

Andris Lauberts

Verktyg och metoder för ID-fusion av sensordata

TOTALFÖRSVARETS FORSKNING SINSTITUT

Ledningssystem

Box 1165

581 11 Linköping

FOI-R--1081--SE

December 2003

ISSN 1650-1942

Metodrapport

Andris Lauberts

Verktyg och metoder för ID-fusion av sensordata

Utgivare Totalförsvarets Forskningsinstitut - FOI Ledningssystem Box 1165 581 11 Linköping	Rapportnummer, ISRN FOI-R--1081--SE	Klassificering Metodrapport
	Forskningsområde 4. Spaning och ledning	
	Månad, år December 2003	Projektnummer E7843
	Verksamhetsgren 5. Uppdragsfinansierad verksamhet	
	Delområde 42 Spaningssensorer	
Författare/redaktör Andris Lauberts	Projektledare	
	Godkänd av	
	Uppdragsgivare/kundbeteckning FMV	
	Tekniskt och/eller vetenskapligt ansvarig	
Rapportens titel Verktyg och metoder för ID-fusion av sensordata		
Sammanfattning (högst 200 ord) Denna rapport beskriver olika aspekter av klassificering och datafusion med hänsyn till principiella metoder. Efter en diskussion om generiska metoder ges en kort beskrivning av vanliga klassificeringsmetoder. Datafusion diskuteras på särdrags- och beslutsnivå. Tillämpning på tre FOI-projekt visas i mer detalj. Scenariorna har utgjorts av dels simulerade landskap med modeller av fordon och sensorer, dels naturlig terräng med verkliga stridsfordon och sensorer. I projektet MUMS (MultiMålsökare) har särdrag extraherats från segmenterade IR-scener och avståndsprofiler från en högupplösande radar. Resultaten visar att ett artificiellt neuronät klassificerar mål oftare rätt med IR och radar i kombination, givet kännedom om osäkerhet i sensordata. I projektet IAM (Interaktiva Marksensornät) fusioneras spårföljarens kinematiska data med ID-information från en klassificerare av akustiska signalspektra vilket ger en betydligt lättare association mål-observation i komplexa situationer. I projektet IR/mm-vågsradar har antalet möjliga målkandidater till en spårföljare starkt reducerats med hjälp av ett IR-kontrastfilter skalat med hjälp av avstånd från radarn.		
Nyckelord datafusion klassificering beslut särdrag sensorer		
Övriga bibliografiska uppgifter	Språk Svenska	
ISSN 1650-1942	Antal sidor: 30 s.	
Distribution enligt missiv	Pris: Enligt prislista	

Issuing organization FOI – Swedish Defence Research Agency Command and Control Systems P.O. Box 1165 SE-581 11 Linköping	Report number, ISRN FOI-R--1081--SE	Report type Methodology report
	Programme Areas 4. C4ISR	
	Month year December 2003	Project no. E7843
	General Research Areas 5. Commissioned Research	
	Subcategories 42 Surveillance Sensors	
Author/s (editor/s) Andris Lauberts	Project manager	
	Approved by	
	Sponsoring agency FMV	
	Scientifically and technically responsible	
Report title (In translation) Tools and methods for ID-fusion of sensor data		
Abstract (not more than 200 words) <p>This report describes various aspects of classification and datafusion with an eye to principal methods. A discussion on generic methods is followed by a short description of commonly used classification methods. Datafusion is discussed in terms of feature and decision fusion. Three FOI projects are studied in more detail. The scenarios are composed of simulated landscapes with inserted models of vehicles, or show real combat vehicles moving in natural terrain. The sensors may be either simulated or real. In the project Multi-Target-Seeker target attributes have been extracted from segmented IR scenes and high-resolution range profiles from a radar. The results show, that using an artificial neural net, targets are classified correctly more often with combined IR and radar data, given their uncertainty. In the project Interactive Ground Sensor Network the tracker fuses kinematic data with ID information on acoustic sensorsdata, making association of target-observation easier in a complex scenario. In the project IR/mm-wave radar the number of possible targets can be strongly reduced by means of an IR contrast filter, scaled by range from a radar.</p>		
Keywords Data fusion, classification, decision, features, sensors		
Further bibliographic information	Language Swedish	
ISSN 1650-1942	Pages 30 p.	
	Price acc. to pricelist	


INNEHÅLL

1	INTRODUKTION	6
2	GENERISKA METODER.....	7
3	KLASSIFICERARE	9
3.1	Kort beskrivning av vanliga klassificerare	9
3.2	Resilient backpropagation.....	11
4	DATAFUSION	12
5	MULTISENSORSYSTEM.....	14
6	MULTISENSORMÅLSÖKARE (MUMS)	16
6.1	Scenario.....	16
6.2	Särdrag.....	17
6.3	Datafusion	19
7	INTERAKTIVA MARKSENSORNÄT (IAM).....	21
7.1	Experiment	21
7.2	Informationsfilter.....	22
7.3	Modellscenario.....	24
8	FOI:S IR/MM-RADAR SYSTEM.....	25
8.1	Sensorer.....	26
8.2	Datafusion och spårföljning	26
9	SAMMANFATTNING	29
10	REFERENSER.....	30

1 Introduktion

Dagens sensorsystem måste snabbt hitta och klassificera mål under högst varierande betingelser. Typiska fall är icke samarbetsvilliga mål, kamouflerade, delvis gömda eller störda, se Figur 1, där en helikopter avlossar en målsökande robot mot en stridsvagn bakom en skogsdunge i kuperad terräng. En ensam sensor ger inte alltid tillräcklig information för att säkerställa upptäckt och identifiering (klassificering) av ett mål. En lösning på detta problem är att kombinera sensorer med komplementära egenskaper. Signaler (rådata) från dessa sensorer fusioneras till en mer fullständig helhetsbild av det verkliga förhållandet. För att lösa uppgiften måste tyngre beräkningsarbete så långt möjligt göras i dedicerad hårdvara. Vägen dit är inte enkel och beror mycket på vad slags algoritmer som sköter jobbet. Denna rapport handlar om några, i viss utsträckning generella, metoder och verktyg som belyser olika aspekter av datafusion för följning och klassificering av mål i ett multisensorsystem.

Med *datafusion* menas en process som kombinerar data och kunskap från olika källor med syfte att maximera nyttoinnehållet i data, som kan vara osäkra, ofullständiga eller motsägelsefulla. Utgående från denna synnerligen generiska innebörd av ordet datafusion skiljer man på olika nivåer av fusion. I den lägsta (sensornära) nivån sker fusion direkt på rådata, t.ex. genom lämplig hoplagring av pixlar från en visuell TV kamera och en IR kamera. Ofta har sensorerna olika egenskaper med råsignaler lagrade i helt olika format, t.ex. IR bilder och radarekon. I dessa fall görs fusionen enklast på en högre nivå. Normalt fusioneras extraherade särdrag (karaktéristiska kännetecken) från målen sedda från varsin sensor. Tyvärr finns sällan generella lösningar på sättet att fusionera sensordata, lika lite som en ensam sensor kan sättas in mot alla möjliga mål. Önskvärt är ändå att sträva mot generiska modeller och dataformat för olika delprocesser. Datafusion på särdragsnivå betingas ofta av sådana argument eftersom gränzytan mellan fusionsmetod och sensordata då i högre grad kan standardiseras. När man väl fått ett multisensorsystem att fungera i stort sett OK, både till prestanda och sett från en operatör, kan systemets olika delar vässas av en expert för att uppnå resterande kanske 10 %. Viktigt är då att dessa delar består av sinsemellan utbytbara moduler. Endast då kan systemet modifieras och växa smärtfritt oberoende av den ursprungliga tillverkaren.



Figur 1. Systemscenario

Datafusion innefattar flera samverkande moment som delvis överlappar varandra. Upptäckt och (del)klassificering görs ofta av enskilda sensorer vid olika tidpunkter. Här är associering (ser sensorerna samma mål?) en viktig hörnsten för en lyckad fusion av sensordata. Associeringen beror både på hur väl målet lokaliseras (spåras) av sensorerna och den åtföljande klassificeringen. Givet dessa betingelser handlar slutstadiet om en förfining av de tidigare stegen. Den gemensamma informationen fusioneras här till en bättre bild av läge och identifiering av målet. Med full kontroll över osäkerheten i data kan man visa att fusion aldrig är sämre än den bästa sensorn. En viktig del i processen är därför rätt uppskattning av tillförlitligheten i sensordata. Det lönar sig sällan att fusionera en bra sensor med en dålig om man inte känner mätosäkerheten. Ett bättre val är i så fall att ta den bästa sensorn. Även för detta krävs någon form av test – ett test som datafusion är tänkt att ge svar på genom att parallellt värdera förloppet av enskilda sensorers prestanda kontra ett sammansatt multisensorsystem.

Uppgiften att beskriva datafusion i några multisensorsystem mer i detalj måste resultera i en kompromiss mellan utförlighet, tillgänglighet och målsättningen med studien. Huvudsyftet är att visa behovet av komplementära sensorer, och i förlängningen, möjligheten att realisera datafusion i ett multisensorsystem med generellt användbara metoder. Den närmare funktionen (och tillförlitligheten) hos externa system är för det mesta väl dolda industrihemligheter. Mot bakgrund av sådana omständigheter betraktar vi främst några av FOI studerade/utvecklade system. Fyra förberedande avsnitt tar upp generiska metoder (avsnitt 2), klassificerare (avsnitt 3), datafusion (avsnitt 4) och multisensorsystem (avsnitt 5), följt av tre tillämpningar. I avsnitt 6 beskrivs klassifikation av markmål med hjälp av ID-fusion av sensordata i en simulerad multisensormålsökare (FOI:s del av projektet MUMS, i samarbete med Saab-Bofors-Dynamics)¹. Avsnitt 7 behandlar kortfattat ett interaktivt marksensornät där association av mål underlättas genom distribuerad fusion av kinematiska data med ID-information om måltyp. Avsnitt 8 beskriver en IR/mm-radar målsökare under utveckling vid FOI. Här ingår datafusion främst i spårföljaren men även som ett grovt filter vid val av markmål.

