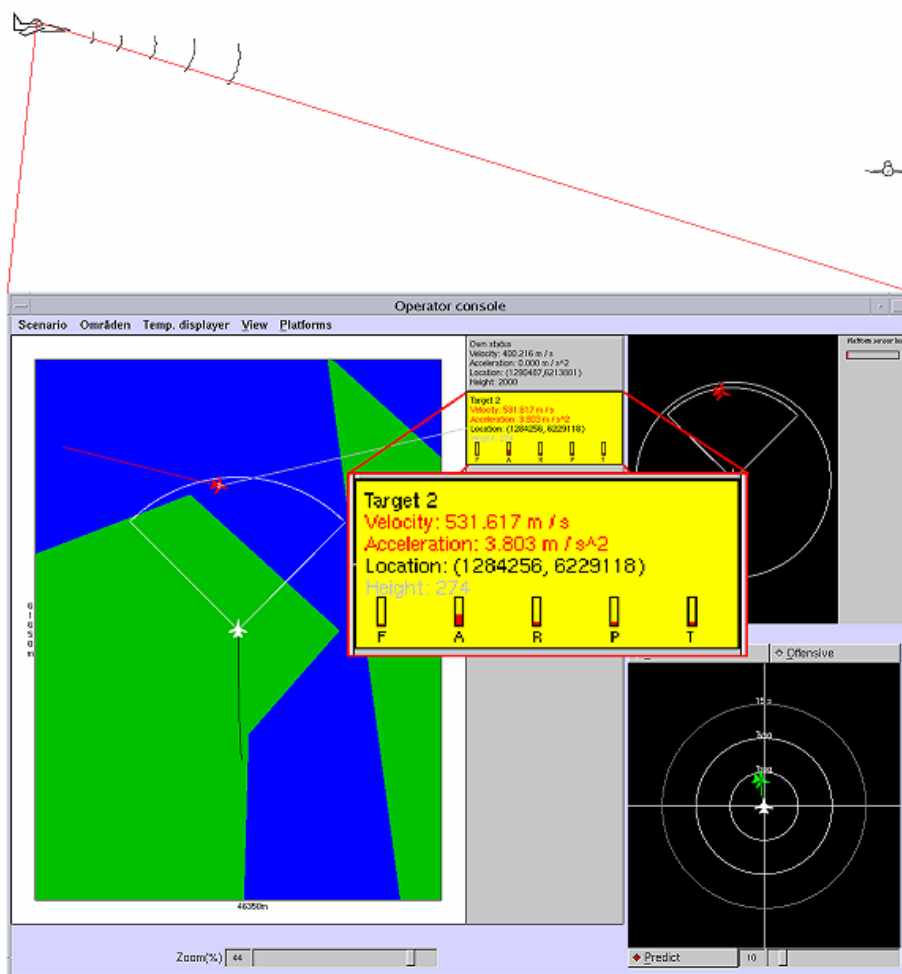


Maria Andersson, Martin Folkesson

Metoder för situationsanpassad måligenkänning baserade på kinematiska data



TOTALFÖRSVARETS FORSKNING SINSTITUT

Avdelningen för Ledningssystem

Box 1165

581 11 Linköping

FOI-R--1022--SE

December 2003

ISSN 1650-1942

Teknisk rapport

Maria Andersson, Martin Folkesson

Metoder för situationsanpassad måligenkänning baserade på kinematiska data

Utgivare Totalförsvarets Forskningsinstitut – FOI Ledningssystem Box 1165 SE-581 11 Linköping	Rapportnummer, ISRN FOI-R--1022--SE	Klassificering Teknisk rapport
	Forskningsområde 8. Människan i totalförsvaret	
	Månad, år December 2003	Projektnummer E7022
	Verksamhetsgren 5. Uppdragsfinansierad forskning	
	Delområde 81 MSI med fysiologi	
Författare/redaktör Maria Andersson Martin Folkesson	Projektledare Dan Strömberg	
	Godkänd av Johan Mårtensson, institutionschef	
	Uppdragsgivare/kundbeteckning Försvarsmakten	
	Tekniskt och/eller vetenskapligt ansvarig Författarna	
Rapportens titel Metoder för situationsanpassad måligenkänning baserade på kinematiska data		
Sammanfattning (högst 200 ord) Rapporten diskuterar måligenkänning baserat på kinematiska data. En modell för uppdragsigenkänning av flygande mål presenteras. Uppdragen som karakteriseras av olika beteenden, eller rörelsemönster, är jakt, attack, spaning, transport och allmänflyg. Modellen bygger på teorin för dolda Markovmodeller. Den har implementerats i den s.k. datafusionsnoden, <i>DF</i> . <i>DF</i> är ett samlingsnamn för en rad olika modeller och algoritmer som beskriver de olika stegen i datafusionsprocessen, d v s insamling och analys av data, situationsbestämning, hotanalys och anpassning/styrning. Ett syfte med <i>DF</i> är att studera olika sätt att förbättra plattformsoperatörens situationsuppfattning. Måligenkänning skapar möjlighet till bättre situationsuppfattning. Några exempel på simulering av måligenkänning presenteras. Dessutom beskrivs kortfattat en annan modell för måligenkänning baserat på kinematiska data. Den modellen baseras på Dempster-Shafers regel. Slutligen diskuteras några allmänna aspekter på måligenkänning baserat på kinematiska data. Sådana aspekter är bland annat hur måligenkänningen kan utnyttjas i ett nätverk av plattformar samt hur den kan ligga till grund inför sensorstyrning.		
Nyckelord Måligenkänning, målklassificering, dolda Markovmodeller, sensorstyrning, operatör, plattform, nätverk, Dempster-Shafer.		
Övriga bibliografiska uppgifter	Språk Svenska	
ISSN 1650-1942	Antal sidor: 36	
Distribution enligt missiv	Pris:	

Issuing organization FOI – Swedish Defence Research Agency Command & Control P. O. Box 1165 SE-581 11 Linköping SWEDEN	Report number, ISRN FOI-R--1022--SE	Report type Technical Report
	Programme Areas 8. Human Systems	
	Month year December 2003	Project no. E7022
	General Research Areas 5. Commissioned Research	
	Subcategories 81 Human Factors and Physiology	
Author/s (editor/s) Maria Andersson Martin Folkesson	Project manager Dan Strömberg	
	Approved by Johan Mårtensson, Head of Department	
	Sponsoring agency Swedish Armed Forces	
	Scientifically and technically responsible The authors	
Report title (In translation) Methods for Situation-Adapted Target Recognition Based on Kinematic Data		
Abstract (not more than 200 words) <p>The report discusses target recognition based on kinematic data. A model for aerial-mission recognition is presented. The missions, which are characterized by different motion patterns, are fight, attack, reconnaissance, transport and general aviation. The model is based on the theory of Hidden Markov Models (HMM). It has been implemented in the Data Fusion node (<i>DF</i>). <i>DF</i> consists of models and algorithms for the different steps of the data fusion process, i. e. collection and analysis of data, situation assessment, threat analysis and adaptation/control. A purpose with <i>DF</i> is to investigate how to improve situation awareness for a platform operator. Target recognition makes possible an improvement in situation awareness. Simulations of aerial-mission recognition are presented.</p> <p>Another model for target recognition based on kinematic data is shortly presented. It is based on Dempster-Shafers' rule.</p> <p>Finally some general aspects on target recognition based on kinematic data are discussed. Such aspects are for example how the target recognition can be used within a network of platforms and how it can be used as a base for sensor management.</p>		
Keywords Target recognition, target classification, hidden Markov models, sensor management, operator, platform, network, Dempster-Shafer.		
Further bibliographic information	Language Swedish	
ISSN 1650-1942	Pages 36	
	Price acc. to pricelist	

Innehållsförteckning

1. Introduktion	6
1.1. Bakgrund och syfte	6
1.2. Måligenkänning – allmänt	7
2.2.1. Kännetecken till grund för måligenkänning	7
2.2.2. Sensorer och måligenkänning	9
1.3. Måligenkänning baserat på målföljningsdata	9
1.4. Måligenkänning och sensorstyrning	11
1.5. Datafusionsnoden (DF)	12
1.5.1. OODA-loopen i DF	12
1.5.2. Algoritmer för målföljning i DF	13
1.5.3. Sensorstyrning i DF	14
1.5.4. Nätverkstjänster i DF	14
2. Dolda Markovmodeller (HMM) – uppdragsigenkänning	14
2.1. Teori för HMM och beräkning av trolighet	14
2.2. Tillämpning på problemet för uppdragsigenkänning	16
2.2.1. Beskrivning av uppdragens typiska rörelsemönster	16
2.2.2. Tillstånd	19
2.2.3. Observationer	20
2.2.4. Inläring av HMM	21
2.3. Simuleringar och resultat	22
2.3.1. Simuleringar i DF	22
2.3.2. Några olika sätt för resultatpresentation	26
2.4. Osäkerheter baserade på val av modellparametrar	26
3. Suddig matchning – typigenkänning	27
4. DF och måligenkänning i plattformsnätverk	29
5. Aspekter på måligenkänning och sensorstyrning	29
6. Några slutsatser	30
6.1. En jämförelse mellan matchningsmodell och HMM	30
6.2. Allmänna reflektioner om måligenkänning med kinematiska data	31
7. Förslag till fortsatt arbete	32
8. Referenser	33
BILAGA 1: Parametervärden till de dolda Markovmodellerna	35

Projektet

Arbetet bakom denna rapport har finansierats inom ramen för FoT-projektet *Operatörsstöd i samverkande stridsplattformar*. Projektet ingår i FoT-området MSI, Människa/System-Interaktion. Forsknings- och Teknikutvecklings (FoT) projekten beställs av FM, den svenska försvarsmakten. Rapporten är en leverans från projektet.

Medhjälpare

Författarna tackar Dan Strömberg, Thomas Berg, Robert Forsgren, Fredrik Lantz, Göran Pettersson och Thomas Kaijser för den hjälp och vägledning som givits under arbetets gång med modellerna och rapporten.

Omslagsbild

Omslagsbilden visar ett flygplan och dess operatörsgränssnitt. Flygplanet spanar på ett mål med sin radar. I ett stapeldiagram i operatörsgränssnittet redovisas skattningen av det uppdrag som målet kan tänkas utföra.

1. Introduktion

1.1 Bakgrund och syfte

I projektet *Operatörsstöd i samverkande stridsplattformar* studeras hur operatörens omvärldsuppfattning kan förbättras. I projektet utvecklas bland annat ett mjukvarusystem kallat *datafusionsnoden* (DF). Syftet med DF är att studera olika alternativ för hur situationsuppfattningen för en operatör kan förbättras.

I DF studeras olika nivåer av datafusion. Dessa är enligt den s.k. JDL-modellen (Joint Directory Laboratory) [12] följande fem nivåer:

1. *Signalbehandling*. Information extraheras ur den signal som sensorn mottagit.
2. *Multisensorfusion*. Uppgifter från olika sensorer eller uppgifter från olika tidpunkter sammanställs.
3. *Situationsanalys*. Den situation som orsakar observerade data och händelser identifieras.
4. *Hotanalys*. Risker och möjligheter analyseras.
5. *Adaption/anpassning*. Resultat från datafusionsprocesser förbättras i ett nästa steg genom bl a styrning av sensorer.

DF är en forskningsprototyp där olika algoritmer på var och en av dessa nivåer kan integreras och analyseras. Särskilt intressant är att studera hur olika operatörers situation och förutsättningar för att fatta beslut påverkas. Projektet fokuserar speciellt på flygförarens situation.

Måligenkänning genomförs på nivå 2 i JDL-modellen. Måligenkänning baseras antingen på information från olika sensorer eller på information som insamlats under en viss tid med en och samma sensor. Måligenkänning utgör därmed en av grunderna för de tre efterföljande nivåerna. Det kan också tänkas att måligenkänning i vissa fall bör gå direkt till hotanalys, d v s utan att passera situationsanalys. Ett exempel på en sådan situation kan vara då tiden för att agera är mycket kort. För flygförare kan kritiska situationer uppstå mycket snabbt och beslut behöva fattas på mycket kort tid.

Rapport ägnas åt två metoder för plattformsbaserad måligenkänning baserade på kinematiska data. Huvuddelen av rapporten ägnas åt en ansats för att känna igen flygande måls *uppdrag*. Modellen tillämpar s.k. dolda Markovmodeller (Hidden Markov Models, HMM), som blivit populära i många olika typer av mönsterigenkänningsproblem. Här har HMM implementerats i DF. Rapporten summerar även en ansats för igenkänning av flygande måls *typ*. Modellen bygger på en ”suddig” (eng. fuzzy) matchning av data mot lagrade data. En fördel med dessa modeller är att de inte kräver extra sensorresurser, eftersom data redan finns tillgängliga via målföljning.

Med plattformsbaserad måligenkänning kan en operatör på egen hand, eller inom ett nätverk av plattformar, skapa sig en uppfattning om vilken klass ett mål tillhör. Möjligheten att få en situationsuppfattning blir mer robust, då även måligenkänning via det övergripande luftövervakningssystemet (luftlägesinformation) finns tillgängligt.

