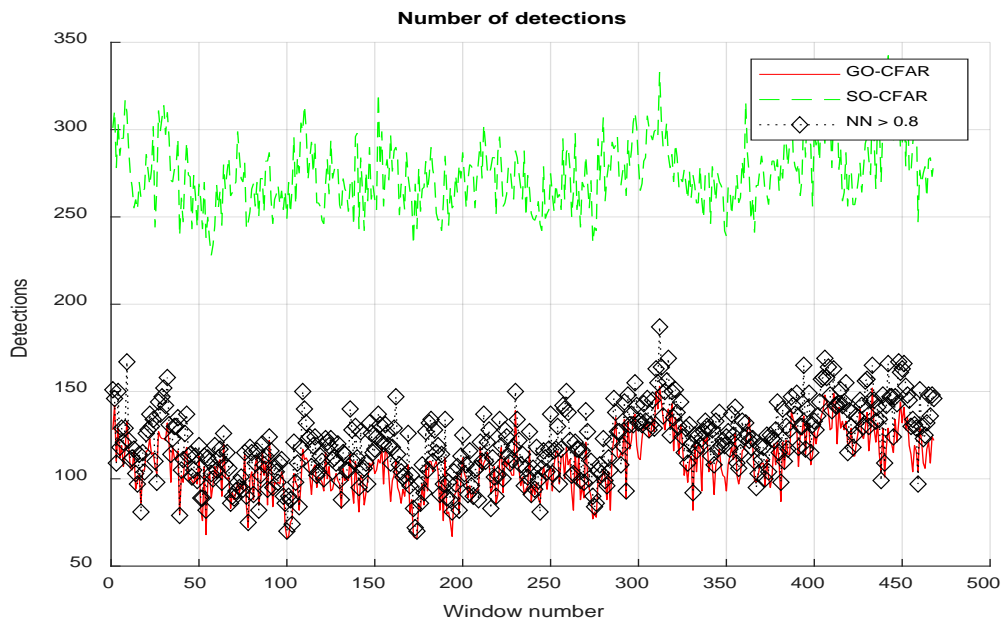


Figur 3.11 Antall deteksjoner per range-dopplerkart ved hjelp av ulike CFAR-metoder og nevralt nettverk (NN) (case 1)

Resultater fra kjøring av GO-CFAR, SO-CFAR og trente nevrale nettverk (NN) på range-dopplerkartene er vist i Figur 3.11 til Figur 3.13. For hvert range-dopplerkart (window number) er det plottet antall deteksjoner som gjøres med de ulike metodene. I figur Figur 3.11 ser en at GO-CFAR (rød kurve) gir relativt få deteksjoner i motsetning til SO-CFAR (grønn kurve). Det nevrale nettverket fra case 1 (svart kurve) gir ganske sammenlignbar ytelse som standard SO-CFAR. I Figur 3.12 er det derimot slik at case 2 nettverket klarer å redusere antall deteksjoner i forhold til SO-CFAR, mens i Figur 3.13 har nettverket en deteksjonsrate som er vesentlig nærmere GO-CFAR. Dette harmoniserer godt med Figur 3.6 og de tidligere resultatene som indikerte at de trente nettverkene evner å få ned totalt antall deteksjoner fra SO-CFAR.



Figur 3.12 Antall deteksjoner per range-doppkart ved hjelp av ulike metoder og nevralt nettverk (case 2)



Figur 3.13 Antall deteksjoner per range-doppkart ved hjelp av ulike metoder og nevralt nettverk (case 3)

4 Oppsummering maskinl ring

I kapittel 2 og 3 har vi sett p  eksempler p  bruk av nyere metoder som compressed sensing og maskinl ring i radar. Disse teknikkene gir nye muligheter til   forbedre radarytelse ved hjelp av moderne signalbehandling hvor regnekraft er blitt en viktig ressurs.

Metodene omtalt i denne rapporten er helt klart mange ganger mer regnekrevende i forhold til for eksempel FFT (Fast Fourier Transform), men kj ring av nevralt nettverk baserer seg i dag p  egne grafikkort (GPU). Slike kort er godt tilpasset problemstillinger hvor det m  foretas mange beregninger parallelt og utviklingen innen GPU-kort er fortsatt stor. Det er videre viktig   v re klar over at selv om metodene blir mer regnekrevende s  kommer de med en avveining hvor en gir avkall p  tradisjonelle krav i forhold til for eksempel samplingsrate eller antall pulser som m  sendes.

De ulike fagfeltene ber rt i tidligere kapitler er likeledes i stor endring og derfor er det viktig at ulike systemer og fremtidige radarer har funksjonalitet for   implementere nye algoritmer og   kunne oppgradere minne og forskjellige prosessorer. Da vil man kunne ta i bruk mer effektive algoritmer og erstatte noen av dem med andre beregningsmetoder, som for eksempel nevralt nettverk, etterhvert som erfaring og kunnskap om nye metoder og teknikker blir moden for bruk.