2 Generiska metoder

Som framgår av avsnitt 1 finns både strävan och viss möjlighet att spjälka upp datafusionsprocessen i standardiserade moduler. Ju närmare sensorerna man kommer desto mer måste algoritmerna som gör jobbet skraddarsys för en specifik uppgift. Uppgiften kan t.ex. vara att detektera mål av viss storlek i en IR-bild, oavsett var denna bild är tagen. Tillämpningen kan alltså variera medan metoden för att ”upptäcka IR-mål” i viss mån är generisk. Inom en större ram vill man finna principiella metoder för att lösa bredare uppgifter på olika hierarkiska nivåer. En robust struktur är här lika viktig som eleganta lösningar på smala problem.

Enligt uppslagsboken står ordet generisk för ”artegen, tillhör viss släkte”. En sökning på internet med [generic algorithm data fusion] gav över 10 000 träffar. Efter en närmare titt på de första 100 listade dokumenten står det klart att ordet "generic" förekommer ganska sparsamt, oftast i rubriken till olika avsnitt i dokumentet. Mer i förbigående framhävs

betydelsen av generella metoder, varefter diskussionen lätt glider in på speciella tekniska lösningar.

Man skall här inte förneka vikten av ett genomtänkt, i praktiken väl fungerande multisensorsystem. För att både behålla god teknik i detaljerna och en helhetssyn används ett objektorienterat arbetssätt med utbytbara moduler. Ett nätverksbaserat försvar (NBF) kan ses som ett enormt uppskalat multisensorsystem där sensorerna utgör alla tänkbara informationskällor från människa och maskin. Ett lyckat genomförandet av NBF kan bara ske om ingående komponenter fås att samverka effektivt i rum och tid.

Hur det generiska inslaget framstår i datafusion och klassificeringsmetoder illustreras kanske bäst genom att peka på generiska funktioner i några studerade exempel. Om inget annat sägs markeras det generiska släktskapet med en stjärna (*).



Figur 2. Simulerat scenario i MOSART med robotbärare på väg mot en akustisk/seismisk sensor.

En första stomme i ett multisensorsystem kan byggas upp av standardiserade block enligt vissa vedertagna principer. Exempel på ett sådant system i miniatyr är FOI:s datafusionsdemonstrator MOSART (Modeling and Simulation for Analysis and Research Test-bed)². Ett exempel på händelsestyrd visualisering i MOSART kan ses i Figur 2.

Blocken består i sin tur av mindre komponenter i en hierarkisk ordning. Vitsen är att varje subdel har ett standardiserat gränssnitt mot andra delar, uppåt, neråt eller på samma nivå. Närmare sensorerna måste algoritmerna skrivas allt mer specifikt. Frågan är då hur nära man kan gå och ändå behålla en viss generisk funktionalitet i algoritmen. Ett exempel på ett beräkningsverktyg med mycket generella funktioner är Matlab:s kärna³. Det är som med LEGO, en mindre mängd klossar kan sättas ihop på ett större antal sätt, ett kanske för stort antal för en icke-specialist. För att göra livet lättare för utövaren, finns också i Matlab:s arsenal Toolboxar* av olika slag, t.ex. Image Processing TB eller Neural Nets TB.

Ekvationen med generisk funktionalitet går bara ihop om en i teorin generell algoritm matas med data på standardiserad form. Kopplingen databas och datafusion är uppenbar, se t.ex. Darpa:s studie "Dynamic Database" av Kessler⁸. Ett huvudmotiv för att göra datafusion på särdragsnivå är just kravet på att utvinna jämförbar information från olika sensordata. Efter normalisering av särdragen kan de kombineras till en storhet, mottaglig av en och samma algoritm, t.ex. en klassificeringsmetod. Den generiska egenskapen hos en viss metod har sina gränser. Normalisering och viktning av särdrag måste göras med omsorg. Ofta bygger en metod på en eller flera justerbara parametrar för att få optimalt resultat. Detta kan tyckas som ett vanskligt företag men i praktiken kommer man ganska långt genom att välja givna schablonvärden.

3 Klassificerare

Datafusion kan ses som klassificering på en högre nivå. Vi passar därför in ett avsnitt om olika klassificerare och deras roll i datafusionsprocessen. En indelning av klassificerare efter matematisk form kan se ut som

Parametrisk klassificerare

- Bayes metod (sannolikhetskvotstest)

Icke-parametrisk klassificerare

- Parzens metod
- k-närmaste granne

Neuronnät

- Resilient Backpropagation
- Support vector machines (SVM)
- Fuzzy logic

Korrelation

- Filterfunktioner

3.1 Kort beskrivning av vanliga klassificerare

*Bayes sannolikhetskvotstest** är den optimala klassificeraren i meningen att den minimerar kostnaden eller felsannolikheten då täthetsfördelningar av sannolikheter och a priori sannolikheter för en uttömmande mängd klasser är givna. Metoden är i sig intuitivt enkel och snabb, men för att kunna konstruera ett sannolikhetskvotstest måste vi känna till de betingade sannolikheterna för varje klass vilket kan vara svårt. Dessutom måste

täthetsfunktionen bestämmas tillräckligt fint för att inte lämna okända ”luckor” i sannolikhetskalkylen. Om datorminnet räcker kan täthetsfördelningen inkludera bidrag från olika sensorer. Vid denna datafusion kommer målet att klassificeras i en multidimensionell rymd av särdrag. Emellertid förstoras problemet med luckorna i sannolikhetsfunktionen vilket till slut blir en återvändsgränd.

En alternativ väg ligger i icke-parametrisk estimering av täthetsfunktionen. Dessa metoder baseras på direkta uppskattningar av tätheten hos observationerna i en multidimensionell rymd. *Parzens metod** går ut på att beräkna en medeltäthet baserad på viktade avstånd till alla grannar, medan *k-närmaste grannar** söker volymen innesluten av k närmaste grannar inom varje klass. Även i detta fall måste dock täthetsfunktionen bygga på ett stort antal punkter för att ett bra estimat ska erhållas. Algoritmerna är visserligen enkla men tyvärr saknas en träningsfas, d.v.s. klassificering görs på indata för varje nytt test. Även här kan täthetsfördelningen inkludera bidrag från olika sensorer (datafusion), men till skillnad från Bayes metod finns inget problem med ”luckor”.

*Artificiella neuronnät** (ANN) har som namnet säger en viss (men avlägsen) likhet med en mänsklig hjärna. Sensorsignaler fortplantas och viktas om i ett nätverk av olika kopplade grenar till ett facit (träning) eller svar (test). Resilient Backpropagation är en speciellt robust träningsmetod med relativt få fria parametrar (vilka naturligtvis degraderar den generiska egenskapen). Ett ANN kan ta tid att träna upp (viss risk för icke optimal träning) men detta uppvägs av en mycket snabb testfas på ett redan tränat nät. Senare i rapporten kommer ANN också att användas direkt som fusionerare mellan attribut från olika sensorer. Avsnitt 3.2 ägnas därför åt en djupare beskrivning av träningsmetoden Resilient Backpropagation.

*Support vector machines** (SVM) är en relativt ny metod för måligenkänning. Tanken bakom SVM är att avbilda träningsdata i en särdragsrymd som har en högre dimension och där estimeras hyperplan som separerar datamängderna med så stor marginal som möjligt. SVM metoder bestämmer hyperplanen från ett antal ”stödjepunkter”. Dessa s.k. supportvektorer är de datapunkter som ligger närmast beslutsgränsen och därför är svårast att klassificera. Linjära SVM är mycket snabba men tar ej hänsyn till krökta beslutsytor. Icke-linjära SVM kan tränas till mycket goda prestanda. Tyvärr är testfasen relativt långsam i dessa fall.

*Fuzzy logic** handlar om att ta beslut med mjuka regler i stil med människans sätt att resonera. Att räkna med ord istället för tal är ett annat sätt att uttrycka samma sak. Ibland kombineras fuzzy logic med neuronnät för att lättare anpassa regelsystemet efter tillämpningen. Detta kan jämföras med hårda regler, t.ex. $A \& B = \text{sann om både } A \text{ och } B \text{ är sanna (och-logik)}$, $A | B = \text{sann om minst en av } A \text{ och } B \text{ är sann (eller-logik)}$. *Eller-regeln** kan i sin tur generaliseras till att fusionera sannolikheterna för att se ett visst mål T , givet oberoende observationer X_1, X_2 från två sensorer, till en kombinerad sannolikhet $P(T|X_1, X_2) = 1 - [1 - P(T|X_1)][1 - P(T|X_2)]$.

*Korrelation** är en slags matchningsmetod, vanligen använd för att jämföra två 1-D vektorer med olika relativa förskjutningar. Korrelation implementeras normalt i en mycket snabb algoritm i ett signalbehandlingsprogram. I likhet med Parzen och k -närmaste granne metoder måste dock korrelation göras på nytt för varje nytt testfall,

vilket förstås tar tid. En annan brist är svårigheten att korrelera linjärt kombinerade data från olika sensorer. En generalisering av 1-D korrelation är modellbaserad matchning i flera dimensioner, t.ex. matchning av en projicerad 3-D modell av ett fordon mot misstänkta mål i ett flygfoto. Skalning med avstånd från t.ex. en radar ger ID-fusion. En speciell variant av korrelation består av *filterfunktioner*. Här bestäms koefficienterna för en bruten rationell funktion som utgör ett filter känsligt för en viss klass objekt. Exempel på tillämpning av ett s.k. autoregressivt (AR) filter ges i avsnitt 7 om interaktiva marksensornät.

Ovanstående klassificeringsrutiner kan i princip tillämpas på en mängd olika fall. Den generiska egenskapen förloras dock i takt med ökad specialisering. De icke-parametriska klassificerarna (Parzen, k-närmaste grannar, korrelation) är i detta avseende mest generella till priset av en ofta långsammare testfas. En styrka hos vissa klassificerare är deras förmåga att på ett enkelt sätt innefatta datafusion, t.ex. neuronät. Ingenting hindrar dock att datafusion baseras på beslut från olika klassificerare, se bl.a. avsnitt 6.3. I sin allra enklaste form leder det till majoritetsbeslut givet att trovärdigheten på något sätt kan värderas för bidragande sensorer.

3.2 Resilient backpropagation

Den vanligaste träningsmetoden för artificiella neuronät är Backpropagation (BP), se t.ex. Haykin⁴ [kap. 4.3]. BP algoritmen försöker att minimera felfunktionen genom att uppdatera vikterna w_{ij} i neuronätet genom en gradientsökning hos en felfunktion E .

$$w_{ij}(t+1) = w_{ij}(t) - \varepsilon \frac{\partial E(t)}{\partial w_{ij}}$$

Parametern ε bestämmer hur mycket man ska vikta den nya vikten med gradientvärdet. Detta påverkar hur stort steg man kommer att ta i gradientriktningen, vilket påverkar konvergenstiden. Om ε är för litet krävs det många steg att nå en acceptabel lösning och om värdet är för stort så kommer algoritmen att oscillera så att den inte konvergerar.

