

# Redovisning av signalbehandlingsmetoder för nätverk av marksensorer

Tomas Eklöv, Andris Lauberts, Ron K. Lennartsson

---

TOTALFÖRSVARETS FORSKNING SINSTITUT

Ledningssystem

Box 1165

581 11 Linköping

FOI-R--1284--SE

Juni 2004

ISSN 1650-1942

**Teknisk rapport**

# Redovisning av signalbehandlingsmetoder för nätverk av marksensorer

Tomas Eklöv, Andris Lauberts, Ron K. Lennartsson

<b>Utgivare</b> Totalförsvarets Forskningsinstitut - FOI Ledningssystem Box 1165 581 11 Linköping	<b>Rapportnummer, ISRN</b> FOI-R--1284--SE	<b>Klassificering</b> Teknisk rapport
	<b>Forskningsområde</b> 4. Spaning och ledning	
	<b>Månad, år</b> Juni 2004	<b>Projektnummer</b> E7036
	<b>Verksamhetsgren</b> 5. Uppdragsfinansierad verksamhet	
	<b>Delområde</b> 42 Spaningssensorer	
<b>Författare/redaktör</b> Tomas Eklöv Andris Lauberts Ron K. Lennartsson	<b>Projektledare</b> Martin Holmberg	
	<b>Godkänd av</b>	
	<b>Uppdragsgivare/kundbeteckning</b> Försvarmakten	
	<b>Tekniskt och/eller vetenskapligt ansvarig</b>	
<b>Rapportens titel</b> Redovisning av signalbehandlingsmetoder för nätverk av marksensorer		
<b>Sammanfattning (högst 200 ord)</b> Projektet IAM (Interaktiva Adaptiva Marksensornät) syftar till att visa hur ett nätverk bestående utav marksensorer och kommunikationssystem skulle kunna utformas, samt hur systeminteraktion med användarna i ett sådant system skulle kunna ske. Här presenteras de signalbehandlingsmetoder som kommer att användas vid den demonstrationsdag som skall genomföras i november 2004. Det är metoder för att kunna klassificera, riktighetsbestämma samt positionera stridsfordon som kör igenom ett sensornätverk. I denna rapport redovisas en utvärdering av metoderna med data från ett fältförsök som genomfördes i Kvarn i oktober 2003.		
<b>Nyckelord</b>		
<b>Övriga bibliografiska uppgifter</b>	<b>Språk</b> Svenska	
<b>ISSN</b> 1650-1942	<b>Antal sidor:</b> 39 s.	
<b>Distribution enligt missiv</b>	<b>Pris:</b> Enligt prislista	

<b>Issuing organization</b> FOI – Swedish Defence Research Agency Command and Control Systems P.O. Box 1165 SE-581 11 Linköping	<b>Report number, ISRN</b> FOI-R--1284--SE	<b>Report type</b> Technical report
	<b>Programme Areas</b> 4. C4ISTAR	
	<b>Month year</b> June 2004	<b>Project no.</b> E7036
	<b>General Research Areas</b> 1. Policy Support to the Government	
	<b>Subcategories</b> 42 Surveillance Sensors	
<b>Author/s (editor/s)</b> Tomas Eklöv Andris Lauberts Ron K. Lennartsson	<b>Project manager</b> Martin Holmberg	
	<b>Approved by</b>	
	<b>Sponsoring agency</b>	
	<b>Scientifically and technically responsible</b>	
<b>Report title (In translation)</b> Tracking and Classification of Ground Combat Vehicles		
<b>Abstract (not more than 200 words)</b> <p>The objective of the IAM (Interactive Adaptive Ground Sensor Networks) project is to demonstrate how a network consisting of ground sensors and communication systems can be designed, and how system user interaction for this system can be designed (a demonstration will be held in November 2004). In this report we present signal processing methods for classification, estimation of direction of arrival and tracking of ground combat vehicles. The presented methods are evaluated with data from a field trial conducted in October 2003.</p>		
<b>Keywords</b>		
<b>Further bibliographic information</b>	<b>Language</b> Swedish	
<b>ISSN</b> 1650-1942	<b>Pages</b> 39 p.	
	<b>Price acc. to pricelist</b>	