5 Innledning adaptiv stråleforming

De fleste nåværende operative langtrekkende militære radarer har fasestyrte gruppeantennener. Eksempler på fasestyrte gruppeantennener finner vi i store overvåkningsradarer, luftbårne radarer i kampfly eller de kan være del av et luftvernssystem. Gruppe av sensorer har en lang historie. Allerede under første verdenskrig ble en akustisk gruppeantenne benyttet av franskmennene for å lytte etter fiendens fly, (Johnson & Dudgeon, 1993). Snart etter andre verdenskrig kom utviklingen av radarer med fasestyrte gruppeantennener godt i gang. (Dolph, 1946) beskrev en metode for å forme beamer med lave sideløber slik at forstyrrende signaler i sidelobene blir dempet. Gruppeantennener med flere mottakskanaler gir prosessoren mulighet til å konstruere optimale romlige filtre som er tilpasset det aktuelle signalmiljøet. Jo flere mottakskanaler jo bedre tilpasningsmuligheter. På slutten av 60 tallet kom adaptive stråleformingsmetoder (Adaptiv Beamforming (ABF)) beskrevet av Applebaum (Applebaum, 1976) og Capon (Capon, 1969) som noen av de første. De første antennene med flere mottakskanaler var monopuls-radarer som klarte seg med 3 mottakskanaler for å gjøre retningsbestemmelse i både azimuth og elevasjon. Monopulse-radarer er fortsatt mye benyttet.

De første fasestyrte gruppeantennene var Passiv Elektronisk styrt gruppe (PESA) antenner hvor alle antenneelementene er knyttet til en felles mottaker/sender, og faseskiftere benyttes for å styre beamen. En aktiv elektronisk styrt grupperadar (AESA) har en computerstyrt analog sende/mottaks-modul bak hvert antenneelement. Fasestyrte antenner med en analog-digital omformer knyttet til hver mottaker/sender kalles gjerne Digital stråleforming (DBF) fasestyrt gruppeantenne. Den fasestyrte antennen kan ha en mottaker/sende-modul for hvert element eller for hver gruppe av antenneelementer arrangert i en subgruppe-struktur. En antenne med full digital stråleforming har en analog-digital omformer for hvert element. Betegnelsen digital electronic scanned gruppe- (DESA) antenne blir også benyttet om DBF antenner.

Fasestyrte antenner med elektronisk skanning gjør det mulig å flytte beamen nesten momentant, og dermed kan flere mål følges samtidig med at det søkes etter nye. En AESA antenne med en sender/mottaker-modul (TRM) for hvert element er i stand til å hente ut retningsinformasjonen i mottatt signal bedre enn mekanisk roterende disk-antenne eller konvensjonell PESA-antenne med en enkel mottakskanal. Signalprosessoren for en AESA kan konstruere romlige filtre som maksimerer forsterkning i retning av målet og undertrykker interferens fra andre retninger slik at forholdet mellom signal og støy pluss interferens (SINR) maksimeres. SINR er en nøkkelfaktor for radarens deteksjonsevne. Digital stråleforming gruppeantennene har i tillegg fordelen av at all signalprosessering av mottatt signal skjer digitalt, og mange beamer kan testes ut samtidig av computeren. Det gir mer effektiv undertrykking av jamming og interferens, og dessuten høyere oppløsning i retningsbestemmelsen av mål og jammer. Videre vil en antenne med mange TRM-er være robust mot forfall, i og med at bare den delen av antennen som inneholder den ødelagte modulen, blir berørt. Resten av antenne vil kunne fungere ok i motsetning til en monopulse-antenne hvor hele antennen bryter sammen hvis en av kanalene blir ødelagt.

Det er også en del utfordringer for gruppeantenner med mange TRM-er, se for eksempel (Aalfs, 2013). Vi nevner noen: Det vil være lite plass bak hvert element til nødvendig hardware, spesielt når radiofrekvensen er høy. Avstanden mellom antenneelementene må være av samme størrelsesorden som bølgelengden, og avstand en halv bølgelengde sikrer at man unngår gitterlober hvor hovedloben foldes inn flere ganger i radarens synsfelt. Det vil være en stor datastrøm til computeren fra en DBF antenne med mange mottakskanaler og høy samplingsrate. Samtidig kreves store regneressurser for sanntidsprosesseringen som utnytter informasjonen det er mulig å hente ut av dataene. Videre må mottaker-hardware være motstandsdyktig mot interferens og ha stort dynamisk område for en DBF-antenne siden hvert antenneelement vil ha relativ konstant direktivitet over stor åpningsvinkel. Dette stiller større krav enn for en PESA-antenne hvor mottakermodulen sitter etter den analoge stråleforming, og lave sidelober i antennemønsteret vil beskytte mottagerelementet mot sterk jamming i sideloben. Alle mottakerne må også være godt kalibrert med hensyn til tid og styrke over frekvensbåndet slik at signalet fra de ulike mottakerne ikke dekorrelerer og svekker mulighet for stråleforming.


Aktiviteten i OPRA II prosjektet innen temaet fasestyrte antenner har i stor grad hatt fokus på prosesseringen av signaler tatt opp med gruppeantenner, såkalt array-prosessering. Prosjektet har sett på om det er enkelt å hente ut og dra fordeler av den ekstra retningsinformasjonen signaler som er høstet med gruppeantenner potensielt har, sammenliknet med informasjonen gitt fra en mekanisk styrt disk antenne eller en PESA med enkel mottakskanal. Resultater fra arbeidet er benyttet som underlagsmateriale inn mot andre prosjekter slik som P2078 Sensorer for militær luftromsovervåking. Det finnes omfattende litteratur om array-prosessering og adaptiv stråleforming. To tekstbøker om temaet er (VanTrees, 2002), (Johnson & Dudgeon, 1993).

6 Stråleforming og array-prosessering i OPRA II

Dette kapitlet sammenfatter artikler og rapporter som er utarbeidet under OPRA II prosjektet i sin helhet eller hvor en betydelig del er utarbeidet under prosjektet. Det blir også henvist til andre arbeider i tilstøtende prosjekter der OPRA II har bidratt uten nødvendigvis å ha vært den dominerende aktøren. Rapportene og artiklene dokumenterer arbeid utført i OPRA II prosjektet relatert til gruppeantenner og særlig til signalprosesseringen forbundet med fasestyrte gruppeantenner.