Att tolka rörelsemönster från en radarbild och försöka förstå vilken klass ett mål tillhör är säkerligen inte något nytt. Men i en omgivning av multipla mål blir det svårare för en operatör att hinna analysera och tolka enskilda banor och samtidigt fatta en rad beslut om olika

åtgärder. Modellen ska beskriva den kunskap och erfarenhet som operatören innehar och fungera som ett stöd vid beslutsfattning. För en obemannad farkost kan en sådan modell också få stor betydelse.

Måligenkänning är en komplicerad process som ofta innehåller stora osäkerheter. Trots osäkerheter kan det vara nödvändigt att introducera en modell för måligenkänning. I en omgivning med stort antal mål blir modellen en hjälp vid prioritering av mål. Prioritering är nödvändigt eftersom utrustning, information och arbetskraft ofta är knappa resurser.

1.2 Måligenkänning - allmänt

Information om målets klass har en viktig taktisk betydelse i militära sammanhang. En felaktig bedömning av målet leder till en felaktig bedömning av risker. För måligenkänning av punktmål ökar betydelsen av stöd för måligenkänning, eftersom flygföraren på långa avstånd inte visuellt kan bekräfta om ett mål verkligen är en fiende. Måligenkänning är också ett av stegen innan situations- och hotanalys. Måligenkänning baserad på dynamiska kännetecken är speciellt värdefull för hotanalys, eftersom variationer i kännetecken kan ge indikation på hur hotfullt målet vid en speciell tidpunkt.

Måligenkänning baseras på en sammanvägning av observationer som samlats in antingen under en viss tid och/eller från olika källor. Varje tidpunkt eller källa ser målet ur en egen synvinkel. Observationerna fusioneras så att kunskapen blir större jämfört med den kunskap som fås från varje enskild tidpunkt eller källa i sig.

Det finns en mängd olika algoritmer för fusion av kännetecken. Vilken algoritm som slutligen väljs är till stor del en fråga om vilken information som finns tillgänglig angående möjliga mål, aktuell omgivning och typ av sensor.

De viktigaste typerna av algoritmer för fusion är Bayesiansk slutledning (inklusive maximum likelihood, ML) och bevisslutledning (eng. evidential reasoning) [6]. De två algoritmerna som studeras i denna rapport hör till dessa två kategorier av algoritmer.

1.2.1 Kännetecken till grund för måligenkänning

Det finns en rad olika kännetecken som kan användas för måligenkänning [6]. Typiska kännetecken ges av följande;

Signaturer

Karakteristiska egenskaper om ett mål kan erhållas genom att extrahera särdrag ur sensorinformation. Sådan information beskriver på något sätt målets spatiala utbredning eller en viss typ av utrustning. Den extraherade sensorinformationen jämförs med känd, beräknad eller uppmätt, information. Signaturer kan erhållas med radar- och IR-sensorer. Radaravbildningar baseras på spridningsteoretiska samband som beskriver samband mellan mätdata och reflektionsfördelning för målet. För IR-avbildningar kan strålningsintensitet kopplas till typ av flygplansmotorer. *Variationer* i strålningsintensitet kan indikera en förändring i målets beteende, exempelvis att efterbrännkammaren används.

En annan typ av signatur ges av JEM data (Jet Engine Modulation, JEM). Jetmotorers rörliga delar påverkar radarekott, vilket kan användas för att identifiera typ av motor.

Signalspaning

Med signalspaning analyseras målets elektromagnetiska emission som orsakas av radar och kommunikationsutrustning. Signalspaning kan därmed ge information om målets tekniska och operativa resurser. Olika typer av mål har olika uppsättningar av radar och kommunikationsutrustning och använder dem på olika sätt.

En annan typ av signalspaning ges med igenkänningssignalering, IK (IFF Identification of Friend or Foe). IK är en metod för att särskilja flygplan från varandra. I militära sammanhang används IK för att undvika vådabeskjutning av egna flygplan. I civila sammanhang används IK för att definiera och särskilja flygplan i samma trafikområde. En s.k. frågepuls skickas till målet. Målets svarsutrustning besvarar pulsen automatiskt. Mål som är vän eller neutral förväntas besvara pulsen. Mål som är fientligt förväntas inte besvara pulsen.

Grov kinematisk information

Fart- och banprofil kan ge information om målets typiska rörelsemönster. Olika klasser av mål har olika fartintervaller inom vilka uppdragen genomförs. De flesta kommersiella flygplan följer inrättade luftleder. Huruvida målet följer eller inte följer en luftled ger viss information om vilken klass målet tillhör.

I litteraturen finns en del beskrivet om igenkänning av flygande mål. I [25] diskuteras hur radaravbildning kan ligga till grund för måligenkänning. I [3] diskuteras hur signalspaning kan modelleras. Måligenkänning baserat på kinematiska data har studerats av exempelvis [7], [22] och [24]. Där ses måligenkänning baserat på kinematiska data som en del i en helhet, där också andra kännetecken hos mål beaktas. Det slutliga resultatet är en sammanvägning, fusion, av olika typer av kännetecken.

Måligenkänning sker till olika detaljeringsgrad. Olika grupper av kännetecken (signatur, signalspaning, kinematiska data) resulterar i olika detaljeringsgrad i igenkänning. I [7] har målets klass delats in i följande tre nivåer:

Tabell 1. Målets klass uppdelat i tre nivåer

<i>Nivå</i>	<i>Benämning</i>	<i>Exempel</i>
1	Typ	F-16, JAS 39 Gripen
2	Klass	Jakt-, attack-, transportflyg
3	Natur	Vän, neutral, fiende, okänd

Den minst detaljerade igenkänningen, nivå 3, beskriver om målets *natur*, d v s vän, neutral, fiende eller okänd. En något mer detaljerad igenkänning ges på nivå 2. Där anges målets *klass* av flygplan. Olika klasser är bl a jakt-, attack- och transportflygplan. Den mest detaljerade igenkänningen, nivå 1, identifierar målet till *typ*, d v s F-16, SU 27. Ytterligare en nivå (nivå 0) skulle kunna introduceras, nämligen *identitet*. Identiteten hos målet beskriver exakt vilken individ av exempelvis F-16 som observeras.

I tabell 1 definieras *klass* till en viss detaljeringsgrad. Trots det används i rapporten benämningen *målets klass* för att beskriva *något* resultat från en måligenkänning, dvs. oberoende av vilken detaljeringsgrad det gäller.

I [7] föreslås vidare att med observationer om banprofil eller IK-svar kan målet kännas igen till nivå 3. Med observationer om fart kan målet kännas igen till nivå 2. Med observationer om elektromagnetisk utstrålning kan målet kännas igen till nivå 1.

1.2.2 Sensorer och måligenkänning

Olika typer sensorer mäter olika kännetecken. Radar mäter avstånd relativt noggrant, men riktning sämre. Avståndet ligger till grund för beräkning av målets position och beteende. Radar kan användas i alla typer av väder och ljus. Radarn är aktiv, vilket innebär att den avslöjar den egna plattformens existens för omgivningen. Att avslöja sin existens är inte alltid önskvärt i militära sammanhang. Radar kan också ge information om målets spatiala utbredning (reflektionsfördelning) samt typ av motor (JEM). På långa avstånd blir informationen om målets spatiala utbredning relativt osäker.

Elektro-optiska sensorer såsom IRST-sensorer (InfraRed Search and Track) är passiva. Dessa sensorer avslöjar inte den egna existensen. IRST mäter azimutvinkel och höjd, men inte räckvidd. IRST kan mäta är målets strålningsintensitet kopplat till exempelvis typ av motor. För att detta ska vara möjligt behöver avståndet till målet vara relativt kort. Optiska sensorer är *inte* oberoende av väderförhållande. De fungerar bäst då luften är klar.

ESM-sensorer (Electromagnetic Support Measures) såsom radarvarnare och IK används för att detektera användning av aktiva sensorer. Aktiva sensorer sänder ut elektromagnetisk energi. ESM-sensorer är, liksom optiska sensorer, passiva. De mäter vinkel relativt bra, men kan inte mäta avstånd. Vid de tidpunkter då målet inte emitterar energi kommer ESM-sensorer inte att ge någon information.

Att kunna ha tillgång till flera typer av sensorer är fördelaktigt. Det ger en mer robust igenkänning där det i de flesta situationer kommer att finnas möjlighet att erhålla någon form av information om målet.

1.3 Måligenkänning baserat på målföljningsdata

Målföljningsdata ger information om målets position, hastighet och acceleration. Flygplan med olika uppdrag har åtminstone periodvis specifika värden på position, hastighet och acceleration som särskiljer dem från andra uppdrag. Ett civilt trafikflygplan flyger i sin luftled. Militära flygplan kan flyga med högre fart. Hur målets beteende varierar över tiden ger också värdefull information. Specifika rörelsemönster kan observeras i exempelvis attack- och jaktuppdrag inför och i samband med attack och jakt [15].

Kinematiska data för igenkänning finns redan tillgängliga från målföljningsmodellen. Osäkerheter i måligenkänning beror inte bara på de parametrar som givits modellen för måligenkänning, utan också på hur målföljningsmodellen lyckas följa målet. Om ett mål inte kan följas tillräckligt bra kommer skattningen av målets klass att innehålla större osäkerheter.

Målföljning består av flera processer. Två viktiga processer är dataassociation och prognos/prediktering.

Då flera mål observeras i samma mätning behövs procedurer för dataassociation. Med dataassociation menas att koppla en observation till rätt målspar. Det finns en rad olika metoder för dataassociation [6]. Innan dataassociation tar vid kan en grov sällning av observationer göras (eng. gating). Gating görs i syfte att reducera antalet beräkningar för dataassociation. De observationer som ligger närmast ett målspar, enligt något intervall, sparas för dataassociation.

Prognos för målets tillstånd görs för den tidpunkt då nya observationer ska komma. En ofta använd modell för prognos av tillstånd är Kalmanfiltret. Kalmanfiltret använder ett

sekventiellt tillvägagångssätt för uppdatering av tillstånd. Nedanstående ekvation beskriver förenklat hur ett Kalmanfilter uppdaterar tillstånd. Det nya tillståndet \hat{x}_{K+1} beräknas som summan av föregående tillstånd \hat{x}_K och en viktad skillnad mellan observationen z_{K+1} och \hat{x}_K .

$$\hat{x}_{K+1} = \hat{x}_K + \left[\frac{1}{K+1}\right][z_{K+1} - \hat{x}_K]$$

Nedan ges exempel på några fall som kan komplicera målföljningen och därmed öka osäkerheten i måligenkänning.

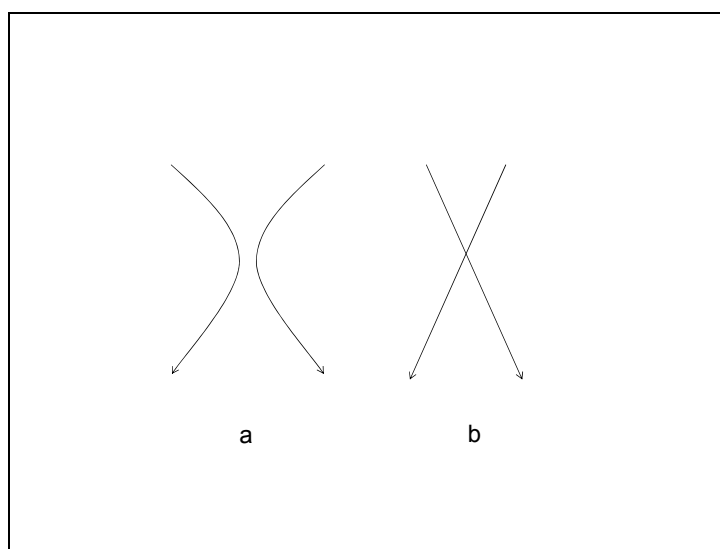
Multipla mål

Dataassociation blir komplicerat i en omgivning med multipla mål, och i synnerhet om de befinner sig nära varandra. I en sådan situation är det svårt att veta vilken observation som ska kopplas till vilket målspar. Det finns därmed en ökad risk att en observation kopplas till fel målspar. Med felaktig dataassociation kan märkliga rörelsemönster växa fram.

Måligenkänning är naturligtvis ointressant i sådana fall.

Korsande målspar

Komplikationer kan också uppstå då två banor ser ut att korsa varandra. Antingen korsar de varandra eller gör en sväng, se figur 1. Rakbana eller sväng har betydelse för måligenkänning. Två skarpa svängar förstärker troligheten för uppdrag som jakt och attack, medan två korsande mål förstärker troligheten för uppdrag som transport och spaning.