1	Inledning.....	6
2	Klassificering .....	6
2.1	Data .....	6
2.2	Metoder .....	7
2.2.1	Särdragsextraktion.....	7
2.2.2	Dimensionsreducering.....	7
2.2.3	Klassificering .....	9
2.2.4	Temporal filtrering.....	11
2.2.5	Fusion i nätverket.....	11
2.3	Resultat.....	12
2.3.1	Val av data.....	12
2.3.2	Val av särdrag.....	13
2.3.3	Jämförelse mellan klassificeringsalgoritmer .....	19
2.3.4	Klassificerare för mikrofoner .....	19
2.3.5	Klassificerare för geofoner.....	20
2.3.6	2 vs. 6-klass problemet.....	20
2.3.7	Effekter av okänd klass modellering.....	22
2.3.8	Optimering av temporal filtrering .....	25
2.3.9	Fusion mellan noder .....	27
2.3.10	Validering med tidigare genomförda mätningar .....	27
2.4	Slutsatser för klassificering .....	30
3	Rikttningsbestämning.....	30
4	Målspårsberäkningar .....	33
4.1	Följefilter.....	33
4.1.1	Multi Sensor Fusion .....	34
4.1.2	Informationsfilter .....	34
4.1.3	Målspårsberäkningar utifrån experimentella data .....	36
4.1.4	Jämförelse mellan spårestimat baserat på två olika Kalmanfilter .....	38
4.2	Modellscenario .....	40
5	Slutsatser .....	41
6	Referenser.....	42

# 1 Inledning

Det kommer att vara av stor vikt att ha information om markläget vid framtida krigssituationer och internationella insatser. Projektet IAM (Interaktiva Adaptiva Marksensornät) har som mål att visa hur ett nätverk bestående utav marksensorer, kommunikationssystem samt systeminteraktion med användarna skulle kunna utformas. I projektet skall vi bland annat studera och utvärdera tillgängliga marksensorer och sensorteknik i syfte att demonstrera ett marksensornät. I uppgiften ingår dessutom att utveckla algoritmer för analys av data insamlade med ett marksensornät samt metoder för distribuerad datafusion. I den här rapporten presenteras de signalbehandlingsmetoder som kommer att användas vid den demonstration som ska hållas i november 2004. Det är metoder för att kunna klassificera, riktningbestämma samt positionera stridsfordon som kör igenom ett sensornätverk. Metoderna utvärderas med data från ett fältförsök som genomfördes i Kvarn i oktober 2003<sup>1</sup>. Sensornätverket bestod av fem mikrofonnoder och fem geofonnoder. I varje nod var tre sensorer placerade så att de bildar en cirkulärarray. Vid fältförsöket gjordes mätningar på tre hjulfordon (TR20, Lastmaskin, BTR70) och tre bandfordon (MTLB401, PBV501, T72). För varje fordon samlades data in från minst sex körningar genom området. Körningarna gjordes i olika fart, och med två olika färdriktningar. Fältförsöket finns mer i detalj beskrivet i<sup>1</sup>.

## 2 Klassificering

Syftet med denna studie är att ta fram och beskriva en lämplig klassificerare för den demonstration som ska hållas i IAM projektet, november 2004. Dessutom skall kritiska frågeställningar för den fortsatta utvecklingen inom detta område belysas.

Den framtagna algoritmen bör uppfylla följande krav:

- Modellen ska baseras på och optimeras för data insamlade i fältförsök.
- Gemensam modell för alla sensorer av samma typ.
- Modellen ska ge en (approximativ) sannolikhet för klasstillhörighet i de aktuella klasserna.
- Modellen bör ge så litet fel i klassificeringen som möjligt.
- Modellen ska förenklas så långt som möjligt.
- Beräknings- och datalagringsbehoven skall ej vara överdrivet stora (nära realtid på vanlig PC).

Mer specifikt ska modellen klassificera data i en av sex förutbestämda klasser eller klassas som okänd. I första hand tas klassificeraren fram för att köras på en sensor i taget. Fusion mellan sensorer belyses endast överskådligt i denna rapport. Syftet är alltså inte att bygga upp en komplett teoretisk bakgrund/metod för detta problem, utan att arbeta så pass mycket med data så att en metod som fungerar tillfredställande (som uppfyller kraven ovan) i den givna demonstrationen kan utvecklas.

### 2.1 Data

Data som används i klassificeringsstudien kommer från ett fältförsök som genomfördes i oktober 2003 i Kvarn. Rådata samlades in med samplingsfrekvensen 44kHz. För klassificeringsändamål har data sedan lågpasfilterats och nedsamlats till 2kHz då all relevant information för klassificeringsändamål finns under 1 kHz. Ett signalavsnitt som innehåller den maximala signalenergin (typiskt när stridsfordonet är som närmast sensorn)

väljs automatiskt ut. Vidare bestämdes också längden på signalavsnittet automatiskt så att signalenergin är en eller fem procent av den maximala i början och slutet av signalavsnittet. De utvalda signalavsnitten delas sedan upp i observationsfönster av längden 0.5 sekunder som flyttas 0.5 sekunder åt gången (det vill säga ej överlappande fönster).