6.1 Passiv radar målinger

I (Strøm et al., 2017; Strøm et al., 2018) er det gjort målinger med Digital videosending-jordbasert (DVB-T) passiv radar med uniform linear gruppe- (ULA) antenne og full DBF. Det ble verifisert at antenne og radarsystem mottok signaler med god nok kvalitet til at stråleforming lot seg gjøre. Signalkvaliteten var god nok til at adaptiv stråleforming oppnådde betydelig bedre SINR enn vanlig stråleforming når radaren var utsatt for direkte signalinterferens fra DVB-T senderen, (Strøm et al., 2018). Målinger med to ULA-antenner ble gjort i (Strøm et al., 2017), den ene antennen ko-polarisert og den andre kryss-polarisert med DVB-T senderen. Bare konvensjonell stråleforming ble benyttet i dette tilfellet. Stråleforming virket bra, men om det er fordelaktig å benytte kryss-polarisert antenne var vanskeligere å fastslå. Figur 6.1 viser den konfigurerbare gruppeantennen for den passive DVB-T radaren.



Figur 6.1 Antenne og kabinet PC-kluster for DVB-T passiv radar

6.1.1 DVB-T passive radar dual polarisasjonsmålinger under påvirkning av sterk direktesignal-interferens. Konferanse proceeding IRS-2017, IEEE explore (Strøm et al., 2017)

En passiv bistatisk radar med dobbel polarisasjon er anvendt for å vurdere mulige fordeler med kryss-polariserte målinger for undertrykkelse av sterkt direktesignalinterferens i DVB-T båndet. Den lineære gruppeantennen består av 10 bowtie-elementer hvor 5 måler horisontal og 5 vertikal polarisasjon. To små fly utstyrt med GPS-mottakere ble benyttet som mål og fløy foreskrevne baner. To antenneplasseringer ble benyttet. For den ene var tv-senderen bare 20 grader fra antennens boresight og denne forårsaket sterkt direktesignalinterferens. I den andre plasseringen var antennen delvis skjermet fra senderen. I begge polarisasjonskanalene ble rekonstruksjon av referansesignal og resiprokal filtrering benyttet for å undertrykke interferens. Resiprokal filter er en type signal-tilpasset filter. GPS-data fra flyet ble benyttet til å finne bistatisk range, doppler og asimut-posisjon. Signal-til-interferens-pluss-støy-forholdet (SINR) ble målt ved denne posisjonen. I tillegg ble asimut fra GPS-posisjonen sammenliknet med retningen avledet fra radarmålingen. Vi finner ingen fordel ved å benytte krysspolarisasjon, selv i tilfellet med sterk direkte-signal-interferens. I gjennomsnitt er det ingen signifikant forskjell mellom ko- og kryss-polarisert SINR, og den ko-polariserte kanalen er litt bedre til å forutsi riktig asimut.

6.1.2 Direktesignalundertrykking med adaptive stråleforming i DVB-T passiv radarmålinger. Konferanse-proceedings IRS-2018, IEEE explore (Strøm et al., 2018)

Adaptiv stråleforming som maksimerer signal-til-støy pluss interferens forholdet er anvendt på dataopptak gjort med passive bistatisk radar utsatt for sterk direktesignal-interferens. DVB-T senderen var lokalisert omtrent 20° fra boresight. Adaptive stråleforming er anvendt etter range-doppler prosessering hvor range-doppler prosesseringen er basert på rekonstruksjon av referansesignalet og resiprokal filtrering. Opptakene ble gjort av en uniform lineær gruppeantenne med 11 horisontalt polariserte bow-tie-elementer, og av to ko-lokaliserte uniforme lineære gruppeantenner med 5 bow-tie-elementer hver, en horisontal polarisert og den andre vertikalt polarisert. Et lite fly utstyrt med GPS-mottaker ble benyttet som samarbeidende mål under opptakene. Ved hjelp av GPS-koordinatene ble flyets bistatiske range-doppler-lokasjon funnet og SINR målt i en halv time. Minimum varians forvrengningsfri respons (MVDR) adaptiv beamformer oppnår signifikant bedre SINR enn den konvensjonelle beamformerer for antennen ko-polarisert med senderen, gjennomsnittlig 4.5dB for 11 elementer og 2dB for 5 elementer. Mindre enn 1dB forbedring ble oppnådd med 5 elementer krysspolarisert antenne. Interferensens av stasjonær karakter tillot å definere MVDR-beamformerer med den samme romlige kovarians-matrisen for støy-pluss-interferens uten oppdateringer gjennom hele opptaket på en halv time uten vesentlig forringelse av beamformerens respons.