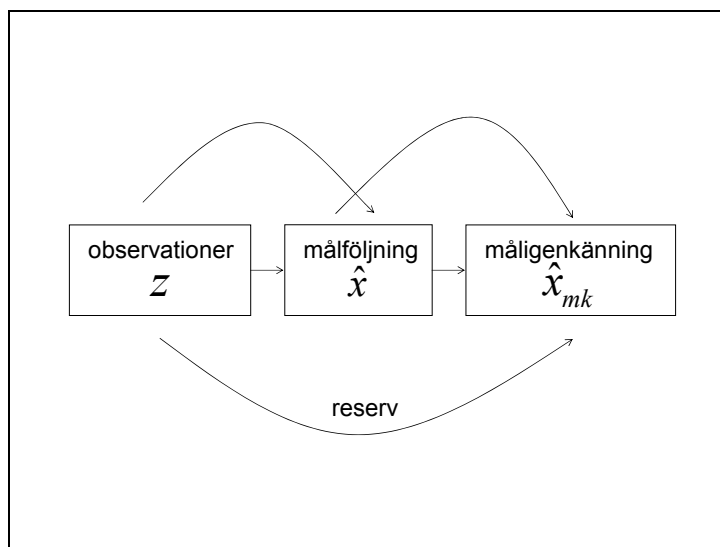


Figur 1. Två alternativ kan uppstå då två mål närmar sig varandra. Mål gör antingen en sväng utan att korsa varandras vägar (a) eller korsar varandras vägar (b).

Förlorade observationer

I vissa situationer får inte modellen för målföljning nya observationer. Till att börja med fortsätter målföljningen och \hat{x}_{K+1} antas vara lika med \hat{x}_K inklusive tidsuppdatering. Till slut kommer dock målsparret att tas bort eftersom osäkerheten om målets verkliga tillstånd blir för stor. För måligenkänning är målföljningsdata att föredra framför observationer, eftersom målföljningsdata finns även då enstaka observationer uteblir. Målföljningsdata ger dessutom en bättre skattning av målets tillstånd \hat{x} . En direkt koppling mellan observationer och skattning av målets klass \hat{x}_{mk} skulle dock vara användbar i de fall då målföljningen fallerar

trots att observationer finns tillgängliga, se figur 2. För modellen för måligenkänning utgör i sådana fall observationer en reserv.



Figur 2. En direkt koppling mellan observationer och modell för måligenkänning är användbar då modellen för målföljning fallerar, trots att observationer finns tillgängliga

Ett mål som följs kan under korta perioder, av någon anledning, försvinna ur radarbilden för att sedan återkomma. Även om det är trivialt att det är samma mål som sensorn ser, kommer modellen för måligenkänning att registrera målet som nytt. Om modellen bygger på sekvenser av observationer blir följden att det tar en viss tid innan \hat{x}_{mk} åter kan skattas. Information om målets beteende går därmed förlorad under en viss tid.

1.4 Måligenkänning och sensorstyrning

Avsnitt nämner något om kopplingen mellan måligenkänning och sensorstyrning, vilka hör till nivåerna 2 respektive 5 i JDL-modellen. Sensorstyrning kan ses som en process som tydliggör den pågående datafusionsprocessen. Sensorstyrning möjliggör därmed en analys av resultatet från datafusionen. Är resultatet inte tillfredsställande enligt något mått kan en anpassning ske i syfte att förbättra resultatet i ett nästa steg.

Sensorstyrningen blir ett medel för att uppnå förbättrad skattning av målets position, hastighet, klass samt situationsbestämning och/eller hotanalys.

Sensorstyrning sker på olika nivåer i ett system av sensorer. På en lägre systemnivå baseras sensorstyrning på resultat från signalbehandling. Syftet är bland annat att erhålla lämpliga sensorparametrar för att reducera inverkan av klotter. På en högre systemnivå baseras sensorstyrning ofta på prioritering av mål, enligt något kriterium. Det senare fallet diskuteras nedan.

Olika typer av faktorer kan ligga till grund för prioritering av mål inför sensorstyrning. Nedan ges exempel på tre sådana faktorer, nämligen måligenkänning, informationsbehov och hotanalys [12].

Måligenkänning

Ett naturligt sätt att prioritera är efter måligenkänning, på någon nivå (natur, klass eller typ). De mål som anses kunna bli hotfulla inom en viss tidsrymd får en hög prioritering. Till dessa mål ägnas merparten av sensorkapaciteten. Mål som inte anses kunna bli hotfulla får en lägre prioritet och tillgång till en mindre mängd sensorresurser.

Informationsbehov

I en pågående fusionsprocess är syftet att skatta målets position och klass så att resultatet hamnar på en viss förutbestämd och acceptabel osäkerhetsnivå. Vid en given tidpunkt, allteftersom fusionsprocessen fortskrider, kommer några mål att kunna skattas med en rimlig osäkerhet. Vid samma tidpunkt kommer andra mål att vara mindre kända, d v s deras skattning har för stor osäkerhet. En lösning är att prioritera de mål som har för stora osäkerheter i skattningarna. Till dessa mål ägnas merparten av sensorkapaciteten i syfte att reducera osäkerheten i skattningarna.

Hotnivå

Vissa mål anses vara mer hotfulla för den egna plattformen än andra. Ett annat kriterium för prioritering är utgående från det hot målet utgör vid en viss tidpunkt. Hotnivån är en funktion av målets klass, hastighet, position och räckvidd hos de vapen som antas vara ombord på det mål som observeras.

I avsnitt 6 diskuteras vilka parametrar från kinematisk måligenkänning som kan användas för att prioritera mål.

1.5 Datafusionsnoden (DF)

I DF finns bl. a. modeller för målföljning och sensorstyrning [19]. Dessutom utvecklas metoder för samverkan mellan flera DF [21]. Det blir då möjligt att studera hur plattformar kan samverka med varandra i nätverk angående sensorstyrning och utbyte av information.

I ett nätverk kan en plattform initiera tjänster där sensorer, inte bara på den egna plattformen, utan också på andra plattformar inom nätverket kan utnyttjas. Det blir därmed möjligt att utnyttja knappa resurser, såsom information, arbetskraft och sensorer, på ett mer effektivt sätt.

Information om ett måls klass, som skattats av en specifik plattform, kan också vara av intresse för andra plattformar. En plattform kan be om hjälp från andra plattformar att få information om klassen hos ett visst mål.

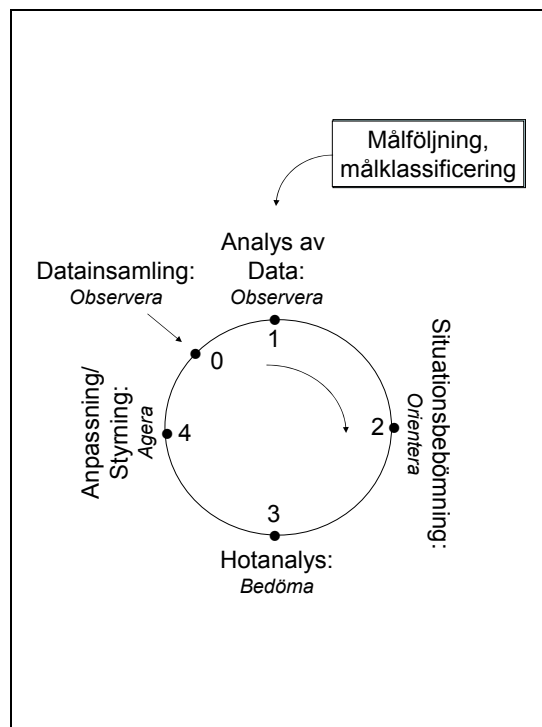
I DF finns modeller för ESA radar (Electronically Scanned Antenna) ochIRST-sensor. En ESA radar skiljer sig från en traditionellt mekaniskt styrd radar med att den är mycket flexibel i sitt arbetssätt. Den byter riktning utan tröghet och på mycket kort tid. Den kan dessutom arbeta med flera uppgifter parallellt.

1.5.1 OODA-loopen i DF

OODA-loopen är ursprungligen en modell för mänskligt tänkande och beslutsfattande [13]. Den fungerar som en standardbeskrivning för den mentala beslutsstöds-cykeln i samverkan med en omgivning. OODA-loopen består av processerna *observera* (Observe), *orientera* (Orient), *bedöma* (Decide) och *agera* (Act). Processerna är kopplade till varandra i ett roterande flöde.

I exempelvis militära sammanhang är det viktigt att flödet roterar så snabbt som möjligt. Ett snabbt roterande flöde innebär att beslut fattas på kort tid. Målet är att ha en OODA-loop som roterar snabbare än motståndarens motsvarande OODA-loop. Ett sätt att få flödet att gå snabbare är att i delar av OODA-loopen introducera datafusion och låta resultat från datafusionen utgöra beslutsstöd.

I DF har OODA-loopen applicerats på JDL-modellen. JDL-modellen beskriver olika steg i datafusionsprocessen. En sammanslagning av OODA-loopen och JDL-modellen visas i figur 3. Processen *observera* innefattar datainsamling och analys av data. *Orientera* motsvaras av situationsbestämning. *Bedöma* motsvaras av hotanalys och slutligen *agera* motsvaras av anpassning och styrning.



Figur 3. OODA-loopen har i DF applicerats på JDL-modellens datafusionsnivåer.

Olika OODA-loopar används för olika uppgifter, såsom spaning, navigering, störning och kommunikation. En DF kan ha olika loopar i drift parallellt. En operatör kan därmed arbeta med flera loopar samtidigt. Looparna kan också vara nästlade i varandra, vilket innebär att resultatet av en process i en loop utnyttjas även av andra loopar, på egen eller annan plattform. En loop som existerar på en plattform kan behöva utnyttja sensorer på andra plattformar. I DF sker samverkan mellan plattformar i form av *tjänster* [4].

1.5.2 Algoritmer för målföljning i DF

I DF används algoritmen GNN (Global Nearest Neighbour) för dataassociation. Målspårets förväntade läget vid nästa tidpunkt skattas med Kalman-filter.

Förmågan hos målföljningsmodellen att följa manövrerande mål har betydelse för vilka rörelsemönster som kan beskrivas i en modell för kinematisk måligenkänning. I DF tillämpas IMM (Interacting Multiple Models) [6]. IMM kombinerar tillståndsvektorer och kovariansmatriser för två eller flera rörelsemodeller enligt en observerbar Markovmodell.

Markovmodellen beskriver övergångar mellan målets manövertillstånd. I DF består IMM av två rörelsemodeller, en för rakbana och en för sväng.

1.5.3 Sensorstyrning i DF

En ESA-sensor kan samtidigt arbeta med flera funktioner, som exempelvis sökning, uppdatering av målspar, störning och kommunikation. I DF finns en algoritm för schemaläggning av funktioner ([18], [19]). Algoritmen tilldelar varje funktion ett tidsintervall inom vilket ESA-radarn används för den specifika funktionen.

1.5.4 Nätverkstjänster i DF

Begreppet tjänst kan för en plattform indelas i tjänster för perception, situationsbedömning, prediktion och styrning/anpassning [4]. Tjänsterna har alltså en tydlig koppling till OODA-loopen och JDL-modellen.

Måligenkänning utgör ofta en viktig del i var och en av nätverkstjänsterna. För tjänsten *situationsbedömning* är en uppgift att informera om målets tillstånd. Tillståndet kan delvis beskrivas med måligenkänning, speciellt måligenkänning som baseras på dynamiska kännetecken. Dynamiska kännetecken är exempelvis variationer i elektromagnetisk emission och variationer i beteende.

För tjänsten *prediktion* är en uppgift att informera om hotnivån hos mål. Måligenkänning kan bidra till hotanalys tillsammans med information om bl. a. antagna vapens räckvidd. Om måligenkänningen indikerar civilt transportuppdrag så minskar målets hotnivå. Om måligenkänningen indikerar jaktuppdrag så ökar målets hotnivå.

För tjänsten *styrning/anpassning* finns ofta en situationsbedömning och/eller en hotanalys till grund. Styrning och anpassning kan exempelvis innebära att varna för ett visst mål, ändra planer för viss plattform eller utnyttjandet av sensorer.

En tjänst utnyttjar en eller flera OODA-loopar för att kunna utföra sin uppgift.

2. Dolda Markovmodeller (HMM) – uppdragsigenkänning

2.1. Teori för HMM och beräkning av trolighet

Avsnittet ger en kortfattad matematisk beskrivning av diskreta dolda Markovmodeller av första ordningen (HMM). Beskrivningen är baserad på [17] och för en noggrannare studie av teorin hänvisas till samma referens. Avsnitt 2.2 ger en beskrivning av hur HMM har tillämpats på fallet med uppdragsigenkänning.

Teorin för HMM presenterades på 1960-talet och har, sedan dess, använts för mönsterigenkänning inom en rad olika områden. Några av dessa är taligenkänning, textigenkänning och igenkänning av strukturer hos molekyler, se exempelvis [23], [8], [11] och [14]. I [5] har HMM använts för igenkänning av militära truppformeringar. I [3] har HMM använts för beskrivning av elektromagnetisk emission i syfte att kunna identifiera flygande mål.

Att modellen är av första ordningen innebär att systemets tillstånd vid tidpunkten $t + 1$ *predikteras* med hänsyn endast till tidpunkten t . Att modellen är diskret innebär att observationer av systemet kommer vid diskreta tidpunkter.