För att minska det här problemet provas en träningsmetod kallad Resilient Backpropagation (RPROP). En stor skillnad mellan BP och RPROP är att RPROP endast använder tecknet på de partiella derivatorna i kombination med en adaptiv steglängd per dimension för att uppdatera vikterna i RPROP, ej dess magnitud. En stor fördel med RPROP algoritmen är att den även fungerar bra då felfunktionen är ”plan”.

RPROP uppdaterar sina vikter på följande sätt (Riedmiller och Braun⁵): Då den partiella derivatan för motsvarande vikt ändrar tecken (motsvaras av att den sista uppdateringen var för stor och algoritmen har hoppat över ett lokalt minimum) minskas uppdateringsparameter Δ_{ij} med en faktor η^- . Om derivatan däremot behåller sitt tecken, så ökas uppdateringsvärdet Δ_{ij} med en faktor η^+ enligt

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ * \Delta_{ij}^{(t-1)} & , \text{if } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ \eta^- * \Delta_{ij}^{(t-1)} & , \text{if } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ \Delta_{ij}^{(t-1)} & , \text{else} \end{cases}$$

där $0 < \eta^- < 1 < \eta^+$. Bra empiriska värden på η^+ och η^- är 1.2 respektive 0.5.

Vikterna i RPROP-nätet uppdateras enligt följande. Om derivatan är positiv (felet ökar) så minskas viktens värde med dess uppdateringsvärde, och om derivatan är negativ adderas uppdateringsvärdet.

$$\Delta w_{ij}^{(t)} = \begin{cases} -\Delta_{ij}^{(t)} & , \text{if } \frac{\partial E^{(t)}}{\partial w_{ij}} > 0 \\ +\Delta_{ij}^{(t)} & , \text{if } \frac{\partial E^{(t)}}{\partial w_{ij}} < 0 \\ 0 & , \text{else} \end{cases}$$

$$w_{ij}^{(t)} = w_{ij}^{(t-1)} + \Delta w_{ij}^{(t)}$$

Om de partiella derivatorna däremot ändrar tecken, dvs. om det föregående steget var för stort och algoritmen missade minimalt, så ändras tecknet på viktuppdateringen enligt

$$\Delta w_{ij}^{(t)} = -\Delta w_{ij}^{(t-1)} , \text{if } \frac{\partial E^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial E^{(t)}}{\partial w_{ij}} < 0$$

RPROP-nät är normalt uppbyggt av två lager, varav ett är gömt. Modulationer av insignalen sker med s.k. sigmoider. I första lagret används tansig, $y = 2/(1 + \exp(-2x)) - 1$, modulation av x till y , säg. I andra lagret används logsig, $y = 1/(1 + \exp(-x))$, modulation.

Fler lager skulle kunna särskilja klasserna bättre men till priset av svårare träning. Därtill ökar risken för överträning med ett större antal justerbara parametrar. Efter träning på träningsdata matas neuronnet med testdata. Vid träningsfasen är det bra med lite extra brus för att få en bättre generalisering av klassificeraren så att inte gränserna blir för specialiserade till träningsdata.

Det bör här påpekas att ingenting så långt nämns om tillämpningen. ANN metoden är på det här stadiet fullständigt generell och färdig att acceptera data från en eller flera sensorer (fusion). Först vid träningsfasen måste viss försiktighet iaktas med hänsyn till antalet oberoende indata.

4 Datafusion

Beroende på förkunskap, arten av sensorer och kommunikationsvägar kan man tänka sig två huvudsakliga fusionsmetoder: *attributfusion** (steget över pixelfusion) och *beslutsfusion** (kombination av beslut från enskilda sensorer). Figur 3 visar schematiskt de båda fusionsmetoderna tillämpat på 6 klasser. Vi antar att klassificering från IR- och radardata var för sig ger högsta vikt åt respektive klasser 2 och 3. Vid attributfusion kombineras särdragen från IR och radarn till en storhet som efter klassificering ger maximalt utslag för klass 2. Även beslutsfusion råkar förorda klass 2, vilket här beror på att IR-sensorn har ett snävare experimentellt utfall omkring klass 2 än radarns utfall omkring klass 3. Till skillnad från beslutsfusion medger attributfusion klassificering utan föregående kunskap om sensorernas klassningsförmåga (träningresultatet säger inget om den *sanna* förmågan). Å andra sidan kan beslutsfusion baseras på sinsemellan olika klassificeringsmetoder, t.ex. neuronnet för IR och korrelation för radar, medan attributfusion normalt görs med en och samma klassificerare. Därtill måste de enskilda attributvektorerna normaliseras innan hopläggningen för att viktas rätt av klassificeraren. I detta sammanhang måste påpekas att vid beslutsfusion inte alltid de enskilda sensorernas klassning av mål ledsagas av ett osäkerhetsmått. Denna brist gäller även i

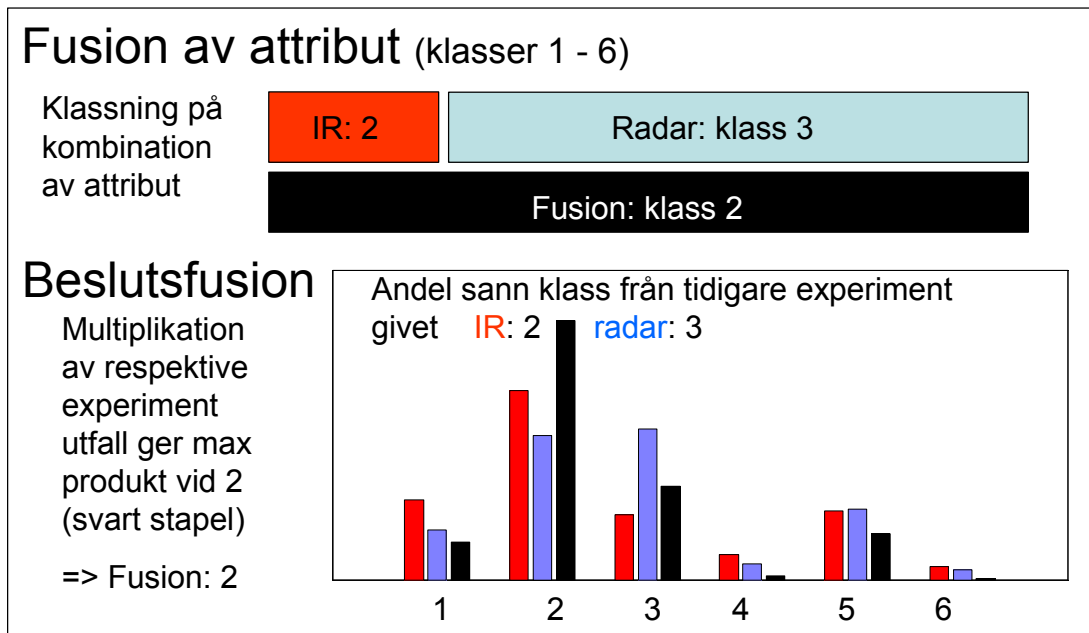
vårt fall, varför beslutsfusion här görs med statistiskt beräknade vikter från empiriska data (a priori sannolikhet).

Låt oss i det följande betrakta en modell av beslutsfusion (se Figur 3) i mer detalj. Antag att målen klassificeras med information från IR och radar var för sig. Resultaten sparades i multidimensionella matriser med avseende på aspektvinkel, målval (antagen klass i), avstånd och sensortyp (A, B, \dots). Avvägningen mellan betingad sannolikhet och a priori sannolikhet kan åskådliggöras med Bayes sats

$$q_i^A = \frac{p_i^A P_i^A}{\sum_k p_k^A P_k^A},$$

där q_i^A är posteriori sannolikhet för givet data enligt sensor A , p_i^A betingad sannolikhet givet måltyp ω_i och P_i^A a priori sannolikhet. Uttrycket i nämnaren normerar sannolikheterna för alla klasser till summa 1. En analog formel kan ställas upp vid fusion av data från två sensorer A och B genom att modifiera Bayes sats till att även innefatta information från sensor B . I denna formel ersätts p_i^A med p_{ij}^A (betingad sannolikhet att upptäcka måltyp ω_j om sensorn valt måltyp ω_i) och P_i^A ersätts med $P_{ij}^A q_{kj}^B$ (kombination av betingade sannolikheter, med analog definition av indexpar ij och kj). Den fusionerade posteriori sannolikheten q_j för att upptäcka måltyp ω_j blir då proportionell mot

$$q_j = \frac{P_{ij}^A P_{ij}^B p_{kj}^A p_{kj}^B}{q}, \text{ där } q \text{ normerar } q_j \text{ till summa 1.}$$



Figur 3. Två fusionsmetoder applicerade på två sensorer. Fusion av attribut går ut på att klassificera en sammansatt vektor av attribut från de enskilda sensorerna. I beslutsfusion vägs de enskilda besluten samman genom att multiplicera respektive fördelningar över sanna målklasser givet estimerade mål, baserat på tidigare experiment.

Om klassificering av mål från enskilda sensordata endast ger det troligaste målet, utan explicita värden på p_{ij}^A och p_{kj}^B (vårt fall), återstår bara uttrycket $P_{ij}^A P_{kj}^B$ med faktorerna tagna från respektive förväxlingsmatriser för sensorerna A och B . Den mest troliga måltypen ω_j kan då fås genom att söka maximum för produkten av a priori sannolikheter m.a.p. index j .

Omvänt kan man naturligtvis tänka sig den andra extremsituationen då klassificeringen ger betingade sannolikheter men a priori sannolikheter är okända, dvs. vi har att söka maximum av produkten $p_{ij}^A p_{kj}^B$ m.a.p. index j .

Beslutsfusion kommer främst ifråga i distribuerade multisensorsystem där sensorerna (ej nödvändigtvis utspridda) fattar beslut på en lokal nivå. En utförlig (men ganska teoretisk) studie över detta kunskapsområde ges i en bok av Varshney⁶. Bokens 276 sidor behandlar olika former av datafusion, t.ex. parallell eller seriell fusion, som en funktion av olika beslutsregler givet sannolikheterna för upptäckt och falsklarm hos de ingående sensorerna.