6.2 Målinger med kortholdsradar og interferens

MVDR-beamformerer maksimerer SINR over alle beamformer for en gitt gruppeantenne-avlesning, også kalt snapshot. Det øker deteksjonssannsynligheten. Men i en konstant falskalarbrate (CFAR) detektor vil det også kunne øke den falske alarmraten når støyen ikke er homogen, (Melvin, 2013). Med homogen støy forstår vi at treningsdataene som benyttes for estimering av den romlige kovariansmatrisen for støy og interferens har samme fordeling som cellen under test ved antagelsen om fraværende signalekko fra målet. Denne romlige kovariansmatrisen estimeres gjerne ved Sample matrix inversion (SMI) prosessen som er en midlingsprosess, (Widrow, Mante, Griffiths, & Good, 1967), (Reed, Mallett, & Brennan, 1974). For inhomogen støy vil den reelle støyen for cellen under test kunne avvike fra den estimerte, og dermed føre til økt falskalarbrate. MVDR vil maksimere SINR for alle celler under test, også når cellen er uten reelt målsignal. Dermed vil estimert SINR for falskt målsignal blåse opp i større grad enn for en konvensjonell beamformer. Det er derfor et spørsmål om den falske alarmraten øker uforholdsmessig mye sammenliknet med oppnådd økning i deteksjonssannsynlighet. I (Strøm, Christiansen, & Gusland, To appear 2021) har vi gjort målinger med en frekvensmodulert kontinuerlig bølge(FMCW)-kortholdsradar med full DBF ULA-16 antenne. Adaptiv stråleforming er benyttet for å undertrykke interferens. Deteksjonssannsynlighet og falskalarbrate er sammenliknet for konvensjonell og adaptiv stråleforming. Adaptiv stråleforming kom fordelaktig ut av sammenlikningen. Radaren er i utgangspunktet laget for annet formål, men den virket bra også i dette tilfellet med flombelysning og mye bakkestøy slik at vi kunne se god effekt av adaptiv stråleforming. Et lignende forsøk ble utført i (Strøm & Norheim-Næss, 2019) med en FMCW kortholdsradar hvor ULA-antennen hadde 8 elementer. I dette forsøket var interferenskilden en digital radiofrekvensminne (DRFM) jammer.

6.2.1 Array-prosessering og interferens i målinger med kortholdsradar. FFI-notat (Strøm & Norheim-Næss, 2019)

Array-prosesseringsteknikker er testet for undertrykking av interferens under søk etter et mål av typen ubemannet luftfartøy med en kortholds FMCW-radar. Konvensjonell stråleforming med sidelobeundertrykking og nulling så vel som minimum varians adaptiv stråleforming med lineære føringer er anvendt og sammenliknet for ulike typer av interferens påført ved en Digital Radio Frekvens Minne (DRFM) jammer i fiksert posisjon. En drone utstyrt med en globalt posisjoneringssystemmottaker (GPS) var samarbeidende mål. Opptak ble gjort hovedsakelig med en interferenskilde i hovedloben eller i dens umiddelbare nærhet. Deteksjonsratene var lave, men adaptiv stråleforming oppnådde betydelig bedre resultater enn konvensjonell stråleforming. Adaptive metoder var også i stand til å lokalisere vinkelposisjonen til interferenskilden.

6.2.2 Adaptiv stråleforming for interferensundertrykking i en flombelysende radar. FFI-rapport utkast (Strøm et al., To appear 2021)

Målinger er utført med en flombelysende FMCW kortholdsradar utsatt for interferens. En drone utstyrt med GPS var samarbeidende mål under opptakene. Radarantennen er en uniform linear gruppeantenne med 16 elementer og mottakskanaler, og tilbyr full digital stråleforming. Dataopptakene ble prosessert med konvensjonell stråleforming og med MVDR adaptiv stråleforming. Begge beamformerne ble testet med og uten Dolph-Chebyshev-dempning for lave sideløber. Deteksjonssannsynlighet og falskalarmløper oppnådd med de ulike prosessorene ble sammenliknet. Støyjammeren sendte med en effekt som til en viss grad, men ikke helt, blendet radaren når den befant seg i den konvensjonelle beamformerens sideløber. Når mål og jammer samtidig opptrådte i beamformerens hovedlobe, ble den konvensjonelle beamformerer nesten fullstendig blendet. I begge tilfellene oppnådde den adaptive MVDR beamformerer bedre deteksjonssannsynlighet, og spesielt ved jamming i hovedlobe. Estimerer av den falske alarmraten var høyere for MVDR-beamformerer enn for den konvensjonelle. Noe som ikke er uventet når støyen er inhomogen, (Melvin, 2013). Plot av deteksjonssannsynlighet versus falskalarmløper-estimerer ved ulike SINR-deteksjonsterskler indikerer at MVDR-beamformerer totalt sett oppnår bedre resultater enn den konvensjonelle beamformerer, og signifikant bedre ved jamming i hovedlobe. Lav sideløbenivå-dempning hadde en positiv effekt for både den konvensjonelle og MVDR-beamformerer når jamming inntraff i sideløben,. Imidlertid ble en motsatt effekt observert for jamming i hovedloben. En mulig forklaring til dette er at hovedloben blir bredere ved sideløbedempning. Dermed vil en jammestrobe som befinner seg i utkanten av hovedloben for en beamformer uten dempning, befinne seg mer sentralt i hovedloben for en beamformer med sideløbedempning. Jo mer sentralt i hovedloben jammeren befinner seg jo kraftigere blir responsen fra den konvensjonelle beamformerer. Den adaptive beamformerer vil plassere en null i retning av jammeren, og jo mer sentralt i hovedloben nullen settes inn jo dårligere blir direktiviteten i retningen mot målet sentralt i hovedloben. Målinger ble gjort for ulike målbaner og flere posisjoner for jammeren. Doppler-forskjøvne signaler reflektert fra UAV-propellene var sterke for deler av dronebanene og skapte utfordringer for estimering av falskalarmløper i de tilfellene.

Figur 6.2 viser FMCW-radar, støyjammer og mål i form av en drone med GPS som ble benyttet under forsøket (Strøm et al., To appear 2021).