För mikrofonerna användes en sensor (nod 6) för att ta fram klassificeringsmodellen, en sensor användes för validering (nod 3), och övriga noder testades enbart den slutgiltiga modellen på. För geofonerna gav nod 1 träningsdata, nod 2 valideringsdata, och övriga noder testades enbart på den framtagna modellen. I modellframtagningen/validering nyttjades enbart körningar med fix hastighet. Bland körningarna med varierande hastighet fanns en betydligt större variation i spektra, vilka gör att fler körningar krävs för att modellerna ska kunna fånga all variation.

## 2.2 Metoder

### 2.2.1 Särdragsextraktion

I den här studien använder vi två olika metoder för att extrahera särdrag; en som baserar sig på AR-modeller och en på FFT koefficienter.

#### AR-modeller

En AR modell av ordning  $p$  kan anpassas till den uppmätta signalen  $x(n)$ , enligt

$$x(n) = -\sum_{k=1}^p a_k x(n-k) + e(n)$$

där  $e(n)$  är vittbrus med variansen  $\sigma^2$ . Modellen anpassas på detta sätt till signalen i varje observationsfönster med hjälp av Yule-Walkers metod. Modell parametrarna  $a_1$  till  $a_p$  användas sedan som särdrag för klassificering. Vi har i en tidigare studie<sup>2</sup> funnit att  $p = 27$  är ett lämpligt värde, varför det används även i den här studien.

#### FFT

En annan möjlighet är att använda FFT analys för att extrahera särdrag. En FFT av storlek 1024 beräknas för varje observationsfönster enligt

$$X(k) = \sum_{n=1}^N x(n) e^{-j2\pi(k-1)(n-1)/N}, 1 \leq k \leq 1024$$

där  $x(n)$  är den uppmätta signalen. Som särdrag används sedan absolutbeloppet,  $|X(k)|$ , för  $1 \leq k \leq 512$ .

### 2.2.2 Dimensionsreducering

Ett första steg inför klassificeringen, är att minska dimensionaliteten i indata. Många variabler, som har en hög samvariationen, gör det svårt att ta fram en pålitlig klassificerare som ger hög noggrannhet även i en validering. Dimensionsreduceringen kan motiveras med "The curse of dimensionality", vilken innebär att antal observationer i träningsdata nödvändiga för att uppnå en viss noggrannhet ökar exponentiellt med antal variabler.

En initial dimensionsreducering har i denna undersökning gjorts vid särdragsextraktionen till AR eller FFT koefficienter. Det finns även andra metoder för särdragsextraktion som nyttjar tid-frekvens relationerna i rådata, såsom wavelets. I denna analys har dock ej denna typ av extraktion undersökts vidare.

## Principalkomponentanalys

En etablerad metod för dimensionsreducering är PCA (principal component analys)<sup>3</sup>. I PCA räknas principalkomponenter (PC) fram vilka är linjärkombinationer av originalvariablerna. En PC tas fram så att den förklarar maximal varians i data. PC räknas ut i ordning så att PC1 förklarar maximal varians i datasetet, PC2 är den riktning, ortogonal mot PC1, som förklarar maximal återstående varians osv. Genom att bara behålla de mest betydelsefulla PC fås en dimensionsreduktion. En PCA modell kan skrivas

$$X = score * loading + E$$

Där  $X$  är original data,  $score$  beskriver observationernas relation i modellen,  $loading$  beskriver variablernas relation, och  $E$  (fel) är den del i  $X$  som ej förklaras av de  $N$  första principal komponenterna. Som nya variabler i den fortsatta modelleringen används  $score$ -matrisen med  $N$  komponenter.

För en ny mätning  $X_{new}$  kan den nya  $score$ -vektorn räknas ut som

$$score_{new} = X_{new} * loading^T$$

där  $T$  beteckning transponatet av vektorn.

För att välja  $N$  görs vanligtvis någon typ av analys av hur mycket relevant information som förklarats med olika antal PC. I den aktuella undersökningen har klassificeringsfelet för olika antal PC använts för att hitta optimalt antal PC.

## Andra dimensionsreduceringsmetoder

Det finns andra metoder för att åstadkomma en dimensionsreducering. En enkel metod är att välja ett subset av variabler, genom att definiera ett urvalskriterium och en sökmetod. Det finns ett stort antal metoder för att göra ett variabelval<sup>4</sup>. Dock blir sökningen svårare ju fler variabler som finns tillgängliga, och det blir beräkningskrävande att hitta ett optimalt subset.