5 Multisensorsystem

På marknaden finns ett relativt stort antal system som innefattar två eller fler sensorer. Dessutom omnämns i litteraturen ett flertal tänkta system avsedda att realiseras någon gång i framtiden. En provkarta på multisensorsystem sett ur USA:s perspektiv ges i "Handbook of Multisensor Data Fusion"⁷. Ett vanligt problem med färdiga system är svårigheten att genomskåda hur de är implementerade funktionellt, för att inte tala om verkligt stora system på kanske brigadnivå⁸. De tänkta systemen, å andra sidan, beskrivs betydligt mer i detalj på papperet, men där återstår att se den färdiga produkten. I en FOI rapport⁹, som egentligen handlar om störning, beskrivs kortfattat ett antal multisensorsystem i olika stadier av utveckling. I dess bilaga ges en mer utförlig lista över system uppdelat på 1) multisensorsystem med laser, 2) multisensorer med passiva optiska system, och 3) multisensorsystem med radar. Som regel beskrivs här tänkta system i generiska termer av *modeller* och *arkitektur* medan algoritmerna hålls på ett mer symboliskt plan.

Av naturliga skäl är datafusion i multisensorsystem utvecklade/studerade av FOI mer lättillgängliga. Dessa system listas i Tabell 1 med en kort beskrivning av syfte, ingående sensorer, fusionsätt och tillämpning. Några externa system, studerade av Saab och FMV, inkluderas p.g.a. beröringspunkter med FOI:s verksamhet. I sammanhanget bör noteras att ett aktuellt område idag, det nätverksbaserade försvaret (NBF), nyligen behandlats i Militärteknisk tidskrift¹⁰ och i IEEE Proceedings¹¹ med temat "Sensor Networks and Applications".

System	sensorer	fusion	tillämpning
MOSART Generell simuleringsplattform ⁷	Standardiserade gränssnitt enligt HLA princip	Distribuerad fusion från system av system	Testbädd för modellering/simulering
EWSim: multi-spektralt ramverk för telekrig-simulering	Moduler av optronik, radar och vågutbredning	Distribuerad fusion, HLA kompatibel	Duell-simulering telekrig
IR/mm - målsökare - systemlösning FOI-RH--99-00443-314 m.m. rapporter	Stirrande IR-kamera, stirrande koherent mm-vågsradar med 8×4 lober	Seriell, ensning av 2-D IR-bild med 3-D radarvolym	Markmål: detektion, klassificering identifiering
IR/mm/laserradar förstudie, FOA-R--00-01552-314--SE	Stirrande IR, stirrande mm-radar, laserradar	Datafusion från tre olika par av sensorer	Markmål
Multisensormål-sökare (MUMS) FOI-R--0652--SE	IR, koherent Ku-radar	Attributfusion Beslutsfusion	Markmål: klassificering
Multisensormål-sökare (Saab)	IR, SAR	Multihypotes	Sjömål
Störning av multisensorsystem FOI-R--0879--SE	Olika kombinationer av sensorer och motmedel	Beroende på ingående sensorer	Markmål, sjömål, luftmål
QWIP/MASP, studie av experiment UAV, FOI-R--0505--SE	IR-kamera, TV, GPS + IMU (nav-system)	Bilder fusioneras med hjälp av IMU	Markmål Spaning/ övervakning
Samverkande robotar (slutrapport) FOI-R--0734--SE	Olika kombinationer av sensorer på olika plattformar	Sammanlagring av information + styrlagar	Markmål Sjömål
Kommersiella marksensorsystem, FMV studie Proj Led 33 100:18028/01	Kombinationer av olika marksensorer	Kommunikations-sätt och sammanvägning av info ber. på situation	Markmål Luftmål (t.ex. helikopter, artilleri)
Interaktiva adaptiva marksensornät (IAM) ¹⁰	Förbrukningsbara marksensorer i självtablerande nät	Agentbaserad utbyte av lokal information	Markmål
Datafusion för zornör i torped (med Saab) FOI-RH--0019--SE	Sonar, magnetik, laser, nav-system	Beslutsfusion med fuzzy logik	Mål på och under vatten

Tabell 1. Multisensorsystem under utveckling vid FOI och i samarbete med industrin.


6 Multisensormålsökare (MUMS)

I samarbete med Saab Bofors Dynamics (SBD) drivs sedan ett antal år en studie med avsikt att utvärdera två varianter av en multisensormålsökare under projektnamn MUMS (MULTiMålSökare). SBD:s delstudie syftar till att ta fram en demonstrator med en robotburen IR-sensor och SAR (Ku-band) mot sjösmål. Detta system testas f.n. i ett specialutrustat flygplan. För FOI:s del handlar det om att klassificera markmål från ett robotburet system av IR-kamera och Ku-radar med mycket hög avståndsupplösning (HRR). Följande avsnitt behandlar datafusion i MUMS projektet avseende FOI:s inriktning på markmål.

I projektet MUMS har tidigare studier¹² visat på nyttan av datafusion mellan IR- och radar vid klassificering av frilagda markmål. Då använda IR- och radardata var dock mycket förenklade varför fortsatt arbete har gått ut på att generera mer realistiska IR- och radarscener^{13,14}. Sex olika markstridsfordon med eldrör i normalläge klassades härvid betydligt oftare med datafusion jämfört med enskild klassning från IR respektive radar. Klassningsprestanda kunde dock variera ganska tvärt för små ändringar i målaspektvinkel, speciellt på kortare avstånd. För närvarande har studierna koncentrerats på olika speciella fall, bl.a. artikulerade fall med eldrör vridet upptill 90° från framriktning. På grund av svårigheterna med att samla in tillräckligt antal reella IR- och radardata har det mesta arbetet baserats på simulerade data. Fältmätningar görs för att kunna verifiera/kalibrera teoretiska klotterberäkningar.

6.1 Scenario

IR- och radarscenerna består av stridsfordon med markbakgrund. Fordonsmodellerna är CAD-modeller med IR-textur för IR-simuleringarna och mycket högupplösta CAD-modeller för radarsimuleringarna. IR-scenarierna är simulerade med ett av FOI eget utvecklat program för grafiska realtidssimuleringar, SceneServer¹⁵, som styr projektioner av 3-D geometrin direkt i grafikortet. Utvecklingspotentialen för sådan hårdvara är enorm (och billig tack vare spelmarknaden). Terrängmodellen som använts för IR är baserad på ett militärt övningsområde uppmätt med både IR och laser, se Figur 4. IR-scenarierna är simulerade för en IR-sensor med våglängdsband 8-9 μm . Eftersom huvudsyftet med studien har varit att visa mervärdet av datafusion har ingen speciell smyganpassning gjorts av IR-modellernas värmeutstrålning kontra bakgrunden. Radarscenerna simulerades genom att först beräkna radarsignaturen från högupplösta CAD-fordonsmodeller för att få fram avståndsprofilerna på dessa fordon. Radarsignaturen beräknades med programmet FOPOL för frekvensen 16 GHz (Ku-bandet). Dessa avståndsprofiler har sedan degraderats med simulerat klotter från en markbakgrund av gräs. Avståndsprofilerna är beräknade för en upplösning av 1 dm (motsvarande bandbredd 1.5 GHz i 121 frekvenser) i upptill 4 polarisationer med olika versioner av pålagt klotter¹⁶. IR- och radardata har insamlats för att simulera en målsökare som flyger på konstant höjd, 300 m, mot sex olika stridsfordon. Ett exempel på detta scenario kan ses i en tidigare bild, Figur 1. Figur 5 visar högupplösta CAD-modeller av de sex målen.



Figur 4. IR-bild av terrängmodell med inlagd stridsvagn T72.



Figur 5. CAD-modeller av sex stridsfordon: BMP1, BTR80, m109a6-Paladin, Sa4lnch, T72 och T80.

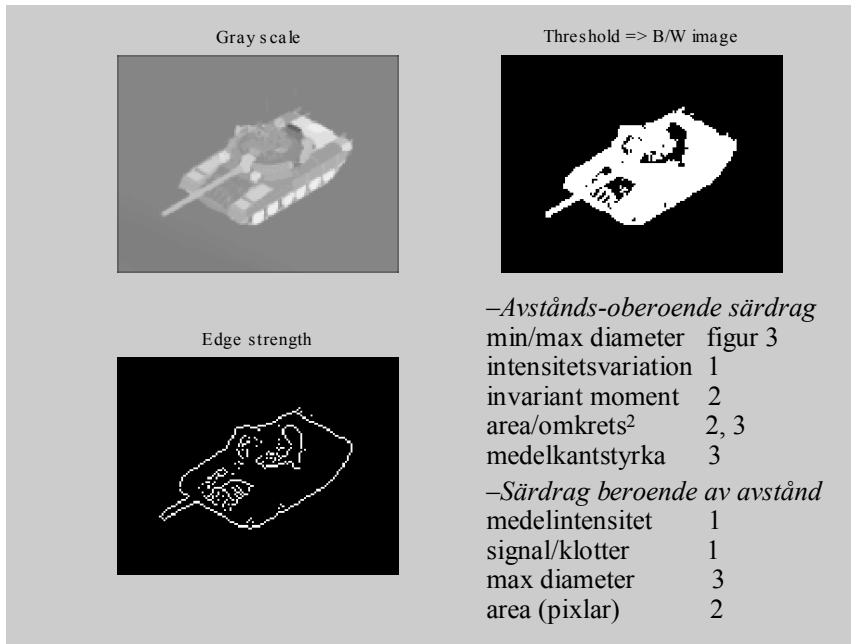
6.2 Särdrag

För en optimal måligenkänning bör all information från de olika sensorerna användas. Här jämför man oftast informationen mot ett bibliotek med kända objekt för att identifiera det objekt som bäst överensstämmer med målet. Använder man då all information skulle biblioteket bli enormt stort och svårsökt. Det gäller därför att reducera datamängden med minsta möjliga förlust av relevant information.

Ett vanligt sätt att minska datamängden är att plocka fram särdrag. Det är då viktigt att måligenkänningsalgoritmen använder så få särdrag som möjligt utan att samtidigt förlora viktig information. Varje använt särdrag måste ge betydande tillskott av information. Ett onödigt extra särdrag kan t.o.m. leda till sämre klassificering. De olika särdragen ska dessutom vara tillförlitliga och okänsliga för störning. Det är därför viktigt att även måligenkänningsalgoritmen är robust mot felaktiga särdrag.