Figur 6.2 FMCW kortholdsradar venstre panel og støyjammer høyre panel


6.3 Flombelysende kortholdsradar

Radaren benyttet under (Strøm et al., To appear 2021) er utviklet i et annet prosjekt i samarbeid med Kongsberg-gruppen, (Gusland, Christiansen, Strøm, Akhtar, & Torvik, 2020). Radaren er flombelysende på sending, noe OPRA II prosjektet har bidratt med. Ved sending ønsker man full effekt ut og ikke noe demping, så sendebeamen er formet ved bare å modifisere fasene på signalet som hvert element sender ut. Matematikken som ligger under for å forme beamer på denne måten blir vanskeligere, og vi har gjort simuleringer for å beregne de individuelle faseforskyvningene som skal til for å lage den ønskede formen. (Strøm, 2020) beskriver simuleringene som ligger til grunn for beregningen av de ønskede faseforskyvningene. Faseforskyvningen er implementert i hardware på radarantennen, og målinger i ekkokammer av antennediagrammet viser godt sammenfall med antennemønsteret slik det fremkom gjennom simuleringer i MATLAB, (Gusland et al., 2020) .

OPRA II har også bidratt inn i signalprosessering for retningsbestemmelse med den samme radaren, der metoden for effekt av minste varians (PMV) er implementert, (Gusland et al., 2020). PMV er en metode for retningsbestemmelse som gir superopløsning, og er en variant av MVDR nært beslektet med en annen metode for retningsbestemmelse kalt multiple signal klassifisering (MUSIC.)

6.3.1 Phase Only Pattern Synthesis for kortholdsradar. FFI-notat (Strøm, 2020)


En phase only pattern synthesis (POPS) metode (Khzmalyan, 2003) er testet for utforming av sendebeamen til en ULA med 16 elementer. POPS modifierer bare fasene, men ikke amplituden til signalet fra hvert av antenneelementene, og minimerer dermed tapet i energien som sendes ut. Ideelle beamer med konstant intensitet over en spesifisert åpningsvinkel er approksimert ved metoden. Matlab-simuleringer er utført for antenne med isotropiske elementer og for antenneelementer med en forenklet elementfaktor med form av et romvinkel båndpassfilter. Metoden oppnår temmelig gode approksimasjoner til flat-topp-templatene, men intensitetsvariasjoner forekommer, spesielt når den ønskede åpningsvinkelen er stor. Stabiliteten til POPS-metoden er i noen grad testet ved å perturbere flat-topp-templatene, og testen indikerer en nokså stabil metode. Metoden er sammenliknet med Woodward-syntese for approksimasjon av den samme flat-topp-templatene hvor elementdempning er benyttet i tillegg til fasemodifikasjoner. POPS-metoden forårsaker høyere sideløber og større intensitetsvariasjoner innenfor den ønskede åpningsvinkelen enn Woodward-syntesen, men fordelene med vektene av uniform størrelse kan veie opp for disse ulempene. Radarer utstyrt med digital beamforming på mottak kan antas å ha fordeler ved å forme beamen til en flat-topp-beam på sending. Beamformerne oppnådd fra simuleringene er implementert på et reelt system med ULA-16 antenne og målinger av strålingsmønsteret til det reelle systemet stemmer godt overens med simuleringresultatene i Matlab (Gusland et al., 2020). Simuleringer og målinger av normalisert antennediagram for den flombelysende radaren er vist i Figur 6.3. Høyre figur viser approximasjon til flat topp med åpningsvinkel 60° . Woodward syntese for flat topp diagram med åpningsvinkel 60° vil ha elementdempning på 14 av de 16 elementene, og hvor de dempede spenningsamplitudene har relativ størrelse i intervallet (0.098,0.34) av de udempede. Dette tilsvarer utsendt effekt for Woodward-syntesen på ca 15% av effekten til en sendebeam der ingen av elementene har dempet amplitude.



Figur 6.3 Antennediagram for flombelysende ULA-16 antenne, åpningsvinkel 30° venstre panel og 60° høyre panel. Blå kurve viser Matlab-simulering, rød kurve antennediagram målt i ekkofritt kammer.

6.4 Utvidelse av intern FFI-simulator

Full digitalstråleforming med analog-digital omforming og høy samplingsrate på alle mottakskanaler for store rektangulære gruppeantennener genererer større datamengder enn det som er håndterbart. I (Strøm, Akhtar, & Johnsen, 2020) har vi utviklet en simulator for bakkebaserte fasestyrte gruppeantennener i operative scenarier. Det er en utvidelse av den eksisterende interne FFI-simulatoren CoRaSim. De fasestyrte gruppeantennene i den utvidete simulatoren har subgruppe-struktur, og resultater for disse er sammenliknet med PESA-radar med bare en mottakskanal. Vi erfarte at subgruppeantennener var nødvendig for å ha en datastrøm som lot seg kjøre med Matlab på vanlige arbeidsstasjoner. Simuleringene indikerer at antenner med subgrupper og beamspace adaptiv stråleforming oppnår betydelig bedre resultater enn PESA-antennener med enkel mottakskanal. Software-utvidelsen av CoRaSim utgjør en vesentlig del av OPRA II prosjektet.