PCA hör till en klass av metoder, där nya ortogonala basvektorer (riktningar) räknas fram i storleksordning genom att maximera ett specifikt kriterium. För PCA maximeras förklarad varians i  $X$  data. Andra metoder är:

- ICA<sup>5</sup> (independent component analysis) hittar riktningar med minimal grad av normalfördelning. ICA används t.ex. för att hitta riktningar som separerar oberoende ljudkällor (cocktail party problem).
- PLS<sup>6</sup> (partial least squares) hittar riktningar där kovariansen mellan  $X$  och en  $Y$  vektor (matris) är maximal. PLS används t.ex. inom spektroskopi, där syftet är att hitta relationer mellan spektra ( $X$ ) och mängden av någon kemisk förening ( $Y$ ).
- LDA<sup>7</sup> (linear discriminant analysis) används för klassificeringsproblem, och riktningar med maximal Fisher-kvot, dvs. de nya riktningarna maximerar kvoten mellan kovariansen mellan klasser och kovariansen inom klasser.
- ODP (optimal discriminant projection) är en vidareutveckling av LDA, där de nya riktningarna minimerar felklassificeringssannolikheten<sup>8</sup>.
- GBP (good and bad projection) används i klassificeringsproblem där syftet är att separera en väldefinierad klass (good) för allting annat (bad)<sup>8</sup>.



### 2.2.3 Klassificering

En klassificerare tar en indatavektor ( $X$ ) och mappar den till en utdatavektor ( $Y$ ), där  $Y$  är ett mått på klasstillhörighet för indatavektorn.

#### Bayes klassificerare

Ett vanligt antagande vid design av klassificerare är att respektive klass kan beskrivas av en multivariat normalfördelning, dvs.

$$P_j(x) = \frac{1}{\sqrt{(2\pi)^n \det(\Sigma_j)}} \cdot e^{-\frac{1}{2}(x-\mu_j)\Sigma_j^{-1}(x-\mu_j)}$$

där  $\mu_j$  är medelvärde för klass  $j$ ,  $\Sigma_j$  är kovariansmatris för klass  $j$ ,  $X$  är indatavektorn,  $n$  är antal dimensioner i  $X$ , och  $P_j$  är sannolikhetsfördelningen för klassen. Om  $\Sigma_j = \Sigma$  för alla klasser sägs problemet vara "homoscedastiskt", och det mer generella fallet med olika  $\Sigma$  för respektive klass sägs problemet vara "heteroscedastiskt". Detta val inverkar på komplexiteten för klassificeraren, och måste avgöras utifrån applikationens egenskaper.

En klassificerare där klassen ( $i$ ) för en observation  $X$  bestäms av maximal  $P_j(x)$  är en Bayes klassificerare<sup>9</sup>. För normalfördelade klasser ger Bayes klassificeraren bästa möjliga modell. Eftersom vi i detta problem ej känner till  $\Sigma$  exakt, måste dessa estimeras utifrån tillgänglig data.

Mahalanobis avståndet<sup>10</sup> i kvadrat från en observation ( $x$ ) till en klass ( $i$ ) kan skrivas

$$MD^2 = (x - \mu_i)\Sigma_i^{-1}(x - \mu_i)$$

enligt beteckningarna ovan.  $MD$  hittas i den multivariata normalfördelningen ovan i exponenten. Om  $\mu$  och  $\Sigma$  är kända är  $MD^2$   $\chi^2$ -fördelad med  $(n-1)$  frihetsgrader, vilket kan användas t.ex. som gräns för outlier detektion eller klassificering.  $\chi^2_{.99}$  ger då en gräns för vilken 99% av observationerna som tillhör en viss klass (som beskrivs av en multivariat normalfördelning) har ett Mahalanobis avstånd i kvadrat som är mindre än denna gräns. Eftersom man i verkligheten sällan känner till  $\mu$  och  $\Sigma$  är detta en approximation, vilken i denna studie ansetts vara tillräcklig. För mer exakt hantering ska en (mer komplicerad)  $\beta$  fördelning användas i stället.

Genom att förenkla  $P_j$  ovan till

$$P_j(x) = k \cdot e^{-\frac{1}{2}MD^2}$$

fås ett  $P$  som är approximativt relaterad till sannolikheten att en viss mätning tillhör en viss klass. Detta  $P$  kan användas/tolkas på två olika sätt beroende på vilket antagande om klasstillhörighet som görs.