En diskret HMM av första ordningen, λ , definieras av ett antal tillstånd N och observationssymboler M . Tillstånden betecknas $S = \{S_1, S_2, \dots, S_N\}$ och observationssymbolerna betecknas $V = \{v_1, v_2, \dots, v_m\}$. Modellen λ beskrivs med följande parametrar:

$$\begin{aligned}\lambda &= (A, B, \pi) \\ A &= \{a_{ij}\} = \{P[q_{t+1} = S_j \mid q_t = S_i]\} \\ B &= \{b_j(k)\} = \{P[O_t = v_k \mid q_t = S_j]\} \\ \pi &= \{\pi_i\} = \{P[q_1 = S_i]\} \\ &1 \leq i, j \leq N \\ &1 \leq k \leq M\end{aligned}$$

Sannolikheter för tillståndsövergångar ges av matrisen A , där a_{ij} är sannolikheten att ett system vid viss tidpunkt bytt från tillstånd i till j . Sannolikhetsfördelningar för observationssymbolerna v_k ges av matrisen B . Sannolikheten för att systemet uppvisar symbolen v_k under förutsättning att det befinner sig i tillstånd S_j , ges av $b_j(k)$. Systemets nuvarande tillstånd är q_t och den aktuella observationen är O_t . Sannolikhetsfördelningen för tillstånden initialt, d v s då $t = 1$, ges av π .

I ett igenkänningsproblem beräknas troligheten L_n , för ett visst O , för alla n modeller λ_n . Det λ_n som har det högsta L -värdet antas vara det system man söker. Följande ekvation beskriver troligheten L_n för observationssekvensen O , givet modellen λ_n :

$$L_n = P(O \mid \lambda_n)$$

där O består av observationer från systemet registrerade vid T tidpunkter, d v s

$$O = (O_1 O_2 \dots O_T).$$

För att beräkna L_n introduceras den s.k. forward-variabeln $\alpha_t(i)$ enligt följande:

$$\alpha_t(i) = P(O_1 O_2 \dots O_t, q_t = S_i \mid \lambda_n).$$

Forward-variabeln beskriver sannolikheten för att observera den partiella observationssekvensen $O_1 O_2 \dots O_t$ i tillstånd S_i vid tidpunkt t , givet modellen λ_n . För den första observationen O_1 beräknas $\alpha_1(i)$ enligt:

$$\alpha_1(i) = \pi_i b_i(O_1).$$

För följande observationer beräknas $\alpha_{t+1}(j)$ enligt följande:

$$\alpha_{t+1}(j) = \left[\sum_{i=1}^N \alpha_t(i) a_{ij} \right] b_j(O_{t+1})$$

där $1 \leq t \leq T-1$. Ekvationen beskriver hur S_j kan nås vid tidpunkten $t+1$ från de N möjliga tillstånden vid tidpunkten t . Beräkningen genomförs för alla tillstånd j vid tidpunkten t . Beräkningen itereras för $t = 1, 2, \dots, T-1$. Det slutliga resultatet ges av summan av forward-variablerna för de olika tillstånden vid den slutliga tidpunkten T , dvs

$$P(O | \lambda) = \sum_{i=1}^N \alpha_T(i).$$

Under beräkningens gång sker vid ett flertal tillfällen multiplikationer med tal som ligger långt under 1, vilket leder till att det slutliga resultatet kommer att ligga mycket nära noll. Problem uppstår då resultatet är mindre än det minsta tal som datorn kan representera. I [17] löses problemet genom att introducera skalfaktorn c_t :

$$c_t = \frac{1}{\left(\sum_{i=1}^N \alpha_t(i) \right)}.$$

Den slutliga ekvationen, som då blir användbar för detta problem, ser ut som följer:

$$\log[P(O | \lambda)] = - \sum_{t=1}^T \log c_t.$$

2.2. Tillämpning på problemet för uppdragsigenkänning

2.2.1. Beskrivning av uppdragens typiska rörelsemönster

Uppdragen som beskrivs här är jakt, attack, spaning och transport. Dessutom har allmänflyg tagits med som en form av uppdrag. Med allmänflyg menas civil luftfart utom tung trafik- och charterflyg. Uppdragsigenkänning har likheter med måligenkänning av klasser av flygplan (se avsnitt 1.2.1.). Skillnaden är att målet vid uppdragsigenkänning inte nödvändigtvis behöver vara knutet till en viss klass av flygplan utan skulle kunna tillhöra en annan, för uppdraget icke-traditionell, klass. Nedan följer en beskrivning av hur uppdragen jakt, attack, spaning, transport och allmänflyg kan tänkas utmärka sig i rörelsemönster. För jakt- och attackuppdragen har information hämtats från [15], som beskriver svenska förhållanden. Skillnader finns sannolikt för andra nationers jakt- och attackflyg. Syftet med beskrivningen är att i grova drag visa att där finns skillnader mellan olika uppdrags rörelsemönster.

Jaktuppdrag

Jaktflyget har till uppgift att skydda ett territorium mot hot från luften. Jaktuppdragets genomförande följer ett visst mönster som ibland kallas jaktcykeln. Jaktcykeln karakteriseras av ett snabbt förlopp. Direkt efter start påbörjas flygning mot det område där målet finns. Väl framme i det aktuella området sker en inflygning mot målet. Flygföraren skjuter på långt avstånd och med hög fart för att snabbt kunna flyga därifrån.

Attackuppdrag

Attackflyget har till uppgift att anfälla fientliga mål till sjöss och på marken. Attackuppdraget genomförs på mycket låg höjd, med syftet att undgå upptäckt av fiendens radar. Över havsytan kan det i vissa fall innebära en flyghöjd på mindre än 20 meter. För en plattform

som utför spaning mot attackflygplanen blir dessa osynliga om de lyckas gömma sig på sin mycket låga flyghöjd.

Till att börja med flyger flygplanen med relativt låg fart. Då de närmar sig målet ökas farten. Anfallet kan genomföras på olika sätt. Ett alternativ är det s.k. dykanfallet. På ett avstånd av knappt 10 km från målet görs en kraftig upptagning till 300-500 meter. Flygplanet dyker sedan i flack vinkel mot målet. I vissa fall är väderförhållandena sådana att upptagning inte kan ske till tillräcklig höjd. Då kan attacken ske med ett s.k. plananfall. Ett sådant anfall genomförs i planflykt, på rakbana eller i sväng. Flygplanen som genomför jakt- och attackuppdrag är ofta små och lätta flygplan och har god manövreringsförmåga till skillnad från stora transportflygplan.

Spaningsuppdrag

Spaningsflygets taktiska uppträdande har ibland stora likheter med attackflygets uppträdande. Flygplanen flyger ofta med hög fart och på mycket låg höjd för att undvika upptäckt av fiendens radar. Spaning kan också utföras på mycket hög höjd. Vilken höjd som tillämpas beror på spaningsuppdraget. Spaning på låg höjd ger en detaljerad bild över ett mindre område. Spaning på hög höjd ger en mindre detaljerad bild, men en överblick av ett större område.

Transport

Stora transportflygplan flyger i regel i en marschfart som är lägre än den maxfart små militära flygplan kan hålla. Civila transportflygplan flyger inom fördefinierade luftleder. Sträckor som exempelvis Arlanda - Köpenhamn är mycket vältrafikerade av civila transportflygplan. Det militära transportflygets uppgifter är att transportera människor och materiel mellan olika platser i landet. Dessa platser är sannolikt knutna till militär verksamhet. Vanligtvis genomförs transportuppdraget med större och tyngre flygplan, vilka inte har lika god manövreringsförmåga som traditionella jakt- och attackflygplan.

Allmänflyg


Med allmänflyg menas civil luftfart utom tung trafik- och charterflyg. Allmänflyg består av, förutom sportflyg med exempelvis flygplanstyper som Piper och Cessna, även skolflyg, fotoflyg, rundflyg och annat privatflyg. Det mest karakteristiska för åtminstone sportflyg är förmodligen låg höjd och låg fart.

Med HMM är det möjligt att beskriva rörelsemönster baserat på fart, höjd och riktning. Det är *kombinationen* av fart, höjd och riktning och hur dessa ändrar sig över tiden, som kan associeras till ett visst uppdrag. Varje uppdrag, eller system, beskrivs av en modell λ_n . Modellen har en specifik uppsättning sannolikhetsfördelningar för tillståndsövergångar A , observationer B och initiala tillstånd π .

Rörelsemönstret skulle kunna observeras från och med start, via genomfört uppdrag, till och med landning. I de flesta fall observeras inte hela uppdraget utan endast en del.

Beskrivningen av rörelsemönster kan indelas i tre nivåer, se figur 4. Nivå 1 är den högsta och mest generella nivån och motsvarar själva uppdraget. Uppdraget representeras av λ_n . Nivå 2 motsvarar delar av ett uppdrag. En del kan till exempel vara att ett anfall *är* på gång att ske eller att ett anfall *inte är* på gång att ske. Enskilda delar representeras av begreppet tillstånd

S_i . Nivå 3 motsvarar observationer från uppdraget, d v s målets fart, höjd och riktning. Observationer representeras av O_t .

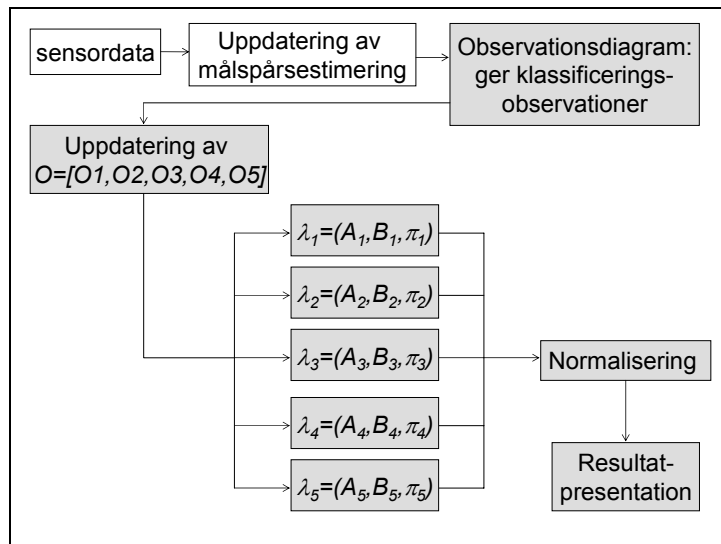


Figur 4. Indelning av rörelsemönstret i uppdrag, tillstånd och observationer

Igenkänning görs i direkt anslutning till skattningen av målsparat. Skattningen av målsparat ger värden för bl.a fart, höjd och riktning. En observation för måligenkänning O_t skapas med hjälp av ett s.k. observationsdiagram. Observationsdiagrammet sammanför enskilda observationer som fart, höjd och riktning till *en* observationssymbol O_t . Då en sekvens O av observationssymboler har skapats görs en skattning av målets uppdrag. Troligheten L för O skattas för vart och ett av $\lambda_1 - \lambda_5$, där $\lambda_1 =$ transport, $\lambda_2 =$ allmänflyg, $\lambda_3 =$ spaning, $\lambda_4 =$ jakt och $\lambda_5 =$ attack.

Slutligen sker en normalisering av troligheter för olika uppdrag ($L_1 - L_5$) för att lättare kunna jämföra resultaten med varandra. Resultatet beskriver därmed en fördelning av troligheter över de fem uppdragen, givet O . Figur 5 beskriver proceduren för måligenkänning från och med sensordata till och med det slutliga resultatet.

Hur ofta ska målets uppdrag skattas? Tidsintervallet för skattning bör vara detsamma som det tidsintervall som ligger till grund för parametrar A , B och π . Sannolikheten för byte av tillstånd a_{ij} baseras på ett visst tidsintervall som i sin tur är kopplat till det rörelsemönster som målet väntas kunna uppvisa. Om avsteg görs från detta tidsintervall kommer λ_n inte längre att beskriva det rörelsemönster som ges av det nya tidsintervallet. Önskas avsteg från ett tidsintervall är alternativet att ha en mängd uppsättningar $\lambda_{n\Delta t_x}$ av samma system, där varje $\lambda_{n\Delta t_x}$ beskriver ett visst tidsintervall Δt_x .



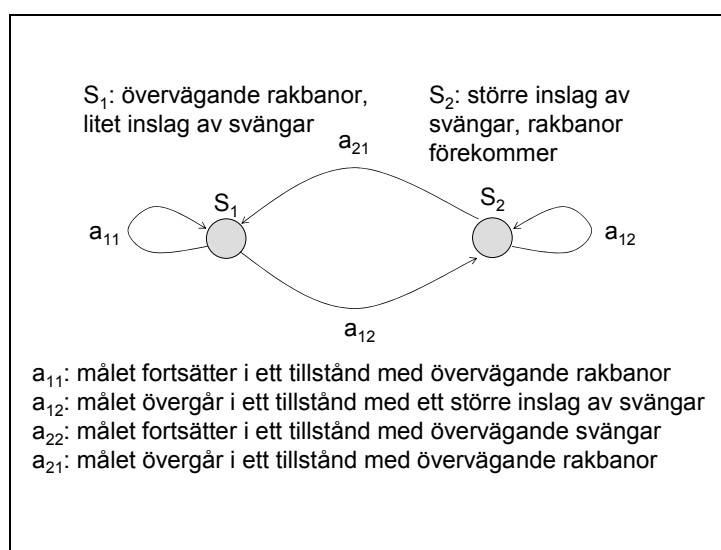
Figur 5. Modellens komponenter (gråtonade) och deras relationer till varandra och omgivning.