Figur 6.4 Simuleringsscenario i CoRaSim med innkommende mål og jammere

6.4.1 CoRaSim moduler for Array Prosessering og Sparse rekonstruksjon, Del 1. FFI-rapport (Strøm et al., 2020)

Konfigurerbar Radar Simulator (CoRaSim) er en omfattende intern radarsimulator utviklet av FFI for å simulere forskjellige typer radarer i ulike situasjoner og omgivelser. Denne radaren er utvidet til å behandle informasjon om propagasjonsretningen til signalene den mottar. Modeller for signal mottatt med fasestyrte gruppeantennener fra støyjammer og fra mål er implementert i simulatoren. Fasestyrte gruppeantennener med flere mottakskanaler som overbringer retningsinformasjonen til signalprosessoren er nå en del av simulatoren, og array-prosesseringsmetoder har blitt implementert. Et nettverk av fullt overlappende sub-gruppeantennener for uniform rektangulær fasestyrt gruppe- (URA) antenne med mange elementer er innført for å redusere antall frihetsgrader til et håndterbart antall for signalprosessoren. Det er en mottakskanal for

hver subgruppe, og subgruppeantennene lager et sett av tettliggende stråler som former en vifte. Adaptive beamspace (BS) metoder maksimerer signal-til-støy pluss interferens forholdet (SINR) ved å undertrykke forstyrrende signaler som har retningsinformasjon. Simuleringer av ulike scenarioer har blitt utført for tre typer radarer, en for passiv elektronisk styrt gruppe- (PESA) antenne med en enkelt mottakskanal og konvensjonell stråleforming, og to for digital elektronisk styrte gruppe- (DESA) antenner hvor en har 9 subgrupper og den andre har 24 subgrupper. Simuleringer er utført med en samling av tre innkommende mål, og en annen med ni innkommende mål. I begge tilfellene bærer en, to eller tre av målene en støyjammer. Deteksjoner gjort med de tre typene av radarer for de ulike kombinasjonen av mål og jammere er registrert og sammenliknet. PESA-radaren med en enkelt mottakskanal er fullstendig blendet av støyjammen. DESA-radaren med ni mottakskanaler og den adaptive beamspace minimum varians forvrengningsfri respons (MVDR) beamformerer klarer å imøtegå en støyjammer bra, og i noen grad to støyjammere. BS-MVDR beamformerer med 24 frihetsgrader klarer også å håndtere godt tilfellet med to støyjammere.

En monopuls-radar er implementert som en URA-antenne med tre mottakskanaler. Sum-kanalen er en konvensjonell beamformer som summerer alle bidragene fra antenneelementene, og differansekkanalen i asimut og i elevasjon er begge konvensjonelle delta-beamformere. De to scenarioene med grupper på tre og ni innkommende mål er simulert uten noen form for støyjaming. Estimat av ankomstretning (DoA) gjort med monopulse-radaren er sammenliknet med retningsestimert oppnådd med PESA enkel-kanal-radaren. Nøyaktigheten oppnådd for den siste er bestemt av hovedlobebredden. For begge simuleringsscenarioene oppnår monopuls-radaren bedre resultater, spesielt i tilfellet med tre mål. I tilfellet med ni mål vil ofte mer enn ett mål befinne seg i hovedloben samtidig. Det fører til at feilspenningen blir midlet for to eller flere mål og avlesningen på monopulse-responskurven for estimat av retning blir tilsvarende.

6.5 Kontrollert forfall av gruppeantenne


En gruppeantenne vil være operativ selv om noen få av sender-mottaker modul(TRM)-ene går i stykker. De resterende TRM-ene vil være operative. Men hvorvidt antennen som helhet kan betraktes som operativ, vil avhenge av om gruppeantennens egenskaper blir ivaretatt slik som gain og sidelobenivå. Noen simuleringer av lineære gruppeantenner er utført i (Strøm, To appear 2021). Maksimum gain blir ivaretatt, men sidelobenivå og motstand mot interferens krever at signalprosessoren kan utnytte kjennskap om hvilke elementer som faller ut, slik som er tilfellet ved adaptiv stråleforming.

6.5.1 Gruppeantenner med ikke-fungerende elementer, en simuleringstudie. FFI-rapport utkast (Strøm, To appear 2021)

Simuleringer av egenskaper ved sending og mottak til en Uniform Linear Gruppe- (ULA) antenne med ikke-fungerende antenneelementer er utført. Maksimum direktivitet for ULA uten sidelobedemping er bestemt av antall operative elementer i gruppeantennen, uavhengig av plasseringen til de ikke-fungerende elementene, og derfor ikke endret mye ved 10% degradering. Imidlertid vil sidelobenivået til en konvensjonell stråleformer med sterk

sidelobedempning lide betydelig ved degradering. Effekten av degradering på oppnådd SINR for en ULA utsatt for en støyjammer er også studert. Mens den konvensjonelle beamformeren blir blendet, oppfører minimum varians forvrengningsfri respons (MVDR) beamformeren seg bra, og klarer å undertrykke sidelobejamming også når 10% av elementene er ikke-fungerende. Det samme holder for ULA med fullt overlappende subgrupper og beamspace minimum varians beamformeren så lenge jammeren befinner seg innen sektoren til stråleviften for de overlappende subgruppeantennene.

Figur 6.5 viser antennediagrammet for en ULA-30 med uniforme elementvekter der 3 elementer er slukket. Elementavstanden er en halv bølgelengde. De 3 slukte elementene er valgt slik at de fører til størst reduksjon i maksimalt sidelobenivå for antennen.



Figur 6.5 Simulering direktivitet for ULA med 30 elementer og uniforme vekter stiplet linje, og med elementene 3,6,25 slukket blå kurve.