Om vi antar att en mätning tillhör exakt en av ett antal kända klasser ger

$$S_j(x) = \frac{P_j(x)}{\sum_{i=1}^{\text{antal klasser}} P_i(x)}$$

approximativt sannolikheten för att  $x$  tillhör en viss klass. En exakt uträkning kräver numerisk integration av de multivariata normalfördelade sannolikhetsfördelningarna, vilket ej kan motiveras i praktiken.

Om vi antar att en mätning kan tillhöra någon av de kända klasserna eller ”okänd klass” blir tolkningen mer komplicerad. En möjlig lösning är att nyttja den framräknade statistiska  $\chi^2$ -gränsen för att skala om  $P_j$  enligt:

$$S_j(x) = \min(P_j(x), P_{\chi^2\text{-limit}}) / P_{\chi^2\text{-limit}}$$

vilket ger  $S \in [0, 1]$ , där  $S=1$  för alla  $P$  större än den statistiska gränsen. Nackdelen blir just att alla  $S > Limit$  får maximal sannolikhet vilket gör det omöjligt, i fallet där två eller fler klasser ger  $S=1$ , att ta fram den mest sannolika klassen. Om vi i stället använder

$$S_j(x) = 0.99 * \min(P_j(x), P_{\chi^2\text{-limit}}) / P_{\chi^2\text{-limit}} + 0.01 * P_j(x) / P_j^{\max}$$

ger den andra delen i ekvationen ett litet bidrag som även inverkas av  $P > P_{Limit}$ .  $P_j^{\max}$  är lika med  $k$  i ekvationerna ovan. Slutligen ges sannolikheten att en observation tillhör en ”okänd” klass av komplementet till maximal sannolikhet för någon av de kända klasserna.

$$S_{okänd}(x) = 1 - \max_{i=1}^{\text{antal klasser}} (S_i(x))$$

Med ovanstående (ad hoc) metod får vi en funktion som hanterar även den ”okända” klassen, och ger sannolikheter för att en observation tillhör en viss klass.

Användaren har alltså två alternativ, beroende på om mätningar alltid tillhör någon av de kända klasserna eller inte:

- Alt 1 (Alla klasser kända): Modellen ger alltid ett svar där en ny observation klassas i den av de kända klasserna som ligger närmast.
- Alt. 2 (Okänd klass): Modellen mäter ”avstånd” till alla klasser för en ny observation. Ett statistiskt avstånd (99%) räknas fram, vilket konverteras till sannolikhet. Denna sannolikhet skalas med den statistiska gränsen så denna (och alla mindre avstånd) motsvarar 0.99 i sannolikhet.

## Andra klassificeringsmetoder

I en **k-NN** klassificerare<sup>9</sup> utgör träningsdata modellen. Genom att beräkna (det euklidiska) avståndet mellan en ny observation och varje punkt i träningsdata och sedan klassificera den nya punkten mha. majoritetsbeslut hos de  $N$  närmaste grannarna fås en klassificering. K-NN modellen är olinjär, och antar inget om strukturen i de olika klasserna

I en **SIMCA** klassificerare<sup>11</sup> beräknas en PCA modell av lämplig dimensionalitet för varje klass. Genom att beräkna avståndet i och utanför modellen för en ny mätpunkt kan en

klassificering göras. SIMCA klassificeraren fungerar bäst för Gaussiskt fördelade klasser som kan vara olika för respektive klass.

Klassificeringsträd (**Classification trees**<sup>12</sup>) en samling metoder där en klassificeringsmodell byggs upp i en trädstruktur, via delningsregler (splitting rules). Denna modell kan sedan användas för att klassificera nya mätningar.

En grupp av klassificerare baserar sig på olika regressionsmodeller, där X är sensor data och Y utgörs av samma antal variabler som klasser. I träningsdata sätts Y som 1 om en observation tillhör klassen och 0 annars. Genom att hitta en multipel regressionsmodell fås en klassificerare som kan användas för att klassificera nya observationer. I en **PCR** klassificerare<sup>13</sup> är modellen en PCA baserad MLR modell. En **PLS-DA** klassificerare<sup>13</sup> använder en PLS modell. I en klassificerare baserad på artificiella neuronnät (**ANN**)<sup>14</sup> utgörs regressionsmodellen av ett feed-forward ANN. En metod som tilldrar sig allt mer intresse är support vector machines<sup>15</sup> (**SVM**), vilket verkar vara lovande metod.