2.2.2. Tillstånd

Ett uppdrag består här av två tillstånd, S_1 och S_2 , se figur 6. Tillståndet S_1 motsvarar en blandning av rakbana och sväng, där inslaget av *rakbana* dominerar över inslaget av sväng. Tillståndet beskrivs också som ”regelbunden” flygning.

Tillstånd S_2 motsvaras också av en blandning av rakbana och sväng, men här dominerar inslaget av *sväng* över inslaget av rakbana. Tillståndet beskrivs också som ”oregelbunden” flygning.

S_2 är ett typiskt tillstånd i samband med själva anfallet eller jakten och S_1 antas vara allt annat som inte är S_2 . Det rörelsemönster som i allmänhet är karakteristiskt för start och landning antas bestå av mindre tvära rörelser med relativt få svängar jämfört med jakt- och attackprocesserna. Rörelsemönstret för start och landning innefattas därmed i tillstånd S_1 .



Figur 6. Markovmodell för flyguppdrag.


2.2.3. Observationer

Då en observation erhålls är det okänt från vilket av de två tillstånden observationen kommer. En enskilda observationer för fart, höjd och riktning skulle kunna komma från såväl en inflygning mot en flygplats som en inledning till en attack. Observationen är observerbar medan tillståndet är dolt.

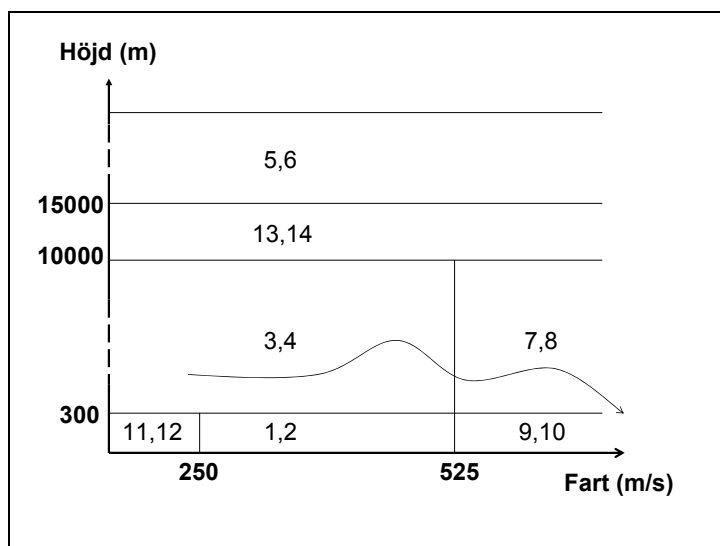
Observationer är, som tidigare nämnts, fart, höjd och riktning. Om hastighetsvektorerna är desamma som vid föregående observation så befinner sig målet på en rakbana. Denna rakbana har i tid varat åtminstone den tid som motsvarar tidsintervallet mellan två observationer. Om målet har en fart på 950 km/h och tiden mellan två observationer är 1 sekund, så förflyttar sig målet en raksträcka på ca 260 meter. Denna sträcka motsvarar den kortaste raksträcka som kan avbildas i HMM.

Observationsdiagrammet utgör en länk mellan målföljning och måligenkänning. Figur 7a visar hur observationsdiagrammet är uppbyggt. X- och y-axeln representerar fart respektive höjd. Observationsdiagrammet är indelat i områden där varje område benämns med två siffror. Den lägre siffran betyder att målet har en fart och en höjd någonstans inom angivna intervaller samt att det rör sig i rak riktning, jämfört med föregående observation. Den högre siffran betyder att målet rör sig inom samma höjd- och fartintervall men att det byter riktning.

Fart- och höjdintervaller väljs så att olika uppdrag ska kunna särskiljas i modellen [10]. Höga farter är vanliga i jakt- attack- och vissa spaningsuppdrag. Mycket låga höjder kan vara typiska för spanings- och attackuppdrag, men också för allmänflyg. Återkommande riktningbyten inom korta tidsperioder är typiska för jakt- och attackuppdrag. Civila trafikflygplan byter riktning mer sällan. För de simuleringar som presenteras i avsnitt 3.3 gäller de värden för fart- och höjdintervaller som redovisas i figur 7b. Värdena är sannolikt inte optimalt valda. Syftet är att med simuleringarna visa hur modellen fungerar i princip.



Figur 7a. Ett exempel på hur ett observationsdiagram kan vara uppbyggt.



Figur 7b. Observationsdiagram med exempel på värden för fart- och höjdintervallen.

En observationssekvens kan se ut som följer:

$$O = [O1 O2 O3 O4 O5] = [4 4 3 3 7]$$

Den äldsta och femte observationen i sekvensen, $O5 = 7$, innebär att målet har en fart som överstiger 525 m/s. Målet flyger på en höjd någonstans mellan 300 och 10 000 m i en rakt bana. $O4 = 3$ indikerar att målet har minskat farten till någonstans mellan 0 och 525 m/s. Det är fortfarande kvar på samma höjd och har inte ändrat riktning. $O2 = 4$ indikerar att målet har ändrat sin riktning men har samma höjd- och fartintervall. $O1 = 4$, alltså den senaste observationen, indikerar att målet har ändrat sin riktning igen. Då en ny observation erhålls flyttas observationerna ett steg åt höger.

2.2.4. Inläring av HMM

Modellparametrarna för HMM har tagits fram med hjälp av inläring. Inläringen är baserad på artificiella data och har genomförts enligt Viterbis algoritm [17] i Matlab. Varje uppdrag har givits ett antal observationssekvenser som både är typiska och mindre typiska för uppdraget. Syftet har varit att lyfta fram för uppdraget typiska rörelsemönster, men också att mindre typiska uppföranden ska finnas närvarande. Rörelsemönstret är baserat på ett tidsintervall mellan observationer på 1 sekund.

Inläring kan ske enligt åtminstone två strategier. En strategi är att låta λ lära sig hur ett uppdrag ser ut i mer generella termer. En annan strategi är att låta λ koncentrera sig på det beteende som är typiskt för det aktuella uppdraget. I det senare fallet uppstår en form av överinläring. Vilken strategi som väljs har betydelse för vilka resultat λ kommer att ge. Det har också betydelse för vilket ”minne” λ kommer att få. Typiska beteenden kommer att ha stor genomslagskraft för överinlärd λ . Å andra sidan kommer λ inte att minnas det typiska beteendet då målet börjar bete sig mer normalt igen. Informationen om ett typiskt beteende kan alltså försvinna relativt snabbt.

Typiska beteenden kommer att ha *mindre* genomslagskraft för mer generellt inlärd λ . Troligheten för typiska beteenden blir alltså inte lika stor med generella λ . Å andra sidan kommer λ att minnas det typiska beteendet något längre. Informationen finns ofta kvar, mer eller mindre, så länge observationen för det typiska beteendet finns kvar i

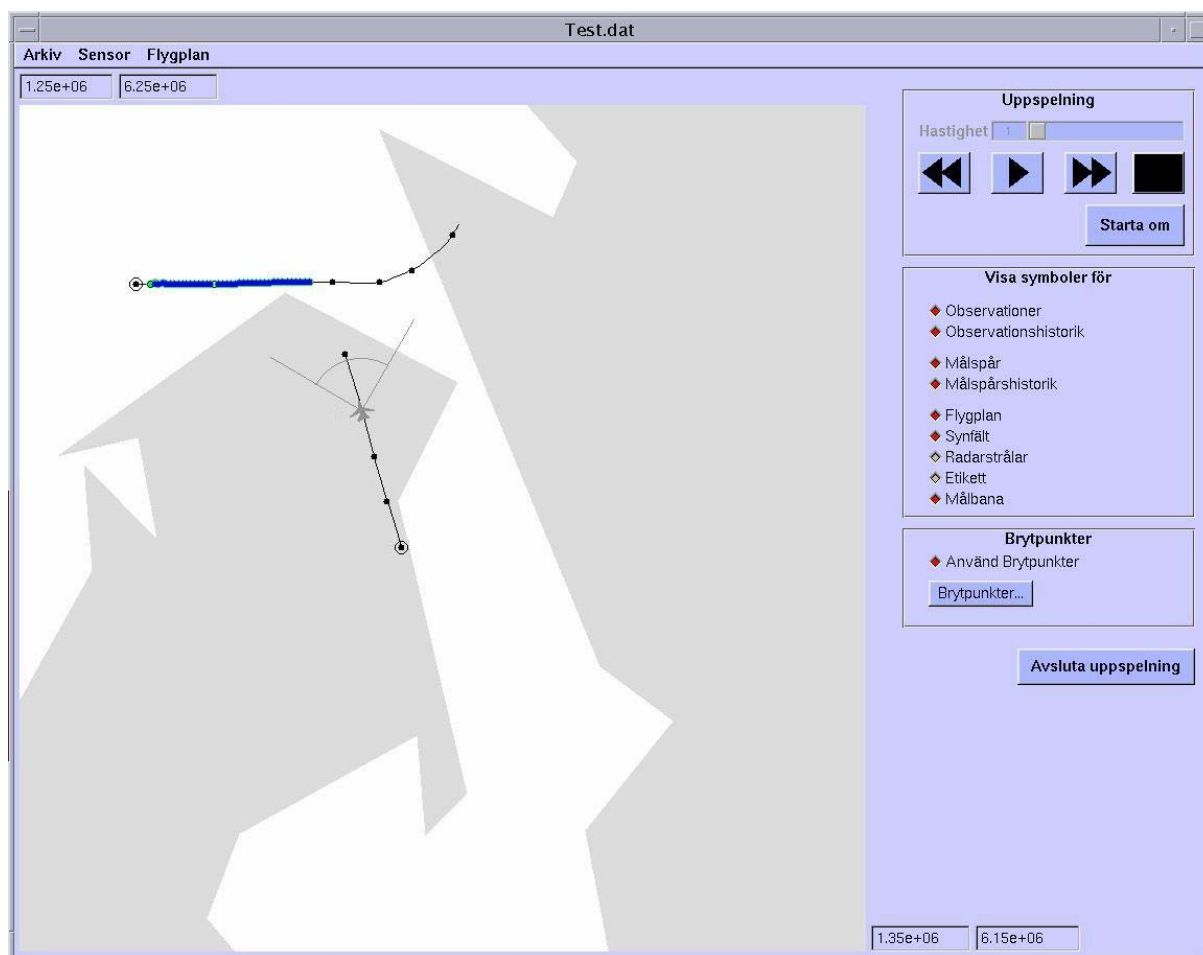
observationssekvensen. Modellparametrarna som användes för $\lambda_1 - \lambda_5$ i simuleringarna nedan redovisas i Bilaga 1. Vid inlärning valdes att lära λ beskriva mer generella beteenden vilket också leder till att λ får något längre minne.

2.3. Simuleringar och resultat

2.3.1. Simuleringar i DF

Simuleringar initieras genom att flygbanor för egen plattform respektive mål definieras. Detta görs genom att bestämma läget för ett antal brytpunkter i respektive bana. Brytpunkterna läggs ut i en karta i ett grafiskt gränssnitt, se figur 8. I gränssnittet förses den egna plattformen med olika typer av sensorer. Scenariots uppspelning hanteras med ”bandspelarknappar”.

Till varje egen plattform hör en operatör. För operatören öppnas ett annat grafiskt gränssnitt, se figur 9. Här finns en traditionell taktisk indikator, med den egna plattformens position centrerad. Målets och plattformens banor, såväl som radarsensorns minsta garanterade täckningsområde, är markerade. Längst upp till höger i figur 9 finns en display speciellt för radarsensorns räckvidd.



Figur 8. Scenariogränssnitt i DF. Banor för mål och plattform är markerade, liksom även radarsensorns synfältsriktning. De blå prickarna anger målsparrets position vid varje tidpunkt.