7 Videre arbeid array-prosessering

Simuleringer og prosessering av reelle data under OPRA II prosjektet indikerer at array-prosessering fungerer godt for bakkebaserte radarer i komplekse signalmiljøer. Adaptiv digital stråleforming gir bedre retningsbestemmelse og deteksjonsevne under påvirkning av interferens enn konvensjonell stråleforming, men krever store ressurser til dataoverføring og beregninger. Hybridløsninger med DBF for overvåkningsradarer er tilgjengelig, men full DBF med digitalisering på alle kanaler for store URA-antenner er foreløpig for regnekrevende etter det forfatterne kjenner til.

I luftbårne radar-plattformer vil clutter-refleksjoner ha doppler-forskyvninger som avhenger av retningen til bakkesprederen i forhold til flyets marsjretning. Filtreering av innkommende signaler med filtre som er adaptive i både tid og rom, har gode resultater ifølge litteraturen (Klemm, 2006; Melvin, 2013; Ward, 1994). Rom-tid adaptiv prosessering (STAP) er en utvidelse av adaptiv stråleforming til å inkludere tids-dimensjonen. Men regneressursene som kreves av STAP-metodene, er så store at de må brukes i kombinasjon med andre og mindre ressurskrevende metoder. For eksempel vil en antenne med 10×4 elementer og full DBF ha $M = 40$ mottakskanaler. Tenker vi oss at hver CPI har pulstog med $N = 64$ pulser, vil det være $NM = 2560$ frihetsgrader til å bestemme et optimalt lineært filter for undertrykking av interferens og støy for et mål som befinner seg i en gitt range celle. Full STAP lager optimalt filter ved å løse et lineært ligningssystem med NM ukjente for hver range celle. En direkte løser som for eksempel Cholesky-faktorisering, vil kreve $O(N^3M^3)$ operasjoner for å løse et slikt system hvor her $N^3M^3 \approx 1.6e10$. Dersom radaren opererer med puls repetisjonsfrekvens 2KHz og båndbredde 1MHz, gir det $L = 500$ range celler. Dermed vil det for hver CPI bli laget en datakube med $LMN \approx 1.3e6$ celler, alle komplekse tall som skal transporteres og prosesseres.

En måte å redusere krav til regneressurser er å benytte adaptive metoder bare for range celler hvor andre metoder leverer resultater med uklart informasjonsinnhold, og dermed benytte adaptive metoder nærmest som forstørrelsesglass. Videre benyttes gjerne subgruppe-strukturer og software som kombinerer adaptive og konvensjonelle prosesseringsmetoder. Slike metoder vil være nødvendig for sanntids-demonstratorsystemer. Videre arbeid ved FFI bør søke verifisere gevinsten av STAP anvendt på reelle målinger for å vurdere robusthet og stabilitet for undertrykking av interferens i komplekse signalmiljøer.

Adaptiv stråleforming har likheter med flere maskinlæringsteknikker. Særlig feed-forward nevrale nett som læres veiledet ved back-propagation, har fellestrekk med ABF. Det vil være interessant å sammenlikne effekten og regneressursene ved bruk av de ulike filtrene. Dette er arbeid som vil følges opp i prosjektet Signalprosessering for fremtidens radarsensorer (SIFR).

Acronyms

ABF: Adaptiv Stråleforming.....	31
AESA: Active Electronically Scanned Array	31
BS: Beamspace	40
CFAR: Constant False Alarm Rate	35
CoRaSim: Configurable Radar Simulator.....	39
CPI: Coherent Processing Interval	8
CS: Compressed Sensing	8
DBF: Digital Stråleforming.....	31
DESA: Digital Electronically Scanned Array.....	31
DoA: Direction of Arrival.....	40
DRFM: Digital Radio Frequency Memory	35
DVB-T: Digital Video Broadcasting -Terrestrial.....	33
FMCW: Frequency Modulated Continuous Wave.....	35
GPU: Graphics Processing Unit.....	8
MUSIC: Multiple Signal Classification	37
MVDR: Minimum Variance Distortionless Response.....	34
PESA: Passive Electronically Scanned Array.....	31
PMV: Power of Minimum Variance	37
POPS: Phase Only Pattern Synthesis	38
RCS: Radar Cross Section	10
SINR: Signal to Interference plus Noise Ratio	31
SR: Sparse Reconstruction.....	8
STAP: Space Time Adaptive Processing.....	42
TRM: Transmit Receive Module	31
ULA: Uniform Linear Array.....	33
URA: Uniform Rectangular Array.....	39