## 2.2.4 Temporal filtrering

I klassificeringsmetoderna ovan tas inte hänsyn till att mätningarna görs på ett dynamiskt system. Till exempel kommer sannolikheten att en ny mätning x tillhör en viss klass bero på tidigare klassificeringar. Genom att nyttja historiken, kan ett stabilare beteende uppnås hos klassificeraren. Ett så kallat rekursivt filter löser denna uppgift.

I ett Bayes interferens filter<sup>16</sup> ges de filtrerade sannolikheterna av

$$S_i^T = p(x_i|Z_K) = \frac{p(z_K|x_i) * p(x_i|Z_{K-1})}{\sum_j p(z_K|x_j) * p(x_j|Z_{K-1})}$$

där  $p(z_K|x_i)$  är den senaste klassificeringen ( $S_i$  ovan),  $p(x_i|Z_{K-1})$  är priori informationen (senaste filtrerade klassificeringen). Ekvationen ovan förutsätter oberoende mätningar, vilket inte är fallet i vår applikation. För att kompensera detta införs en  $\alpha$ -faktor enligt

$$S_i^T(T) = \alpha * S_i^T(T) + (1 - \alpha) * S_i^T(T - 1)$$

där  $\alpha$  ligger mellan 0 och 1.  $\alpha$  kommer att bero på samplingshastigheten.

## 2.2.5 Fusion i nätverket

Fusion i nätverket kan antingen göras på särdrag (data fusion) eller på klassificerings sannolikheter (decision fusion). Data fusion ger i fallet för korrelerade sensorer optimalt resultat, men kräver högre datatrafik i nätverket. Det är dessutom oklart vilka särdrag som är optimala för en specifik sensor/omgivning/situation. Decision fusion är tillräckligt om sensorerna är oberoende i den aktuella applikationen. I den aktuella problemställningen är data i nätverket en blandning av beroende och oberoende delar. Nyligen publicerade studier<sup>17</sup> av liknande problemställningar (inkluderande både verklig och simulerad data) visar att decision fusion är ett minst lika bra alternativ som data fusion, givet de begränsningar som finns i dataöverföring och beräkningskapacitet för marksensornät. I denna studie studeras därför enbart decision fusion i nätverket, dvs. varje sensor klassificerar separat, följt av en fusionering mellan noder.

Ett första antagande baserad på diskussionen ovan är att varje nod klassar separat, och utsignalen från klassificeraren är mått på klasstillhörighet för respektive klass. Fusionen i nätverket kan göras med olika förfaranden beskrivna i litteraturen:

- Max
- Medel
- Summa
- Produkt
- Summa med avståndsviktning
- Röstning

En väletablerad metod för fusionen är att nyttja Bayes formel, dvs. sannolikheten att en observation tillhör klass  $i$  givet mätning  $Z$  kan skrivas

$$p(x_i|Z) = \frac{\prod_{k=1}^{\text{antal sig noder}} p(z_k|x_i)}{\sum_{j=1}^{\text{antal klasser}} \left( \prod_{k=1}^{\text{antal sig noder}} p(z_k|x_j) \right)}$$

där  $p(z_k|x_i)$  är utsignalen från klassificeraren för sensornod  $k$ . Sannolikheten för en viss klass kan alltså skrivas som produkten av sannolikheterna från alla signifikanta noder, normaliserat så att summan av alla klasser blir 1.

I praktiken måste eventuellt modifieringar göras, exempelvis att ta hänsyn till att olika sensorer har olika konfidens (mikrofon vs. geofon), och att konfidensen för en viss mätning beror på uppmätt energi.

## 2.3 Resultat

Framtagningen av den slutgiltiga modellen är en iterativ process, där de olika delarna i dataflödet optimeras tillsammans. Under respektive punkt nedan redovisas därför de avgörande resultaten vilka bestämmer utformningen för en viss modul, även om resultat från andra delar nyttjas i analysen.

### 2.3.1 Val av data

Frågeställningar:

1. Vilka data bör användas för modellframtagning/validering?

Variationen i särdrag/klassning

- under en passage
- mellan olika passager

är i samma storleksordning som för hela mätserier (med signifikant effekt). Data valda med 1% resp. 5% energi ger ungefär lika bra klassning  $\Rightarrow$  Urvalskriteriet är ej kritiskt för klassningen. Modellen tas därför fram på ett större dataset (t.ex. 1% energi med uppenbart dåliga mätningar borttagna). Därmed kommer vald data att täcka in stor variation och därmed ge bättre statistiska egenskaper för den framräknade modellen.