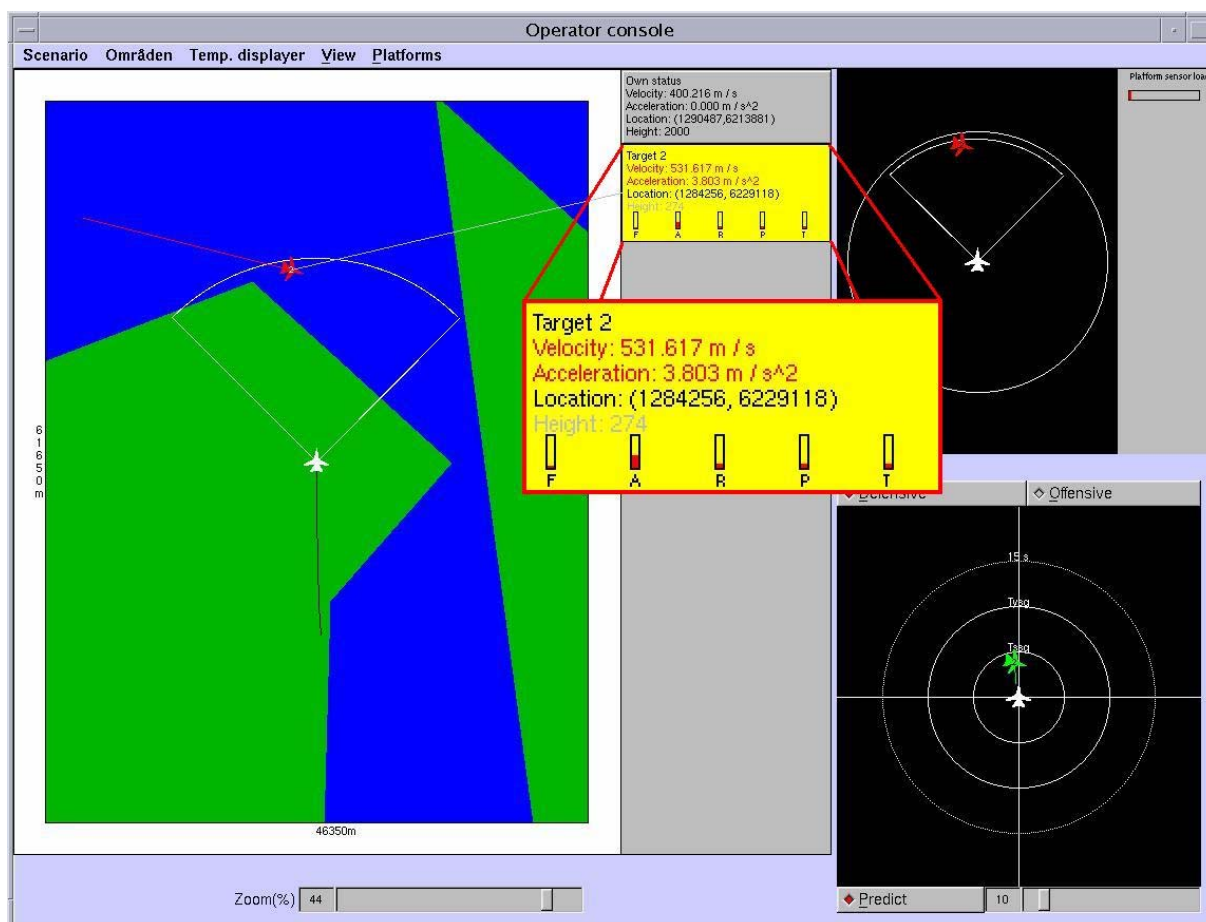
Längst ned till höger i figur 9 finns också en s.k. temporal hotdisplay [19]. Den temporala hotdisplayen används för att värdera målen angående vilket hot de utgör mot egen plattform. I hotdisplayen är tid en grundläggande dimension, till skillnad från taktisk indikator som har

avstånd som grundläggande dimension. Det är tiden för handling som presenteras. Tiden för handling ges av fusion av positioner, hastigheter, plattformskaraktäristiska och räckvidd hos vapen.

Scenario 1


Kartan i figur 8 visar banor för mål respektive egen plattform i det första scenariet. De blå prickarna anger skattningen för målets position i varje tidpunkt. Figur 9 visar operatörsgränssnittet vid tidpunkten 40 sekunder efter att målet först har observerats. Resultatet presenteras med staplar, där bokstaven under varje stapel representerar den engelska översättningen av uppdragen (dvs. fight, attack, reconnaissance, general aviation, transport). De logaritmerade troligheterna har normaliserats, så att summan av troligheterna för de fem uppdragen är lika med ett. Staplarnas höjd kan tolkas som procentsatser.

Figureerna 10 och 11 visar målets höjd- och fartprofil under den tid målet observerats. Uppdraget är tänkt att vara ett attackuppdrag. Målet flyger på en låg höjd och vid ett tillfälle sker en uppstigning och därefter sjunker målet igen. Farten hålls konstant till en början. Sedan ökar farten för att därefter åter hållas konstant.

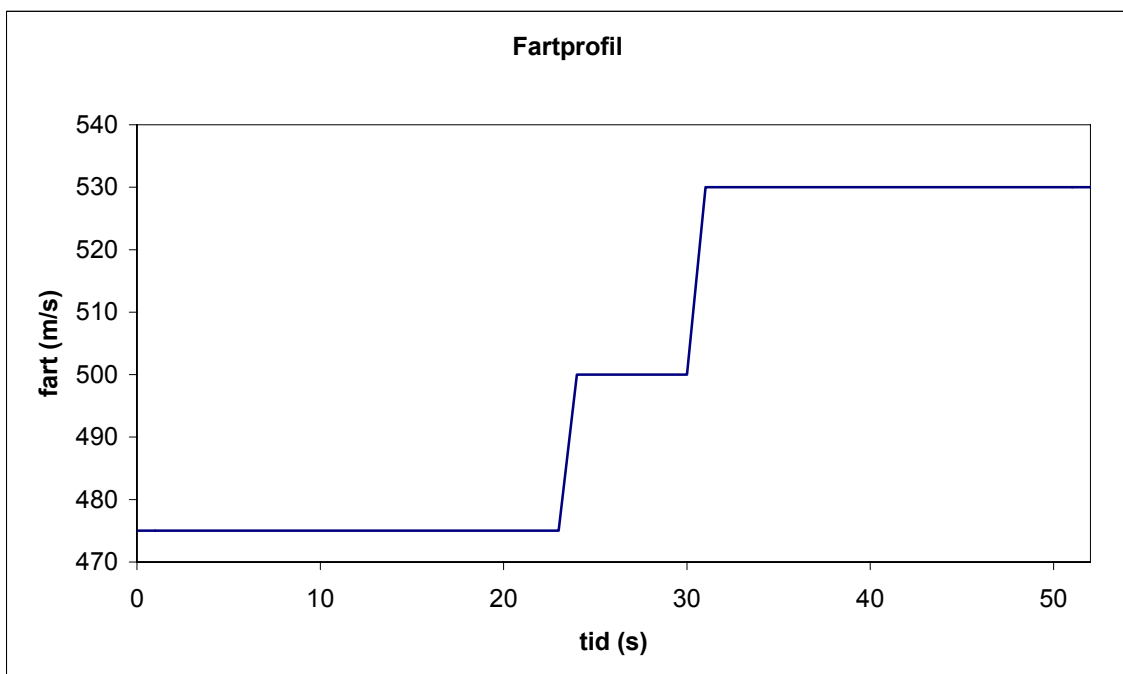


Figur 9. Operatörsgränssnitt i DF. Målets och plattformens banor vid ca 40 sekunder efter upptäckt är markerade, liksom sensorns minsta täckningsområde. En sensordisplay och en temporal hotdisplay har infogats i gränssnittet. Resultatet av uppdragsigenkänningen har förstörats.

Figur 12 visar hur skattningen av uppdrag varierar över tiden. Eftersom 5 observationer krävs för att göra en beräkning fås den första skattningen efter 5 sekunder. Mellan 5 och 10 sekunder är spaningsuppdrag det mest troliga. Mellan 10 och 34 sekunder är jaktuppdraget det mest troliga. Efter 34 sekunder dominerar attackuppdraget.



Figur 10. Höjdprofil för målets bana i scenario 1.



Figur 11. Fartprofil för målets bana i scenario 1.





Fig 12. Resultat för skattning av uppdrag i scenario 1.

Scenario 2

Målet rör sig med konstant fart på höjden 11 000 meter. Banan är tänkt att motsvara en luftled för civil transport. Under den tid målet observeras är transportuppdraget det mest troliga. Troligheten är som störst då målet rör sig i rakbana. Troligheten sjunker något då målet byter riktning. Resultatet presenteras i figur 13. Några ytterligare exempel på simuleringar ges i [1].



Figur 13. Resultat för skattning av uppdrag i scenario 2.

2.3.2. Några olika sätt för resultatpresentation

Det finns en mängd olika sätt på vilka resultat kan presenteras. Ett sätt är att för varje mål redovisa alla troligheter. Med många mål blir mängden information stor. Ett annat sätt är att för varje mål presentera endast det mest troliga alternativet (alternativt de två mest troliga alternativen). På så sätt reduceras mängden information något.

Referens [7] föreslår en presentationsmetodik som baseras på tröskelvärden för olika nivåer av igenkänning. Metodiken innehåller följande steg:

1. Om troligheten för målet överstiger tröskelvärdet T_{natur} kan målet åtminstone skattas som neutral, vän, fiende eller okänd. Om troligheten ligger under T_{natur} anses målet vara oidentifierat.
2. Om T_{natur} kan överskridas provas troligheten för nivån T_{klass} . Om troligheten överskrider T_{klass} skattas målet som t ex jakt-, attack- eller spaningsflygplan. Om troligheten underskrider T_{klass} skattas målet med dess natur.
3. På samma sätt provas troligheten för nivån T_{typ} .

I [16] inkluderas begreppet konfidens, d v s tillförsikt och tilltro, till resultatet. Ett konfidensintervall anger ett intervall inom vilket rätt värde finns med förutbestämd sannolikhet. På så vis kan tillförlitligheten för resultatet uppskattas. I [16] beskrivs även en algoritm för rangordning av resultat baserat på konfidensintervallen. Genom att introducera begreppet entropi (från informationsteori) kan resultat från olika nivåer av igenkänning rangordnas och jämföras. Ett resultat från nivå *klass* kan exempelvis jämföras med ett resultat från nivå *natur*.

2.4. Osäkerheter baserade på val av modellparametrar

Vilka modellparametrar som väljs för λ_1 till λ_5 har betydelse för vilka resultat som modellerna kommer att ge. Hur väl beskriver modellen verkligheten? Modellens struktur och parametrarnas värden är en förenkling av verkligheten. Med det följer att modellen innehåller osäkerheter.

Modellparametrar som kan varieras är dels N och M, dels A, B och π . De två första parametrarna är kopplade till någon form av struktur hos uppdraget. Om inlärning tillämpas bestäms de tre sistnämnda parametrarna till stor del av inlärningsdata.

Val av parametrar har också stor inverkan på hur längre modellen minns ett extremt och kortvarigt uppförande (vilket har diskuterats tidigare).

Bättre minne kan möjligen erhållas med en HMM av högre ordning. En HMM av första ordningen tar hänsyn till tidpunkt t då skattning görs för tidpunkt $t+1$. En sådan modell ger en liten mängd ekvationer vilket leder till korta beräkningstider. En HMM av andra ordningen tar hänsyn även till tidpunkten $t-1$ då beräkning görs för tidpunkten $t+1$. En sådan modell kan vara ett alternativ då det gäller att försöka behålla information om en tidigare händelse. En nackdel med modeller av högre ordning är att det blir fler modellparametrar att skatta (se exempelvis [2]), vilket introducerar fler osäkerheter. A-matrisen blir exempelvis tredimensionell i en andra ordningens modell $\{a_{ijk}\}$ medan den i en första ordningens modell är tvådimensionell $\{a_{ij}\}$. Med en högre ordningens modell blir beräkningstiderna längre.

Ytterligare ett alternativ för bättre minne kan vara längre observationssekvenser. En nackdel är att det tar det längre tid innan den första skattningen kan göras.

Gränserna i observationsdiagrammet motsvarar inga successiva övergångar. Då målet befinner sig nära en gräns i höjd eller fart kan små förändringar i beteendet orsaka stora förändringar i skattningen av målets klass. På något sätt bör hänsyn kunna tas till den osäkerhet som uppstår då höjd och fart ligger nära en gräns.

3. Suddig matchning - typigenkänning

Avsnittet summerar kort en modell för igenkänning av måltyp, baserad på kinematiska data. Modellen beskrivs utförligt i [9]. Till skillnad från den modell som beskrivs i avsnitt 2 sker igenkänning i denna modell till måltyp. En sådan ansats har alltså studerats, trots hypotesen om att signalspaning och/eller signalbehandling av radarreflektion krävs för att nå måltyp (se avsnitt 2.2.1. och [7]). Modellen utvecklades parallellt med modellen för uppdragsigenkänning.