Referanser

- Aalfs, D. (2013). Adaptive Digital Stråleforming. In W. J. Melvin & J. A. Scheer (Eds.), *Principle of Modern Radar: Advanced Techniques* (pp. 401-452). Edison, New Jersey: Scitech Publishing.
- Akhtar, J. (2020a). *Compressed sensing og sparse rekonstruksjon i radarsammenheng* (20/02394). Retrieved from FFI:
- Akhtar, J. (2020b). Sparse Range-Doppler Image Construction with Neural Networks. *Proc. of IEEE Radar Conference*.
- Akhtar, J. (2020c). Training of Neural Network Target Detectors Mentored by SO-CFAR. *Proceedings of 28th European Signal Processing Conference*.
- Akhtar, J., & Olsen, K. E. (2016). Formation of range-Doppler maps based on sparse reconstruction. *IEEE Sensors Journal*, 5921--5926.
- Akhtar, J., & Olsen, K. E. (2018). A Neural Network Target Detector with Partial CA-CFAR Supervised Training. *Proc. of Intl. Conference on Radar*.
- Akhtar, J., & Olsen, K. E. (2019). GO-CFAR Trained Neural Network Target Detectors. *Proc. of IEEE Radar Conference*.
- Applebaum, S. P. (1976). Adaptive Arrays. *IEEE Transactions on Antennas and Propagation*, 24(5).
- Capon, J. (1969). High-Resolution Frequency-Wavenumber Spectrum Analysis. *Proceedings of the IEEE*, 57(8).
- Dolph, C. L. (1946). A Current Distribution for Broadside Arrays Which Optimizes the Relationship Between Beam Width and Side-Lobe Level. *Proceedings of the IRE*, 34(6).
- Gusland, D. R., Christiansen, J. M., Strøm, K., Akhtar, J., & Torvik, B. (2020). *Radar for C-UAS applications* (20/00978). Retrieved from FFI:
- Johnson, D. H., & Dudgeon, D. E. (1993). *Array Signal Processing: Concepts and Techniques*. Upper Saddle River, New Jersey: Prentice-Hall Inc.
- Khzmalyan, A. D. (2003). Phase-only control of an array pattern: Beam shaping and monopulse nulling. *Xplore Digital Library, Proc. IEEE International Symposium on Phased Array Systems and Technology*, 577-582.
- Klemm, R. (2006). *Principles of Space-Time Adaptive Processing 3rd Edition*: The Institution of Engineering and Technology, London UK.
- Melvin, W. J. (2013). Clutter Suppression Using Space-Time Adaptive Processing. In W. J. Melvin & J. A. Scheer (Eds.), *Principles of Modern Radar: Vol II Advanced Techniques*. Edison, New Jersey: Scitech Publishing.
- Reed, I. S., Mallett, J. D., & Brennan, L. E. (1974). Rapid Convergence Rate in Adaptive Arrays. *IEEE Trans.AES*.
- Strøm, K. (2020). *Phase Only Pattern Synthesis* (20/00461). Retrieved from FFI:
- Strøm, K. (To appear 2021). *Array antennas with defunct elements, a computational study* (21/XXXXXX). Retrieved from FFI:
- Strøm, K., Akhtar, J., & Johnsen, T. (2020). *CoRaSim modules for Array Processing and Sparse Reconstruction* (20/02579). Retrieved from FFI:
- Strøm, K., Christiansen, J. M., & Gusland, D. R. (To appear 2021). *Adaptive stråleforming for interference suppression in a ubiquitous radar* (21/XXXXXX). Retrieved from FFI:
- Strøm, K., Lie-Svendsen, Ø., Finden, E., Norheim-Næss, I., Johnsen, T., & Baruzzi, A. (2017). DVB-T Passive Radar Dual Polarization Measurements in the Presence of Strong Direct Signal Interference. *Proceedings International Radar Symposium 2017*.

-
-
- Strøm, K., Lie-Svendsen, Ø., Norheim-Næss, I., Johnsen, T., Finden, E., & Olsen, K. E. (2018). DSI Suppression with Adaptive Stråleforming in DVB-T Passive Radar Measurements. *Proceedings International Radar Symposium 2018*.
- Strøm, K., & Norheim-Næss, I. (2019). *Array processing and interference in short range radar measurements* (19/01882). Retrieved from FFI:
- VanTrees, H. (2002). *Detection, Estimation, and Modulation Theory, Optimum Array Processing, (Part IV)*. New York: John Wiley & Sons, Inc.
- Ward, J. (1994). *Space-Time Adaptive Processing for Airborne Radar* (1015). Retrieved from Lexington, Massachusetts:
- Widrow, B., Mantey, P. E., Griffiths, L. J., & Good, B. B. (1967). Adaptive Antenna Systems. *Proceedings of the IEEE, 55* (12).

About FFI

The Norwegian Defence Research Establishment (FFI) was founded 11th of April 1946. It is organised as an administrative agency subordinate to the Ministry of Defence.

FFI's MISSION

FFI is the prime institution responsible for defence related research in Norway. Its principal mission is to carry out research and development to meet the requirements of the Armed Forces. FFI has the role of chief adviser to the political and military leadership. In particular, the institute shall focus on aspects of the development in science and technology that can influence our security policy or defence planning.

FFI's VISION

FFI turns knowledge and ideas into an efficient defence.

FFI's CHARACTERISTICS

Creative, daring, broad-minded and responsible.

Om FFI

Forsvarets forskningsinstitutt ble etablert 11. april 1946. Instituttet er organisert som et forvaltningsorgan med særskilte fullmakter underlagt Forsvarsdepartementet.

FFIs FORMÅL

Forsvarets forskningsinstitutt er Forsvarets sentrale forskningsinstitusjon og har som formål å drive forskning og utvikling for Forsvarets behov. Videre er FFI rådgiver overfor Forsvarets strategiske ledelse. Spesielt skal instituttet følge opp trekk ved vitenskapelig og militærteknisk utvikling som kan påvirke forutsetningene for sikkerhetspolitikken eller forsvarsplanleggingen.


FFIs VISJON

FFI gjør kunnskap og ideer til et effektivt forsvar.

FFIs VERDIER

Skapende, drivende, vidsynt og ansvarlig.

FFI's organisation



Forsvarets forskningsinstitutt
Postboks 25
2027 Kjeller

Besøksadresse:
Instituttveien 20
2007 Kjeller

Telefon: 63 80 70 00
Telefaks: 63 80 71 15
Epost: ffi@ffi.no

Norwegian Defence Research Establishment (FFI)
P.O. Box 25
NO-2027 Kjeller

Office address:
Instituttveien 20
N-2007 Kjeller

Telephone: +47 63 80 70 00
Telefax: +47 63 80 71 15
Email: ffi@ffi.no