### 2.3.2 Val av särdrag

Frågeställningar:

1. Vilka särdrag ska användas?
2. Hur påverkar dimensionsreducering resultatet?

Vid val av särdrag som insignal till klassificeraren används 2 alternativ:

1. AR koefficienter (27variabler)
2. FFT koefficienter (512 variabler)

Teoretiskt bör dessa vara i princip likvärdiga, eftersom båda beskriver spektralinnehållet i den akustiska signalen. Det är t.ex. relativt enkelt att utifrån AR modellen skatta FFT spektrat.

Det viktigaste kravet vid val av särdrag är att de ska ge ett så litet klassificeringsfel som möjligt, speciellt för valideringsdata. Detta innebär att särdragen bör beskriva skillnaderna mellan de olika klasserna på ett så generellt sätt som möjligt. Andra faktorer som påverkar valet är hur enkel klassificerare som kan uppnås, och om det utifrån särdragen är möjligt att tolka orsaker till t.ex. skillnader mellan klasser eller effekter av olika typer av störningar.

Efter val av särdrag kan en dimensionsreducering göras med någon av metoderna beskrivna ovan. Denna reduktion optimeras med liknande kriterium som ovan, dvs. minimalt fel för valideringsdata.

I analysen nedan görs val av särdrag och analys av dimensionsreducering i samma steg.

I Figur 1 och Figur 2 visas AR respektive FFT koefficienter för två körningar med ett fordon. Notera skillnaderna mellan de olika körningarna, där FFT spektrat uppvisar en mycket tydligare struktur än AR koefficienterna. Tittar man i detalj på FFT figurerna ser man tydliga toppar, framförallt vid låga frekvenser. Dock varierar topparnas positioner och inbördes storlek, vilket försvårar framtagningen av en klassificerare. Figur 3 visar variationen för ett fordon under en 5 sekunders passage. Även under denna korta tidsperiod syns en signifikant variation för FFT spektrat, speciellt för högre frekvenser. Genom att studera skillnader mellan/inom klasser framstår FFT som ett bättre val, speciellt med avseende på möjligheten att tolka/förstå orsaker till t.ex. skillnader mellan klasser.