Modellen bygger på att data om möjliga måltyper lagras i en databas, och att inkommande observationer matchas mot databasens element. Databasen är tänkt att vara lokaliserad i en plattform (eller möjligen distribuerad på olika plattformar). I databasen lagras information om olika flygplanstypers prestanda angående fart (maximal), flyghöjd (maximal) och g-belastning (maximalt negativ respektive maximalt positiv). Eftersom information är behäftad med osäkerhet görs en ”suddig” (eng. fuzzy) matchning av inkommande data mot databasen. Varje matchning kvantifieras till ett värde strikt mellan 0 och 1. Antag att inkommande data innehåller g-belastningsvärdet 5. Lagrad maximal g-belastning för en viss flygplanstyp är 6. Matchning av data mot denna typ ger ett förutbestämt, maximalt matchningsvärde (nära 1). Matchning mot en flygplanstyp med lagrad maximal g-belastning 4,5 ger dock inte matchningsvärdet 0, utan ett värde mellan 0 och det maximala matchningsvärdet, enligt någon vald kurva som avtar asymptotiskt mot noll. Denna kurva kallas här matchningskurvan. Inkommande data som är tillräckligt långt från lagrad maximal g-belastning skulle ge ett matchningsvärde godtyckligt nära 0.

Genom att tillämpa ”suddig” matchning kan graden av vikt som fästs vid lagrade data justeras, möjligen till och med i realtid, genom justering av matchningskurvan. Antag en kurva som från dess värde för maximal g-belastning avtar väldigt långsamt mot noll. I en sådan kurva ger matchning på ömse sidor nära ”gränsen” i stort sett samma matchningsvärde. Detta motsvarar att förhållandevis låg vikt fästs vid lagrade data. Ett snabbt avtagande hos kurvan skulle däremot motsvara att förhållandevis hög vikt fästs vid lagrade data. Detta kan ses som att systemet görs mindre respektive mer känsligt för indata, eftersom det är inkommande data i förhållande till lagrade data som bestämmer matchningsvärdet.


Matchning sker sekventiellt för höjd, fart respektive g-belastning, och matchningsvärdena multipliceras till ett resulterande matchningsvärde för den aktuella typen.¹ Detta kombineras med tidigare matchningsvärden för denna typ enligt *Dempsters regel*. Denna operation innebär uppdatering av ett mått som beskriver hur troligt det är att målet är av just denna typ. Till varje typ hör ett sådant mått. Detta mått liknar en sannolikhet, men har ingen sannolikhetsmässig tolkning, och behöver inte normaliseras. Denna sista egenskap anses värdefull i detta sammanhang. Innebörden illustreras med ett exempel.

Antag att A respektive B är de två enda möjliga utfallen av en händelse. Data som erhålls stöder varken A eller B särskilt mycket. I sannolikhetsteorin sker, efter varje uppdatering, en

¹ Kan också vara en grupp av typer. Förklaring följer i texten

normalisering så att summan av de två sannolikheterna blir 1. Med den teori som används ges utrymme för att undvika normalisering. Det ger möjlighet för reservation för det faktum att alla möjliga utfall inte har kunnat förutses. Skillnaden mellan summan av de icke-normaliserade måtten och 1 kan ses som ett mått på hur stor osäkerheten är i systemet.

Data för de olika flygplanstyperna grupperas hierarkiskt i databasen, i en s.k. binärträdsstruktur², se figur 14. På så sätt matchas indata mot två grupper av typer i taget, där de första två grupperna tillsammans representerar alla lagrade flygplanstyper. I varje grupp utgörs gruppens extremvärden för g-belastning, flyghöjd och fart av de totalt sett extrema värden som finns i gruppen (dvs. som regel ej hos ett och samma flygplan i gruppen).



Figur 14. Exempel på binärträdsstruktur för flygplanstyper. Typernas respektive prestanda avgör hur de grupperas

Då en av grupperna, efter en eller flera uppdateringar, är tillräckligt trolig – enligt ett tröskelvärde satt så att inte båda grupperna kan uppnå det – fortsätter matchningen på typerna i denna grupp. Matchningen fortsätter på detta sätt så långt det är möjligt, dvs. tills en vald grupp innehåller bara en flygplanstyp. Denna typ är resultatet av identifieringen. Hur uppdelningen i grupper ser ut bestäms av de specifika data som karakteriserar flygplanstyperna.

I systemet användes två värden som parametrar. Dessa är det ovan nämnda tröskelvärde i matchningen samt det maximala matchningsvärdet. Det maximala matchningsvärdet sattes lika för de tre storheterna. Detta är dock ingen nödvändighet.

Modellen studeras fortfarande med avseende på teoretiska egenskaper. Resultat från hittills genomförda tester är mestadels av teoretiskt intresse, och har utelämnats från denna rapport.

Modellen är ännu ej implementerad i DF. En komplikation är att det i DF ännu inte finns någon målföljningsmodell som fortlöpande uppskattar målets g-belastning. Dessutom finns tydliga utrymmen för förbättringar i modellens nuvarande form.

² ”binär” innebär här att varje nod i trädet som har underliggande noder, har två närmast underliggande noder

4. DF och måligenkänning i plattformsnätverk

Med en modell för måligenkänning i DK kan situationsbestämning och hotanalys beskrivas vidare och prioritering av mål kan ske på fler sätt inför sensorstyrning. I ett nätverk av DF kan måligenkänningens roll studeras vad avser samverkan mellan plattformar, tjänster och sensorstyrning.

Nätverk av DF

I ett nätverk av plattformar (eller nätverk av DF) kan måligenkänning som görs på en viss plattform bli tillgänglig för alla i nätverket ingående plattformar. En enskild plattform kan därmed erhålla information om ett visst måls troliga klass, vilken har skattats av någon annan plattform. Detta leder till möjligheten att studera exempelvis inverkan och betydelse av måligenkänning i nätverk. Leder måligenkänning till att OODA-loopen roterar snabbare, d v s att beslut kan fattas på kortare tid?

Information om målets klass skickas mellan plattformar

En plattform som upptäcker ett mål kan överta (eller få del av) en skattning av målets klass från en annan plattform, som följt målet sedan tidigare. Med HMM kan exempelvis hela observationssekvensen överföras. Genom att överföra information om målets klass så behöver den ”nya” plattformen inte ägna tid åt att samla in information innan en första skattning kan göras.

Målspårsassociation

Om flera plattformar observerar ett mål kan information om målets klass, eller dess observationssekvens, vara till hjälp för att ta reda på om plattformarna observerar samma mål, dvs. association av målspar. Överensstämmer observationssekvensen mellan plattformar observerar de sannolikt samma mål. Om observationssekvensen inte överensstämmer observerar de sannolikt olika mål. Om $\lambda_1 - \lambda_5$ används för en sådan tillämpning bör antalet möjliga observationer i observationsdiagrammet utökas så att mål som utför samma uppdrag kan särskiljas.

5. Aspekter på måligenkänning och sensorstyrning

Avsnittet nämner kort hur resultat från uppdragsigenkänning kan utnyttjas för prioritering av mål, baserat på följande de tre faktorer (se avsnitt 1.4.): måligenkänning, informationsbehov och hotnivå.

Måligenkänning

Prioriteringen baseras på målets mest troliga uppdrag. Mål som skattas som jakt- eller attackuppdrag kommer i militära sammanhang att prioriteras högre än andra mål.

Informationsbehov

Prioriteringen baseras på osäkerheter i måligenkänning. I vissa situationer kan det tänkas att fördelningen av troligheter $L_1 - L_5$ för ett mål blir mer eller mindre jämnt fördelad. Om följande gäller:

$$L_1 = L_2 = L_3 = L_4 = L_5 = 0,20$$

kan ingen slutsats dras. Genom att hämta mer information om målet kan förhoppningsvis något av uppdragen bli mer troligt än de andra. Mål med sådana resultat kan prioriteras högre än mål med mer entydiga resultat, i syfte att reducera osäkerheter.

Hotnivå

Prioriteringen baseras på målets hotnivå, dvs. beteende i kombination med antagen räckvidd för vapen. I DF redovisas hotnivån i den temporala hotdisplayen, där tiden för handling är central. I hotdisplayen antas varje mål utföra ett jaktuppdrag. Genom att väga samman måligenkänning och hotbild introduceras i hotdisplayen en skattning av målets uppdrag. För mål som kan antas utföra andra uppdrag än jakt kan tiden för handling förlängas. Om målet kan antas vara civilt finns inte längre något hot om att den egna plattformen kan bli attackerad. En sammanvägning av information från hotdisplay och måligenkänning kan förbättra operatörens situationsuppfattning. Detta leder i sin tur till ett bättre underlag för prioritering inför sensorstyrning.

6. Några slutsatser

6.1. En jämförelse mellan matchningsmodell och HMM

Rapporten fokuserar på beskrivningen av modellen för uppdragsigenkänning (HMM) medan modellen med suddig matchning (matchningsmodellen) beskrivs endast kortfattat. HMM har implementerats i DF och en rad erfarenheter om hur modellen fungerar har erhållits via simuleringar. Här görs ett försök att jämföra modellerna, trots att matchningsmodellen inte har studerats och provats i lika stor utsträckning.

Modellerna har vissa egenskaper gemensamma eftersom båda är kopplade till målföljningen. De är lika robusta mot enstaka uteblivna observationer och lika känsliga mot eventuella anomalier i målföljningsmodellen.

HMM ger ett dynamiskt resultat. Troligheten för olika uppdrag kan variera över tiden och i vissa fall skiftar även uppdraget såsom i scenario 1 (avsnitt 2.3.1.). Ett extremt och kortvarigt beteende kan glömmas bort efter en tid om målet börjar bete sig mer normalt igen. För att HMM ska kunna bevara information om kortvariga och extrema beteenden behöver den kompletteras med en separat rutin, i någon utformning. Det dynamiska resultatet kan också användas som en del i en hotanalys. Då målet betar sig extremt ökar trolighetsvärdet för till exempel jakt- eller attackuppdrag, vilket kan användas som indikation på att ett anfall är nära förestående. Matchningsmodellen, i dess nuvarande utformning, ger resultat som är irreversibla på varje nivå i trädet. Resultaten varierar inte över tiden och modellen kan sägas ha "oändligt minne".

HMM modellerar, till skillnad från matchningsmodellen, även moderat beteende i form av exempelvis transportuppdrag. HMM behöver nödvändigtvis inte invänta extrema beteenden för att kunna säga något om vilket klass målen tillhör. Matchningsmodellen gör inga antaganden om förväntade beteenden utan fokuserar på förväntade prestanda. Matchningsmodellen blir mer robust mot vilseledande beteenden, men behöver å andra sidan invänta situationer där målet avslöjar sin prestanda i fart, höjd eller svängförmåga.

I matchningsmodellen finns ingen möjlighet att särskilja en flygplanstyp med extremvärden "helt inom ramarna" för en annan typs extremvärden. Det är en begränsning hos denna ansats, till stöd för den tes som presenteras i [7], d v s att kinematiska data inte räcker för igenkänning på typnivå.

Modellerna är troligtvis tillämpbara i olika faser och kan därmed komplettera varandra. HMM kan tänkas användbar för att skatta målets uppdrag på långa avstånd, med förhållandevis

mycket tid till förfogande. HMM kan även tänkas användbar som direkt indata till hotanalys. Matchningsmodellen kan tänkas användbar i en fas där irreversibla beslut³ är önskvärda – till exempel då jaktstrid inletts. I en sådan fas antas inferens om målets typ, och därigenom möjlig beväpning, vara av stort värde.

6.2 Allmänna reflektioner om måligenkänning med kinematiska data

En modell baserad på kinematiska data bör kunna bidra till måligenkänning. Modellen kommer dock inte att i alla situationer kunna ge information om målet, men stundtals kommer målet sannolikt att bete sig på ett sådant sätt att modellen kan ge väsentlig information. Valet av modellparametrar har stor inverkan på hur modellen reagerar på ett visst måls beteende. Vid val av modellparametrar är det viktigt att komma underfund med vilka beteenden som modellen bör reagera för och hur stor reaktionen bör vara jämfört med andra beteenden. Val av parametrar och inlärningsdata bör göras så att modellerna speglar de mest karakteristiska egenskaperna i stora drag.

Det kommer att finnas tillfällen då modellen inte kan nå sin maximala nivå av igenkänning. Det är därmed fördelaktigt om modellen kan ta hänsyn till nivåerna under den maximala nivån. En modell vars maximala nivå motsvarar *klass*, ska även kunna generera ett svar som beskriver målets *natur*. En modell vars maximala nivå motsvarar *typ*, ska även kunna generera ett svar som beskriver dels *klass*, dels *natur*.

Sensorer kan vara utsatta för störningar av olika slag. Störning för en radar kan vara klotter som uppstår dels över land, dels över vatten (hav). Klotter över land orsakas bl. a av topografi, vegetation och fuktig luft. Klotter över vatten orsakas bl. a av storleken på vågor, vindhastighet och regn. Störning kan också skapas direkt av människan för att vilseleda. För störning med kinematiska data kan störsändare på fiendens plattform låta kopiera inkommande radarpulser till hundratals kopior, vilka skickas tillbaka mot radarn. Under sådana förhållanden blir det mycket svårt att upprätthålla målföljning och måligenkänning.