Klassiska mönsterigenkänningsmetoder bygger på att särdrag från objekt från olika klasser ligger i olika regioner i en multidimensionell särdragsrymd och att dessa är separerade, medan särdrag från samma klass ligger i samma region. Andra önskvärda egenskaper hos ett särdrag är geometrisk invarians (rotation, skala och translation), beräkningseffektivitet och robusthet. Ett särdrag bör motsvara en specifik utmärkande egenskap. De vanligaste särdragen som används bygger på geometriska, topologiska

och/eller spektrala egenskaper hos objektet. Den viktigaste egenskapen hos valda särdrag är att de maximerar likheten mellan objekt i samma klass och maximerar skillnaden mellan objekt i olika klasser. Det är då nödvändigt att dessa särdrag är okorrelerade. Statistiskt beroende eller även betingad olikhet mellan särdrag kan resultera i att felaktig hänsyn tas till det bästa särdraget. Figur 6 visar gången i segmentering av en IR-bild samt några utvunna särdrag. Urvalet av dessa särdrag betingas av osäkerheten i avståndsuppskattning. Ett exempel på avståndsberoende särdrag är förhållandet $\text{area}/\text{omkrets}^2$. Om avståndet är känt kan även absoluta mått användas, t.ex. den maximala diametern given av diametern i vinkelmått och avstånd (från radarn).



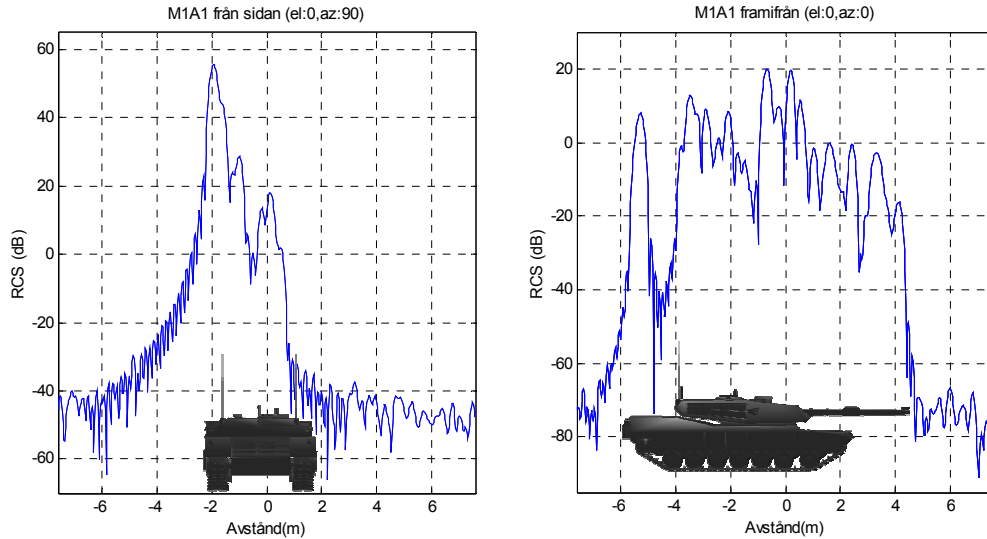
Figur 6. Extraherade särdrag ur segmenterad IR-bild av stridsvagn.

Radarekon har simulerats genom att beräkna strålgången i en Ku-radar med mycket hög avståndsupplösning. Figur 7 visar avståndsprofiler utan klotter i 121 steg för en stridsvagn sedd av radarn från sidan (vänster bild) och frontalt (höger bild). I detta fall utgörs särdragen av hela profilen. Högupplösta avståndsprofiler har flera fördelar vid måligenkänning. De ger bland annat en stor mängd målspecifik information även på långa avstånd. Nackdelen är dock att avståndsprofilerna är starkt beroende av målets orientering. Observera de lokalt hastiga variationerna i avståndsprofilen betingat av interferenser mellan närliggande radarekon.


Efter klotterdegradering blir situationen besvärligare. Figur 8, vänster bild, visar en avståndsprofil med och utan klotter. I det realistiska fallet, med klotter, uppstår betydande skillnader mellan avståndsprofilerna även för en liten ändring i elevationsvinkel till målet (höger bild).

Uppenbarligen dras IR och radar med artagna problem, både med avseende på målets aspektvinkel och avstånd till målet. En lämplig kombination av IR- och radardata bör

därför ha en chans att identifiera målet bättre (upptäckt anses redan gjord). Datafusion utnyttjar för detta ändamål en eller flera klassificerare som verkar på sammanslagna IR- och radarsärdrag (attributfusion) eller kombinerar beslut från enskilda sensorer (beslutsfusion).



Figur 7. Simulerade avståndsp profiler för en M1A1 stridsvagn där sidan respektive fronten är riktad mot radarn.




Figur 8. Vänster bild: Avståndsp profil för mål med (blå) respektive utan (röd) klotter. Höger bild: Avståndsp profil för mål sedda under elevation 16° (blå) och skillnad i profiler för mål sedda under elevationer 16° och 16,05° (röd, undre kurvan).

6.3 Datafusion

Figur 9 visar ett resultat av datafusion för ett genomsnitt av 6 mål sedda under olika aspektvinklar, dock alla med eldrör i normalt framläge. Den genomsnittliga andelen korrekt klassade mål ges här som funktion av avstånd från 489 m till 5480 m. Jämförelse mellan klassningar är baserade på enbart IR, enbart radar, fusionerat beslut mellan IR (med avståndsinformation från radarn) och radar. Klassningarna har i samtliga fall gjorts med hjälp av ett artificiellt neuronnät. IR målen har degraderats med upp till 25 % salt-och-peppar brus (bildelement med omväxlande maximalt eller minimalt utslag).

Mervärdet av datafusion hänger på valet av fusionsmetod och osäkerhetsuppskattning av ingående sensordata. Som framgår av den *vänstra bilden* i Figur 9 ser man ett klart mervärde av attributfusion över bästa enskilda sensor för avstånd över 1600 m (logskala 3.2). På kortare avstånd är attributfusionen endast bättre än radarn, ett väntat resultat då radarn här, p.g.a. snabba fluktuationer i avståndsprofilen, skulle krävt långt tätare träningsdata än IR och därför behövt viktas ner i förhållande till IR. Å andra sidan är beslutsfusion överallt minst lika bra som den bästa sensorn. Trots sämre prestanda har attributfusion en viktig fördel emedan den endast använder färsk information till skillnad från beslutsfusion som behöver a priori information (beslut viktade med utfall från tidigare experiment sparat i s.k. förväxlingsdiagram). I en aktuell MUMS studie¹⁷ tränas ett neuronät på principalkomponenter (SVD) från grupper av mycket tätt stegade radarprofiler utmed en skara målaspekter i azimuth. Dessa grupper ligger allt tätare (med färre medlemmar) närmare målet med följd att testdata bättre matchar en representativ SVD-profil på känt avstånd. Detta framgår klart i Figur 9, *höger bild*, där radarprestanda nu står i paritet med IR på kortare avstånd, och följaktligen attributfusion är minst lika bra som bästa sensorn över hela linjen.


Hur prioritera bästa sensorn är en given fråga i detta sammanhang. Ett svar kan fås genom att studera målet under en kortare tid. Om härvid en sensor ger data som tyder på onormalt uppträdande, t.ex. starkt fluktuerande bäringar eller rentav måltyp, finns orsak att negligera just den sensorn. Även datafusionen i sig tenderar då att försämrat resultatet, fast i lägre grad. Man skulle också kunna tänka sig att studera resultat från datafusion och enskilda sensorer parallellt och därvid slopa sensorn med den största avvikelser.



Figur 9. Resultatet av datafusion för ej artikulerade mål (eldrör i normal framriktning). **Vänster bild:** attributfusion (streckad svart linje), beslutsfusion (heldragen svart linje), glest stegade radarmätningar för träning. **Höger bild:** attributfusion (prickad), tätt stegade radarmätningar för träning. Individuella beslut från IR och radar markeras med respektive röda och blå linjer. Den genomsnittliga andelen korrekt klassade mål visas som funktion av avståndet från 489 m till 5460 m i logaritmisk skala. Klassning är gjord med ett artificiellt neuronät där IR störts med 0 – 25 % salt och peppar brus och radarprofiler beräknats i VV polarisation. Observera att för en anflygande robot bilderna skall läsas från höger till vänster.

Taget över alla målaspektvinklar och avstånd visas klassningsresultaten enklast i s.k. förväxlingsdiagram (andelen olika föreslagna måltypen givet sann måltyp), se Figur 10. En perfekt klassificering skulle här resultera i en matris med 100 % fyllda rutor på diagonalen och bara nollor utanför. De två första diagrammen visar resultatet för resp. IR och radar, de sista två diagrammen visar resultatet för resp. attribut- och beslutsfusion. I

stort förbättras enskilda klassificeringar på IR- och radardata med attributfusion. Det försämrade resultatet för måltyp 1 och 2 beror på alltför glest samplade träningsdata för radarn. Det bästa resultatet fås med beslutsfusion. Som tidigare sagts, bör den sanna bilden ligga någonstans mellan attribut- och beslutsfusion.



Figur 10. Förväxlingsdiagram för resp. IR (röd), radar (blå), attributfusion (svart) och beslutsfusion (svart). Ej artikulerade mål. Genomsnitt över alla aspektvinklar och avstånd. Kolumner: korrekt måltyp. Rader: föreslagen måltyp enligt klassificeringsalgoritm. En perfekt klassificering skulle visa matriser med 100 % fyllda rutor på diagonalen och bara nollor utanför.

7 Interaktiva marksensornät (IAM)

En heltäckande spaning mot främmande förband kräver ofta data från flera typer av källor. Givet lämplig förhandsinformation, kanske via flygspaning om en befarad luftlandsättning, kan man i förväg preparera ett landområde med ett stort antal akustiska marksensorer. Dessa sensorer är relativt billiga och kan t.o.m. släppas ner från luften. Väl nere bildas ett självorganiserande trådlöst nätverk av noder med informationsbärande ”agenter”.

7.1 Experiment


Sedan 2002 studeras vid FOI ett marksensornät med noder förbundna av kablar kopplade till en kontrollcentral. Fältnässiga avlyssningar mot stridsfordon gående på en skogsväg har gjorts med upptill 10 noder bestående av mikrofoner och geofoner utplacerade i ett övningsområde vid Kvarn utanför Linköping, se Figur 11. Råsignalerna har analyserats m.a.p. bäring och måltyp. Bäringar har räknats ut genom att korrelera fasskillnaden för inkommande ljudvågor mot tre sensorer konfigurerade i en triangel. Måltyper har estimerats genom att filtrera ljudsignalerna med ett AR-filer (se avsnitt 3.1 under korrelation) med koefficienterna beräknade på kända måldata. Givet nodernas positioner har spåren till rörliga mål estimerats m.h.a. ett modifierat Kalmanfilter. Detta *informationsfilter** (se avsnitt 7.2) arbetar med data från var och en av sensornoderna i form av bäringar med mycket stor osäkerhet i målavstånd. Denna lokala information, som ej behöver vara samtidig från olika sensorer, portioneras via agenter ut till omgivande noder. Undan för undan blir allt fler och fler sensornoder delaktiga av samma information med optimalt endast små skillnader i spårestimat. Inledningsvis har experimenten bara gjorts med ett fordon i taget. Infällt i Figur 11 visas det estimerade spåret (rött) av ett lastfordon observerat från 7 stationer med mikrofoner och geofoner. Notera att noderna placerats relativt långt från vägen för att kunna följa målet en längre sträcka, inte nödvändigtvis på vägen. Ett tänkbart alternativ är att observera passagen från olika

fordon vid bestämda kontrollpunkter med huvudsyfte att klassificera måltyper. Detta förutsätter att fordonen inte kan ta en annan väg.

7.2 Informationsfilter

Ett decentraliserat datafusionssystem består av ett nätverk av sensornoder (ex.: IAM) med var sin processorkapacitet. I ett sådant system sker datafusion lokalt vid varje nod baserat på egna observationer samt översänd information från närläggna noder. Ingen sensornod har global kunskap om vare sig nätverkets topologi eller kommunikationsvägar. Allt som räknas ryms i en relativt liten omgivning. Ett system byggt på så kan fritt skalas till andra storlekar, är ej sårbart för mindre förluster av enstaka noder (redundans), samt är lätt att uppdatera modulärt. I det följande ges grundekvationerna för ett Kalman filter i decentraliserad form^{20,18}. Låt

- $\mathbf{x}(k)$ tillståndsvektor med tidsindex k
- $\mathbf{Z}^k = \{\mathbf{z}(1), \dots, \mathbf{z}(k)\}$ en sekvens observationer
- $\hat{\mathbf{x}}(i|j) = E\{\mathbf{x}(i)|\mathbf{Z}^j\}$ estimatet av tillståndsvektorn givet observationer
- $\mathbf{P}(i|j) = E\{\tilde{\mathbf{x}}(i|j)\tilde{\mathbf{x}}^T(i|j)|\mathbf{Z}^j\}$ estimatets kovarians



Figur 11. Övningsområde med markerade positioner för akustiska sensornoder omkring en väg. Skala: en ruta = 25 m. Infällt: estimerat spår (—, start från vänster) efter en lastvagn på en väg (--) observerad från 7 noder (o).

Informationsformen av Kalmanfiltret fås genom att skriva om tillståndsvektorns estimat och kovarians i två nya variabler

$$\hat{\mathbf{y}}(i|j) \equiv \mathbf{P}^{-1}(i|j)\hat{\mathbf{x}}(i|j),$$

$$\mathbf{Y}(i|j) \equiv \mathbf{P}^{-1}(i|j).$$

Observationerna antas följa modellen

$$\mathbf{z}_i(k) = \mathbf{H}_i(k)\mathbf{x}(k) + \mathbf{v}_i(k), \quad i = 1, \dots, N \text{ sensorer,}$$

$$E\{\mathbf{v}(i)\mathbf{v}^T(j)\} = \delta_{ij}\mathbf{R}(i),$$

med matriserna

$$\mathbf{H}_i(k) = (\text{transform tillståndsvektor - observation}),$$

$$\mathbf{v}_i(k) = (\text{brus}),$$

$$\mathbf{R}(k) = (\text{kovarians}).$$

Informationen associerad med en observation kan då skrivas på formen

$$\mathbf{i}_i(k) \equiv \mathbf{H}_i^T(k)\mathbf{R}_i^{-1}(k)\mathbf{z}_i(k),$$

$$\mathbf{I}_i(k) \equiv \mathbf{H}_i^T(k)\mathbf{R}_i^{-1}(k)\mathbf{H}_i(k).$$

Med dessa definitioner uppdateras estimat och kovarians enligt

$$\hat{\mathbf{y}}(k|k) = \hat{\mathbf{y}}(k|k-1) + \sum_{i=1}^N \mathbf{i}_i(k),$$

$$\mathbf{Y}(k|k) = \mathbf{Y}(k|k-1) + \sum_{i=1}^N \mathbf{I}_i(k).$$

Uppenbarligen sker uppdateringen i termer med dimensionen av tillståndsvektorer, till skillnad från ett standard Kalman filter som uppdateras i termer med dimensionen av observationer. Vinsten med informationsfilter framstår vid multisensorproblem där uppdateringen sker genom en summa av okorrelerade termer \mathbf{i}_i respektive \mathbf{I}_i , vilket inte är möjligt med ett Kalmanfilter i standardform.

Prediktionen av information görs enligt (sensorindex i undertryckt för enkelhets skull)

$$\hat{\mathbf{y}}(k|k-1) = \mathbf{L}(k|k-1)\hat{\mathbf{y}}(k-1|k-1),$$

$$\mathbf{Y}(k|k-1) = [\mathbf{F}(k)\mathbf{Y}^{-1}(k-1|k-1)\mathbf{F}^T(k) + \mathbf{G}(k)\mathbf{Q}(k)\mathbf{G}^T(k)],$$

med matriserna

$$\mathbf{L}(k|k-1) = \mathbf{Y}(k|k-1)\mathbf{F}(k)\mathbf{Y}^{-1}(k-1|k-1),$$

$$\mathbf{F}(k) = (\text{övergång för tillståndsvektor}),$$

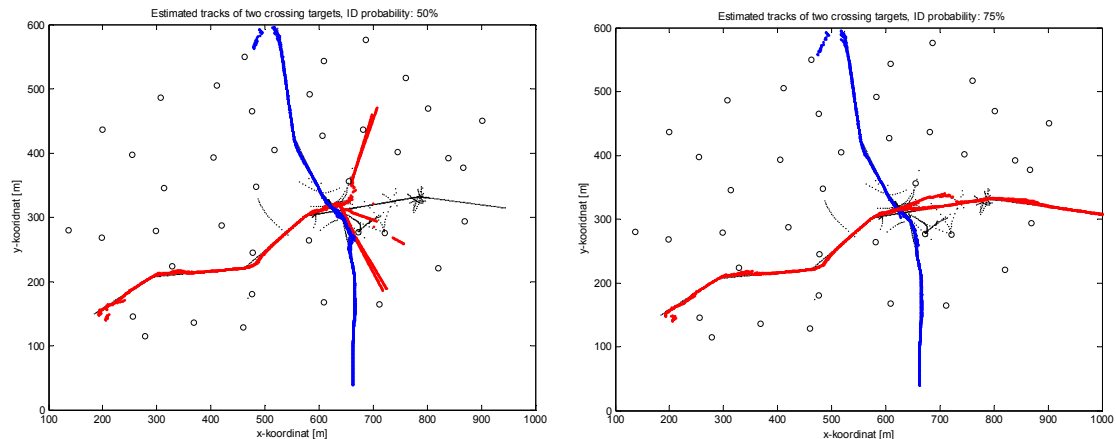
$$\mathbf{Q}(k) = (\text{processbrus}),$$

$$\mathbf{G}(k) = (\text{övergång för processbrus}).$$

En viktig punkt är associationen observation till mål. Givet sannolikhet för att visst mål observerats av samma sensorer (ID-fusion) kan man vid summeringen av \mathbf{i}_i och \mathbf{I}_i utesluta termer som inte uppfyller ett minimimått på samhörighet mål-observation. Detta har gjorts med framgång i ett simulerat scenario, diskuterat i avsnitt 7.3.

7.3 Modellscenario


Ett scenario med flera mål och nästan samtidigt korsande spår utgör en realistisk komplikation. I det följande studeras ett konstruerat fall med två fordon på kollisionskurs. Figur 12 visar ett exempel på två scener med 40 akustiska noder (o) som vid olika tidpunkter uppfångar ljud från två olika fordon (röda, blå spår). De svarta små punkterna markerar skärningar mellan bäringar från mikrofoner med nästan samtidiga mätningar. Huvudparten av dessa skärningar ligger på den sanna vägen. För att hålla detaljrikedomen nere har spår estimerat från endast 5 sensorer markerats. Vänster bild fokuserar på korsningen vid ca (650, 300) där associationen mål - observationer går helt fel för det från vänster kommande målet. Position och hastighet ensamma räcker här inte för att skilja mellan de två målen. Lösningen på detta problem blev att fusionera spårföljarens kinematiska information med klassificerarens ID-typ. En betydligt bättre situation uppstår när 75% av målen klassificeras korrekt, t.ex. grundat på majoritetsbeslut från tillförlitliga sensornoder. I detta fall sammanfaller huvuddelen av spår estimerat för båda målen praktiskt taget med den sanna vägen. Två röda spår avviker visserligen strax efter korsningen men återtar senare rätt kurs med hjälp av bättre information från majoriteten av sensorer. Som väntat uppför sig spårföljaren näst intill perfekt när båda målen klassificeras utan fel. I verkligheten uppstår komplikationer p.g.a. ljudets relativt låga fortplantningshastighet och dopplerskift från en rörlig ljudkälla. Dessa frågor kommer att tas upp vid fortsatta studier av IAM under 2004.



Figur 12. Vänster bild. Simulerat scenario med två mål på kollisionskurs. Sammanlagt 40 akustiska noder (o) observerar målen inom ett maximalt avstånd på 100 m. Bilden visar estimerade spår (röd: start från vänster, blå: start från topp) enligt 5 av dessa sensorer. De svarta punkterna markerar skärningar mellan bäringar från mikrofoner med samhöriga mätningar. Målen associeras med hjälp av position och hastighet. ID-klassificering ger endast 50% korrekta mål, d.v.s. slumpen avgör. **Höger bild.** ID-klassificering med 75% korrekta mål.