Vilseledning kan ske även för andra typer av kännetecken. För att inte avslöja sin verkliga signatur kan väl valda förändringar på flygplanskroppen skapa vilseledning. Radarpulsens reflektion förändras jämfört med den reflektion som karakteriserar flygplanskroppens ursprungliga form. Den uppmätta signaturen kommer inte att kunna identifieras i signaturbiblioteket, med vilket uppmätta data jämförs.

Måligenkänning baserad på radardata blir oberoende av väder och ljus. Radarn har dessutom mycket lång räckvidd. Måligenkänningen blir inte heller beroende av att målet avslöjar sig genom emission av elektromagnetisk strålning. Med kinematiska data som bas blir måligenkänningen okänslig för vilseledning av signaturer.

Radarsensorn är dock en aktiv sensor, vilket innebär att den egna plattformen avslöjas för omgivande mål då radarn används. Målföljning med radar kan dock ske i samverkan med en IRST-sensor, vilket gör målföljningen mer passiv. I sådana fall bör måligenkänning kunna fortskrida så länge kvaliteten på målföljningsdata är tillräckliga.

För att erhålla en mer robust måligenkänning bör modellen baseras på *olika* typer av kännetecken. Det slutliga resultatet beräknas genom fusion av olika kännetecken. Måligenkänningen blir robust dels eftersom ett mål beskrivs ur flera synvinklar, dels för att

³ t ex att avfyra missil

det förhoppningsvis hela tiden finns något kännetecken som kan observeras och ligga till grund för en skattning.

7. Förslag till fortsatt arbete

Kompletterande måligenkänning

Som nämndes i slutet av avsnitt 6.2 är det fördelaktigt med en modell som kan hantera olika typer av kännetecken. Det vore därför önskvärt att i DF även ha tillgång till ESM-sensorer. Med befintliga ESA- eller IRST-sensorer finns möjlighet att introducera signaturer. Kinematiska data bör därför ses som en typ av kännetecken som tillsammans med andra kännetecken kan skapa en mer robust måligenkänning. Modeller baserade på olika typer av kännetecken kan exempelvis studeras i [7] och [24].

Gruppmålföljning

Gruppmålföljning är en typ av information som kan komplettera modellen för uppdragsigenkänning [6]. Med gruppmålföljning är syftet att ta reda på om flygplan flyger i grupp, eller formation. Vissa uppdrag utförs i grupp med två eller flera flygplan. Jaktuppdraget utförs ofta med två flygplan. Attackuppdraget utförs ofta med fyra flygplan. Transport- och spaningsuppdragen utförs ofta med ett flygplan. Sådan information kompletterar resultaten från uppdragsigenkänning. Om uppdragsigenkänning indikerar trolighet för attackuppdrag samtidigt som gruppmålföljning indikerar att där finns fyra närliggande mål kommer troligheten för attackuppdrag att öka markant.

Koppling till hotdisplay

Resultat från hotanalys och måligenkänning vägs samman för att förbättra hotanalys och förberedelse inför sensorstyrning (se avsnitt 5).

Utvärdering

Att få modellen för uppdragsigenkänning utvärderad av flygförare i simulator skulle vara av stort värde. En utvärdering kan ske från olika aspekter, dels om nivån av igenkänning inklusive tillförlitlighet upplevs som tillräcklig, dels på vilket sätt resultatet bör presenteras för att flygföraren ska kunna tillgodogöra sig informationen på bästa sätt.

Multipla HMM för samma uppdrag

HMM-parametrar för ett och samma uppdrag är sannolikt olika i olika omgivningar. Nära flygplatser bör beteenden typiska för start och landning lyftas fram. Att beskriva ett uppdrags beteende i en och samma HMM är förmodligen svårt. Ett alternativ är att skapa en uppsättning av två eller flera HMM för samma uppdrag. Om sensorn kan förstå vilken omgivning den söker i så kan en motsvarande HMM utnyttjas för igenkänning.

Information om kvalitet på målföljning kopplas till HMM

I modellen för målföljning finns i kovariansmatrisen information om målföljningens kvalitet. Sådan information är av intresse för måligenkänning baserat på kinematiska data och bör synliggöras i modellen. Låg kvalitet på målföljning leder till större osäkerheter i måligenkänning. På samma sätt leder hög kvalitet på målföljning till mindre osäkerheter i måligenkänning.

8. Referenser

1. Andersson, M.: *Classification of Aerial Missions Using Hidden Markov Models*. Proc. of the 7th European Conference ECSQARU 2003, LNAI 2711, Aalborg, Denmark, July, pp. 123-136, 2003.
2. Aycard, O., Mari, J.-F., Charpillat, F.: *Second Order Hidden Markov Models for Place Recognition: new results*. Tenth IEEE International Conf. on Tools with Artificial Intelligence, pp. 408-415, November, 1998.
3. Bharadway, P., Runkle, P., Carin, L., Berrie, J., A., Highes, J., A.: *Multiaspect Classification of Airborne Targets via Physics-Based HMMs and Matching Pursuits*. IEE Transactions on Aerospace and Electronic Systems, Vol. 37, No. 2 pp. 595-606, April, 2001.
4. Berg, T., Lantz, F., Strömberg, D.: *Plattformar i nätverk – Mjukvaruarkitektur och operatörstjänster*. FOI-R—0696—SE, december, 2002.
5. Björnftot, J., Svensson, P.: *Modeling the Column Recognition Problem in Tactical Information Fusion*. Proc. of the 3rd Int. Conf. On Information Fusion, Paris, France pp. 24-30, July, 2000.
6. Blackman, S., Popoli, R.: *Design and Analysis of Modern Tracking Systems*. ISBN 1-58053-006-0, Artech House, Norwood, MA, 1999.
7. Caromicoli, A., Kurien, T.: *Multitarget Identification in Airborne Surveillance*. SPIE Vol. 1098 Aerospace Pattern Recognition, pp. 161-176, 1989.
8. Cho, W., Lee, S.-W., Kim, J. H.: *Modeling and Recognition of Cursive Words with Hidden Markov Models*. Pattern Recognition, Vol. 28. No. 12 pp. 1941-1953, 1995.
9. Folkesson, M.: *Fuzzy Matching and Evidential Reasoning*. Proc. of the 7th European Conference ECSQARU 2003, LNAI 2711, Aalborg, Denmark, July, pp. 267-278, 2003.
10. *Flygplan – kort*. ISBN 91-973255-8-9, Gummessons, Falköping, Sverige, 1999.
11. di Francesco, V., Garnier, J., Munson, P., J.: *Protein Topology Recognition from Secondary Structure Sequences: Application of the Hidden Markov Models to the Alpha Class Proteins*. Molecular Biology, Vol 267, pp. 446-463, 1997.
12. Hall, D.: *Lectures in Multisensor Data Fusion and Target Tracking*. Tech Reach Inc., 268 Homan Avenue, State Collage, PA 16801-6332, 2000.
13. Hollnagel, E.: *Cognition as Control: a Pragmatic Approach to the Modelling of Joint Cognitive Systems*. IEEE Transactions on Systems, Man and Cybernetics, 2003. (in print)
14. Koski, T.: *Hidden Markov Models for Bioinformatics*. ISBN 1-4020-0135-5, Kluwer Academic Publishers, the Netherlands, 2001.

15. Liander, P.: *Flygande försvarare – dagens svenska militärflyg*. ISBN 91-85496-59-6, Gummessons, Falköping, Sverige, 1993.
16. Pendergast, S. L.: *An Algorithmic Approach to Multi-Source Identification*. Proc. of the 1988 Command and Control Research Symposium, Monterey, California, June 7-9, pp. 144-152, 1988.
17. Rabiner, L., R.: *A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition*. Proc. of the IEEE, Vol. 77, No. 2, February, pp. 257-286, 1989.
18. Strömberg, D.: *A Platform-Based Data Fusion and Sensor Management Node*. IEE RADAR 2002, Edinburgh, UK, pp. 483-487, October, 2002.
19. Strömberg, D., Andersson, M., Petterson, G., Forsgren, R.: *Temporala displayer*. FOI-R—0576—SE, ISSN 1650-1942, September, 2002.
20. Strömberg, D., Andersson, M., Lantz, F.: *On Platform-Based Sensor Management*. Proc. Of the 5th Int. Conf. On Information Fusion, Annapolis, USA pp. 600-606, July, 2002.
21. Strömberg, D., Berg, T.: *Samverkande datafusionsnoder – delprojekt inom Ledst/T/FOI*. Statusrapport juni 2002, FOI Memo, 02-1531, maj, 2002.
22. Teti, J., G., Gorman, R., P., Berger, W., A.: *A Multifeature Decision Space Approach to Radar Target Identification*. IEEE Transaction on Aerospace and Electronic Systems, Vol. 32, Issue 1, pp. 480-487, January, 1996.
23. de la Torre, A., Peinado, A. M., Rubio, A. J.: *Discriminative Feature Weighting for HMM-Based Continuous Speech Recognizers*. Speech Communications, Vol. 38, pp. 267-286, 2002.
24. Wigren, T.: *Noncooperative Target Type Identification in Multi-Sensor Tracking*. Proc. of the IRCTR Colloquium on Surveillance Sensor Tracking, Delft 26 June, pp. 1-12, 1997.
25. Åkermark, H.: *Radaravbildningar – Grunder och tillämpningar, särskilt måligenkänning*. FOA-R—99-01127-408—SE, april, 1999.

BILAGA 1: Parametervärden för de dolda Markovmodellerna

Jaktuppsdragets observationssannolikheter för symbolerna (k) fördelat på S₁ och S₂.

$(b_j(k))_n$	1	2	3	4	5	6	7	8	9	10	11	12	13	14
$(b_1(k))_{ja}$	0,01	0,00	0,20	0,04	0,01	0,02	0,54	0,13	0,02	0,00	0,02	0,00	0,00	0,00
$(b_2(k))_{ja}$	0,01	0,01	0,12	0,09	0,01	0,02	0,34	0,32	0,03	0,01	0,03	0,01	0,01	0,01

$$\pi_{ja,i} = \begin{pmatrix} 0,61 \\ 0,39 \end{pmatrix}$$

$$a_{ja,ij} = \begin{pmatrix} 0,54 & 0,46 \\ 0,55 & 0,45 \end{pmatrix}$$

Attackuppsdragets observationssannolikheter för symbolerna (k) fördelat på S₁ och S₂.

$(b_j(k))_n$	1	2	3	4	5	6	7	8	9	10	11	12	13	14
$(b_1(k))_{at}$	0,24	0,17	0,02	0,01	0,02	0,01	0,02	0,01	0,37	0,07	0,02	0,01	0,01	0,00
$(b_2(k))_{at}$	0,26	0,19	0,01	0,02	0,02	0,02	0,01	0,02	0,13	0,26	0,02	0,02	0,02	0,00

$$\pi_{at,i} = \begin{pmatrix} 0,45 \\ 0,55 \end{pmatrix}$$

$$a_{at,ij} = \begin{pmatrix} 0,49 & 0,51 \\ 0,56 & 0,44 \end{pmatrix}$$

Spaningsuppsdragets observationssannolikheter för symbolerna (k) fördelat på S₁ och S₂.

$(b_j(k))_n$	1	2	3	4	5	6	7	8	9	10	11	12	13	14
$(b_1(k))_{sp}$	0,51	0,00	0,02	0,00	0,38	0,00	0,02	0,00	0,01	0,00	0,02	0,00	0,01	0,00
$(b_2(k))_{sp}$	0,23	0,01	0,02	0,01	0,60	0,00	0,02	0,01	0,03	0,00	0,03	0,00	0,03	0,00

$$\pi_{sp,i} = \begin{pmatrix} 0,61 \\ 0,39 \end{pmatrix}$$

$$a_{sp,ij} = \begin{pmatrix} 0,81 & 0,19 \\ 0,67 & 0,32 \end{pmatrix}$$

Transportuppsdragets observationssannolikheter för symbolerna (k) fördelat på S₁ och S₂.

$(b_j(k))_n$	1	2	3	4	5	6	7	8	9	10	11	12	13	14
$(b_1(k))_{tr}$	0,00	0,00	0,05	0,00	0,01	0,01	0,01	0,00	0,00	0,00	0,01	0,00	0,88	0,02
$(b_2(k))_{tr}$	0,02	0,00	0,04	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,02	0,00	0,89	0,02

$$\pi_{tr,i} = \begin{pmatrix} 0,51 \\ 0,49 \end{pmatrix}$$

$$a_{tr,ij} = \begin{pmatrix} 0,92 & 0,08 \\ 0,91 & 0,09 \end{pmatrix}$$

Sportflygningens observationssannolikheter för symbolerna (k) fördelat på S_1 och S_2 .

$(b_j(k))_n$	1	2	3	4	5	6	7	8	9	10	11	12	13	14	
$(b_1(k))_{pr}$	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,88	0,09	0,00	0,00
$(b_2(k))_{pr}$	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,49	0,45	0,00	0,00

$$\pi_{pr,i} = \begin{pmatrix} 0,90 \\ 0,10 \end{pmatrix}$$

$$a_{pr,ij} = \begin{pmatrix} 0,62 & 0,38 \\ 0,62 & 0,38 \end{pmatrix}$$