8 FOI:s IR/mm-radar system

Under sent 80-tal uppstod världen över tankarna på att ta fram en målsökare som förenade fördelarna med både IR och mm-vågsradar. Ett exempel på sådana satsningar gavs av det fransk-tyska experimentsystemet Astrid¹⁹, en två-mods IR/mm-w-sökare på en APACHE helikopter mot markmål. En sökning idag på Internet med ”dual-mode seeker” ger över 100 träffar, dock med ytterst knapphändig information och inget alls om Astrid. Trots allt har området varit tillräckligt intressant för att sporra utländska företag till olika systemlösningar. Eftersom så lite kunde utläsas ur öppna källor, beslöt FOI (fd FOA) att realisera planerna på att utveckla ett kombinerat stirrande IR- och stirrande mm-radar system för upptäckt av markmål. Den så vunna egna erfarenheten kunde komma till pass för att även värdera andras arbeten. Genom att utnyttja sensorernas komplementära egenskaper skulle markmålen bättre urskiljas mot en ofta besvärlig bakgrund. Valet av det korta mm-vågsbandet för radar svarade mot kravet på högre upplösning i sida och därmed lättare associering med IR. Kruxet var att fabricera en stirrande 2-D matris sammansatt av enskilda radarsensorer. Fram till år 2002 simulerades den stirrande radarns verkningsätt genom att stegvis avsöka målområdet genom en befintlig en-kanals radar. Mätningarna ensades i efterhand med IR-data vilket naturligtvis tog tid, och framförallt, inte gav den önskade samtidigheten med IR. Ett genombrott togs 1 oktober 2003 då man i realtid kunde demonstrera en prototyp av ett stirrande IR/mm-radarsystem mot rörliga markmål (en terrängbil och ett 15-tal får). I skrivande stund överarbetas systemets olika komponenter för att tillåta en mer fältmässig användning.



Figur 13. Vänster bild: IR/mm-vågs målsökare på ett vridbord. Höger bild: Översikt av försökssystemet.

8.1 Sensorer

Syftet med en kombinerad IR och mm-vågs målsökare (i fortsättningen kallad IR/mm) är för FOI:s del att hitta, identifiera och invisa högvärdiga markmål som kan bekämpas från en robot, se Figur 1. Ett försökssystem av målsökaren finns idag monterat på ett vridbord vid FOI, Linköping (se Figur 13, vänster bild). Till systemet hör också en tredje sensor, en videokamera, som idag används för manuell kontroll av de övriga sensorernas synfält. IR-kameran har en stirrande 64×64 pixel matris som upptar $5^\circ \times 5^\circ$ synfält i 3-4 μm våglängdsband. Millimetervågsradarn stirrar med 4×8 (höjd \times tvärs) mottagarelement inom $2,5^\circ \times 5^\circ$ synfält på 94 GHz. Figur 13 (höger bild) ger en översikt av försökssystemet bestående av 4 huvudgrupper: 1) sensorer på ett vridbord, 2) datalagring, 3) signalbehandling - målföljning, samt 4) konfigurering/ övervakning. Pilarnas gång visar hur kommunikationen mellan de olika delarna är tänkt att samverka till en önskad återkoppling mellan observationer och sensorstyrning. En flaskhals i systemet utgörs av datalagringen där signaler från sensorer med olika arbetstakt måste synkroniseras och matas vidare i lagom proportioner utan att strypa signalflödet. Idag är stora delar av försökssystemet skrivet i C/C++ under operativsystemet QNX avsett att köras i realtid. Ambitionen är att uppgradera systemet, först till fordonsburet med koherent radar, på sikt med sensorerna placerade i en luftburen kapsel för att simulera ett robotburet system.

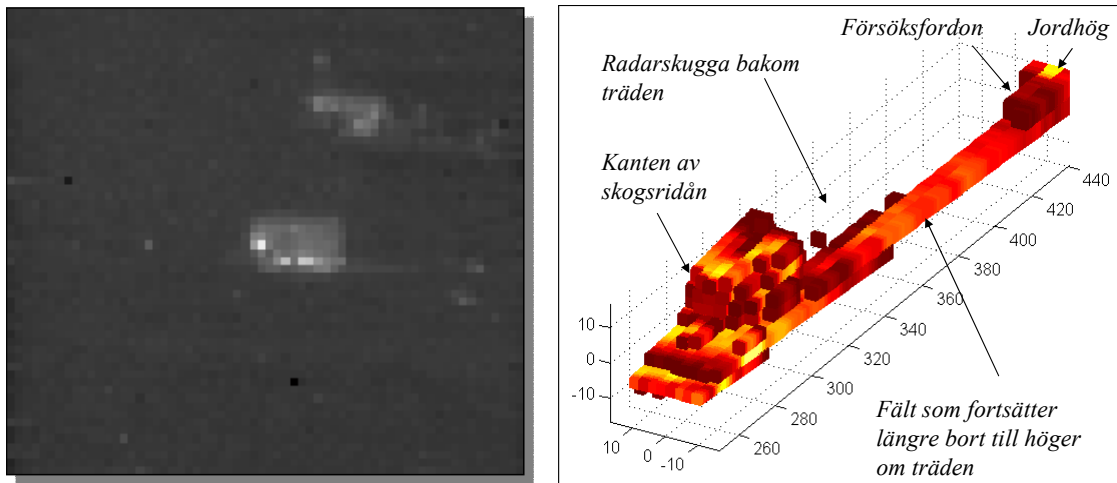
8.2 Datafusion och spårföljning

Beroende på situationen, målets art och taktiska överväganden finns olika sätt att kombinera en passiv IR med en aktiv radar. Figur 14 visar en scen med försöksbil tagen i visuellt ljus för att ge läsaren en bättre uppfattning av scengeometrin. Resultatet från de två huvudsensornas IR och radar visas i Figur 15. IR-bilden framhäver varma partier i mål och bakgrund. Radarbilden är från en tidigare upptagning i 8×8 lobar med en enkanalsradar. Eftersom en stirrande radar genererar en 3-D volym av signalekon (sida \times höjd \times avstånd) inskränker sig visualiseringen här till att visa en projektion av denna signalvolym. Tagna tillsammans ger IR och radardata en mer komplett bild av målscenen. IR ger, förutom en värmebild, även 8 gånger bättre tvärsupplösning, medan radarn bidrar med specifika ekon på registrerade avstånd.




Figur 14. Scen med försöksbil i visuellt ljus.

Autonom upptäckt, identifiering (klassificering) och följning av ett mål ställer krav på robusta algoritmer för signalbehandling, målföljning och sensorstyrning. I det tänkta målsceariot förutsätts någon form av invisning från t.ex. en helikopter till ett målområde som målsökaren har att avsöka under anflygningen. Utgångspunkten för spårföljning är ett detekterat mål från åtminstone en sensor. Vid bra väder observeras normalt målet först i IR-bilden som filtreras med en grupp *kontrastfilter** avstämnda i storlek och orientering till målets förväntade utsträckning i höjd och bredd.



Figur 15. Scen enligt Figur 14 i IR (vänster bild) och perspektiv av 3-D ekon i 8×8 lober från en skannande radar (höger bild, fordonet längre bak än i IR).

Figur 16 visar två orienteringar av sådana filter med storleken 14×7 pixlar. Den inre 7×7 regionen med positiva värden är avstämmd till målets vinkelutsträckning. Omgivande korridorer på vardera 3×7 nollor utgör en friyta till marginalerna på 1×7 negativa värden som känner av bakgrunden. Summan av alla filterelement är noll så att en ren bakgrund returnerar filtervärdet noll. Kombination av filter med olika orientering resulterar i undertryckning av ej önskad bakgrund.

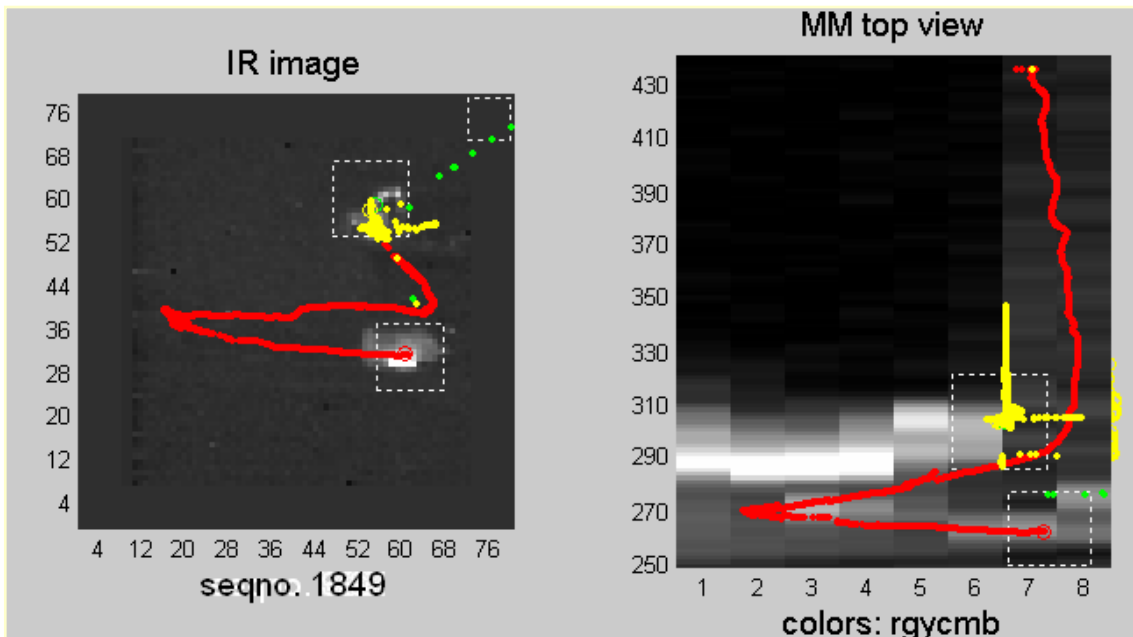


Figur 16. Kontrastfilter i två orienteringar för IR-bilder.

Radarns roll är att förse IR-data med bättre avstånd och därmed skärpa storleksurvalet av filtren. Denna fusion av IR- och radardata verkar för att sälla ut målkandidater av förväntad storlek mot en varierad bakgrund. Huvuduppgiften för datafusion i IRmm-systemet ligger annars i spårföljning av tänkbara mål. De sökta målen är oftast bara en delmängd av de funna p.g.a. att klassificeringen har en viss osäkerhet. Ett antal spår startas upp och det är upp till följealgoritmen att associera rätt mål med rätt spår. En del

mål är stationära, andra rör sig. Nya mål kommer till, gamla mål ”dödas”. Uppenbarligen kan denna process bli tämligen komplicerad med många mål i en besvärlig omgivning.

Identifiering i detta sammanhang handlar om att hålla reda på just de ”heta” målen som av olika anledningar tenderar att tappas bort. I vårt fall utgörs spårföljaren av en grupp algoritmer under punkt 3 i Figur 13 (höger bild) där kärnan är ett s.k. *informationsfilter** (en variant av Kalmanfilter)²⁰ gjord för att fusionera asynkrona kinematiska data från olika sensorer till ett gemensamt målspar. En inbyggd robusthet i algoritmen gör att denna ”tracker” följer *många* samtidigt med *flera olika oberoende* sensorer. Skulle en sensor ”spåra ur” finns möjlighet (med smart logik) att hålla kvar målet med övriga sensorer.



Figur 17. Spårföljning av tre mål i varsin färg. **Vänster bild:** IR. **Höger bild:** projicerad toppvy av starkaste radarekon från 250 till 440 m enligt y-axeln.

Figur 17 visar ett resultat från fölning av tre mål i hagmark (se Figur 14). En terrängbil (rött spår) syns vid IR-koordinater (60,30). De streckade kvadraterna markerar detektioner med från kontrastfiltret. De andra spåren ansluter två sporadiska falskmål, varav ett mål (gult) egentligen är en lastbil bortanför terrängbilen. Ett typiskt problem är att associera rätt mål med rätt spår vid täta passager. I Figur 17, höger bild, uppstår en sådan situation vid koordinaterna (7,290). Det röda huvudspåret klarar sig likväl förbi detta parti p.g.a. en inbyggd flervalnsfunktion i trackern. En annan (här bemästrad) svårighet är att urskilja målet från en klottrig bakgrund, t.ex. en skogsrand nära fordonet i avståndsintervallet 280 – 310 m.

ID-fusion med hjälp av sensordata är planerad till 2004 och väntas följa i stort samma mönster som i MUMS projektet. Skillnaden är att IRmm-systemet baseras på en stirrande mm-vågsradar medan MUMS arbetar med en högupplösande Ku-radar (FOI) eller SAR teknik (Saab), vilket medför att olika typer av särdrag bidrar till måligenkänningen.

9 Sammanfattning

Denna rapport beskriver olika aspekter av klassificering och datafusion med en blick på principiella metoder av generisk art. Gränsen mellan klassificering och fusion av sensordata är ibland svår att dra, vilket också har motiverat en kort beskrivning av vanliga klassificerare. För att studera några metoder i mer detalj ges tillämpning av datafusion på tre FOI-projekt, en Multisensormålsökare (MUMS), ett interaktivt marksensornät (IAM) och ett IR/mm-vågs målsökarsystem.

I projektet MUMS har en robotburen multisensormålsökares förmåga att känna igen stridsfordon studerats. Scenariorna har utgjorts av dels simulerade landskap med modeller av fordon och sensorer. Särdrag har extraherats från segmenterade IR-scener och avståndsprofiler från en högupplösande radar. Målet med särdragsextraktion är att välja de särdrag som bäst bevarar klass-separabiliteten för att sedan bli indata till klassificeringsalgoritmerna. Resultaten visar att ett mål klassificeras rätt med högre sannolikhet om man kombinerar IR och radar, givet kännedom om osäkerhet i sensordata. I synnerhet för radarn gäller att träningsmängden objekt ligger tillräckligt tätt i målavstånd och aspektvinkel. Dessa prestanda bygger på en klassificerare baserad på artificiella neuronät. Andra kombinationer av klassificerare ger jämförbara resultat.

I projektet IAM fusioneras spårföljarens kinematiska data med ID-information från en klassificerare av akustiska/seismiska signalspektra i naturlig terräng med verkliga stridsfordon och sensorer. Vinsten med fusion är här en betydligt lättare association mål-observation i komplexa situationer (t.ex. förband med många fordon på liten yta). Liknelse görs med ett NBF i miniatyr med agenter som informationsbärare.

I projektet IR/mm har en robotburen multisensormålsökares förmåga att detektera och följa olika stridsfordon studerats. Scenariorna har utgjorts av naturlig terräng med verkliga stridsfordon och sensorer. Antalet möjliga målkandidater till en spårföljare har starkt reducerats med hjälp av flervals-kontrastfilter (detektion m.a.p. storlek i IR). ID-fusion med hjälp av sensordata är planerad till 2004.

Betydelsen av principiella metoder framhävs på ett övergripande plan, men lika viktigt är metodernas omsättning i praktiken. Enkelhet att komma igång, hanterbarhet och tillit är tre framgångsfaktorer. Den förväntade extra volymen av information kan inskränka sig till en marginell effekt om insamlings- och räkneprocessen drivs tillräckligt snabbt för att hålla obearbetade data på ett minimum. Mycket av hittills studerat arbete bygger på ett fåtal "favoritmetoder", t.ex. artificiella neuronät, som visat sig generellt användbara. Den kanske allra enklaste formen av datafusion är majoritetsbeslut med det stilla antagandet att trovärdigheten på något sätt kan värderas för de olika beslutsfattarna.

Särdragsextraktion ur data från olika sensorer är ett sätt att reducera information till ett gemensamt format som direkt kan fusioneras. Framförallt behövs standardiserade format till ID-bibliotek och datafusionsnoder. På grund av yttre omständigheter händer det ofrånkomligen att dataformaten skiljer sig åt, i vilket fall dokumentationen av formaten måste vara helt klar för att möjliggöra en transformation till ett gemensamt system. De grundläggande algoritmerna skrivs antagligen av experter och behöver ej vara synliga för slutanvändaren.

En väsentlig del av förbehandling till ID-fusion bör kunna göras av algoritmer i hårdvara. T.ex. roteras 3-D scener direkt i grafikkortet, men steget till mer allmänna operationer är inte långt. Enkla fast robusta klassificeringsmetoder, som bygger på direkta skattningar av sannolikhetsfördelningar (Parzens metod) eller matchningar genom korrelation av särdragsvektorer, skulle kunna snabbas upp väsentligt i dedicerad hårdvara. Resultatet från sådana beräkningar måste dock jämföras med motsvarande resultat beräknade i mjukvara för att säkerställa vissa minimikrav på kvalitet.

Rent allmänt syns en tydlig trend mot mer avancerade beräkningar nära sensorerna. En springande punkt är datafusion. Robustifiering av datafusionsprocessen kräver ett mer utspjutt arbetssätt fördelat på lokala sensorer och någon central enhet. En optimal avvägning mellan önskad information och dess överföring, som kostar tid, är ett organisatoriskt problem för informationssystem på högre nivå.

10 Referenser

- ¹ L. Carlsson, M. Gustafsson, P. Hermansson, M. Karlsson, N. Karlsson, A. Lauberts, F. Näsström, M. Wilow, "Multisensormålsökare - Klassificering av markmål med datafusion", FOI-R--0652--SE (2002).
- ² M. Tyskeng, "MOSART-Instructions for use". FOI Technical Report FOI-R--1098--SE (2003).
- ³ The MathWorks, <http://www.mathworks.com/>.
- ⁴ S. Haykin, *Neural Networks, 2. Ed*, New Jersey, Prentice Hall (1999).
- ⁵ M. Riedmiller and H. Braun, "A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm", *Proceedings of the IEEE International Conference on Neural Networks*, San Francisco, CA, March 28-April 1 (1993)
- ⁶ P. K. Varshney, "Distributed Detection and Data Fusion", Springer Verlag (1998).
- ⁷ D. Hall and J. Llinas, "Handbook of Multisensor Data Fusion", kap. 22, CRC Press, New York (2001).
- ⁸ O. Kessler, "Dynamic Database", <http://www.darpa.mil/DARPATech2000/presentation.html>
- ⁹ B. Andersson, B. Boberg, G. Bolander, A. Eneroth, S. Gadd, O. Gustavsson, N. Karlsson, P. Klum, C. Nelsson, O. Steinvall, T. Svensson, C. Wigren, "Störning av multisensorsystem - en förstudie", FOI-R--0879--SE (2003).
- ¹⁰ "Data and information fusion in Network Centric Warfare", *Miltärteknisk Tidskrift #1* (2003).
- ¹¹ "Sensor Networks and Applications", *Proc. of the IEEE*, Vol. 91, Number 8, August 2003.
- ¹² M. Karlsson och A. Lauberts, "Användning av datafusion vid klassificering av markmål, en inledande studie", Linköping: FOA-R--00-01655-314--SE (2000).
- ¹³ L. Carlsson, M. Gustafsson, P. Hermansson, M. Karlsson, N. Karlsson, A. Lauberts, F. Näsström, M. Wilow, "Multisensormålsökare - Generering av simulerade IR- och radardata från terrängmodell", Linköping: FOI-R--0540--SE (2002).
- ¹⁴ L. Carlsson, M. Gustafsson, P. Hermansson, M. Karlsson, N. Karlsson, A. Lauberts, F. Näsström, M. Wilow, "Multisensormålsökare - Klassificering av markmål med datafusion", Linköping: FOI-R--0652--SE (2003).
- ¹⁵ F. Bennet och S. Fenelius, "SceneServer - a 3D software assisting developers of computer vision algorithms", FOI-R--0831--SE (2003).
- ¹⁶ A. Sume: "Multimålsökarprogrammet: Radarsignaturer hos mål och bakgrund med speciell inriktning mot mm-vågsområdet", Linköping, FOA delunderlag, FOA-DH--98--00101-314, April (1998).
- ¹⁷ R. Aljasmí, L. Carlsson, S. Gadd, J. Gustavsson, M. Gustafsson, N.-U. Jonsson, M. Karlsson, N. Karlsson, A. Lauberts, F. Näsström, A. Sume, M. Wilow, A. Örbom, "Multisensormålsökare - Klassificering av markmål med datafusion - 3", FOI-R----SE (2003, preliminär version).
- ¹⁸ E. Nettleton and H. Durrant-Whyte, "Delayed and Asequent Data in Decentralised Sensing Networks", University of Sydney, <http://www.acfr.usyd.edu.au>
- ¹⁹ "Guidance candidate for conventional strategic weapons", *International Defense Review* 8/1993, s. 611.
- ²⁰ H. Durrant-Whyte and M. Stevens "Data Fusion in Decentralised Sensing Networks", University of Sydney, <http://www.acfr.usyd.edu.au>