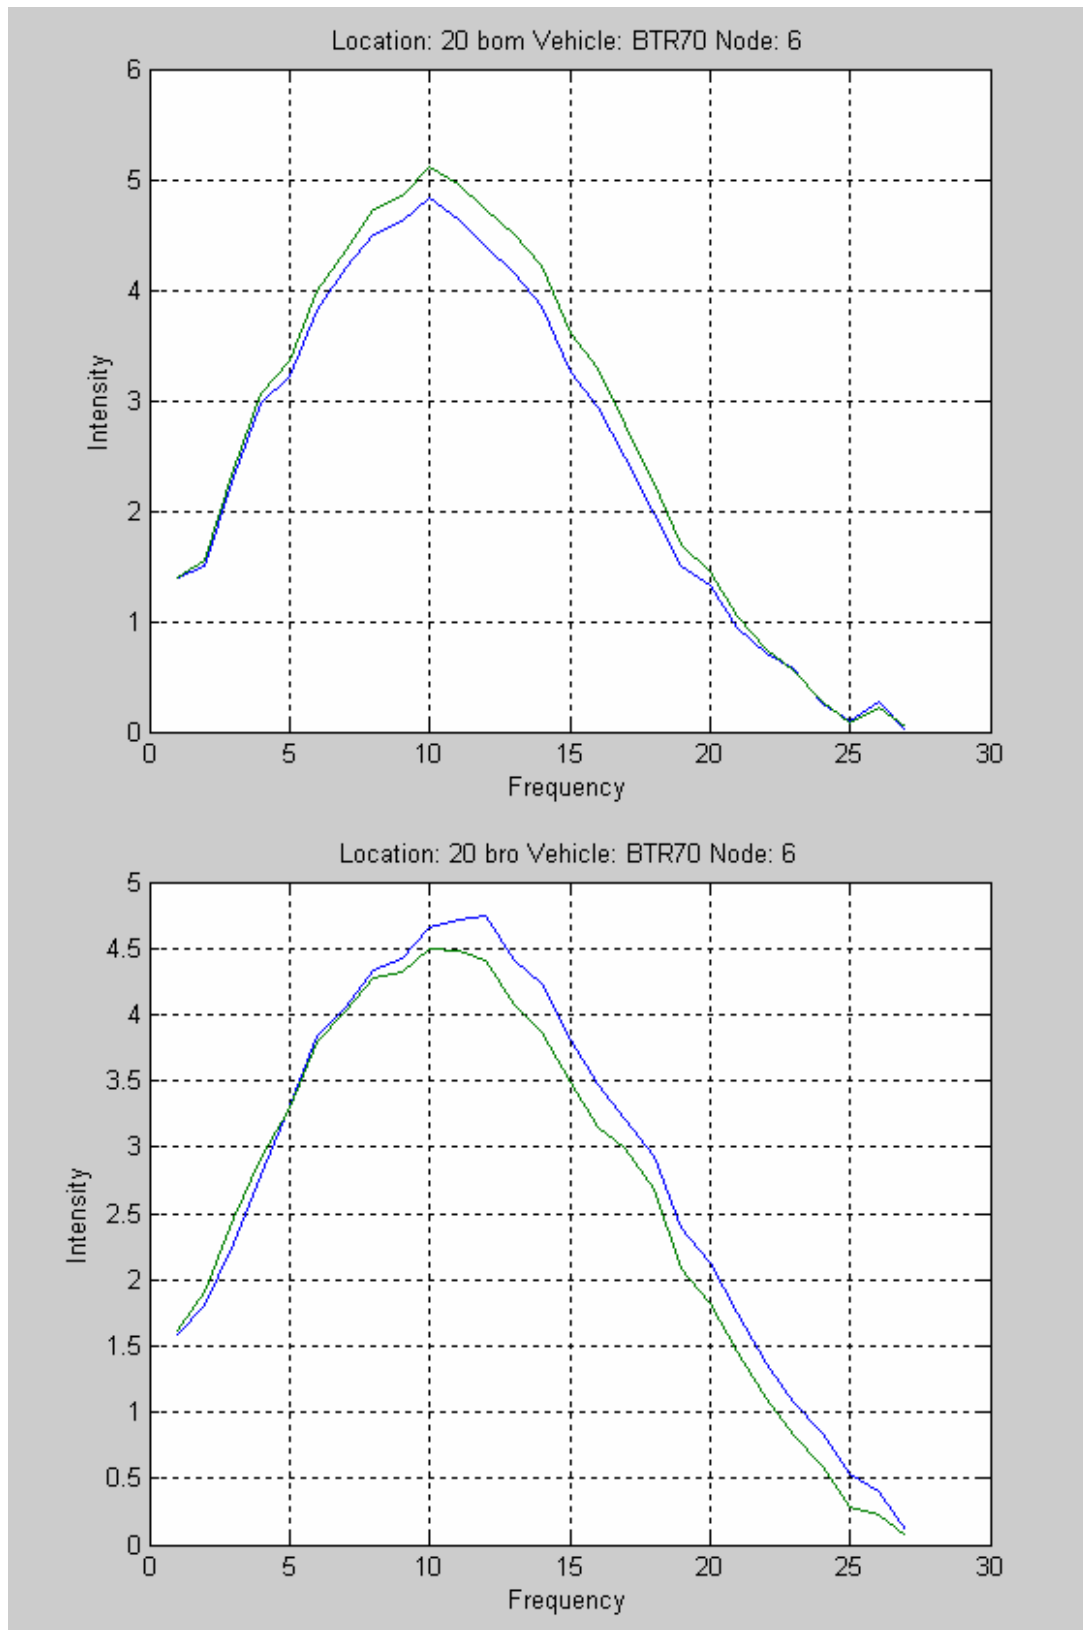
Den viktigaste faktorn för att välja särdrag är hur bra klassificerare som kan tas fram. För att undersöka detta togs en standard Bayes klassificerare fram, där data förbehandlades med PCA. Genom att välja olika antal PC att använda som insignal fick vi varierande komplexitet i klassificeraren. Hög noggrannhet med få antal PC indikerar högt informationsinnehåll bland de valda särdragen. I Figur 4 (FFT) och Figur 5 (AR) visas klassificeringsprestanda som funktion av komplexiteten i klassificeraren för både träningsdata (nod 6) och valideringsdata (nod 3). Ett antal observationer kan göras i dessa figurer:

- Jämförs enbart träningsdata ger AR koefficienterna bäst resultat då alla 27 koefficienterna används.
- För valideringsdata är skillnaden markant mellan AR och FFT. I FFT modellerna följer resultaten väl träningsdata och kommer snabbt upp till en hög korrekt klassificeringsgrad. För AR är skillnaden stor mellan träning och validering.
- För FFT planar kurvorna ut kring 10 PC och ingen markant förbättring uppnås därefter. För AR ger alla 27 koefficienter bäst resultat både i träning och i validering.

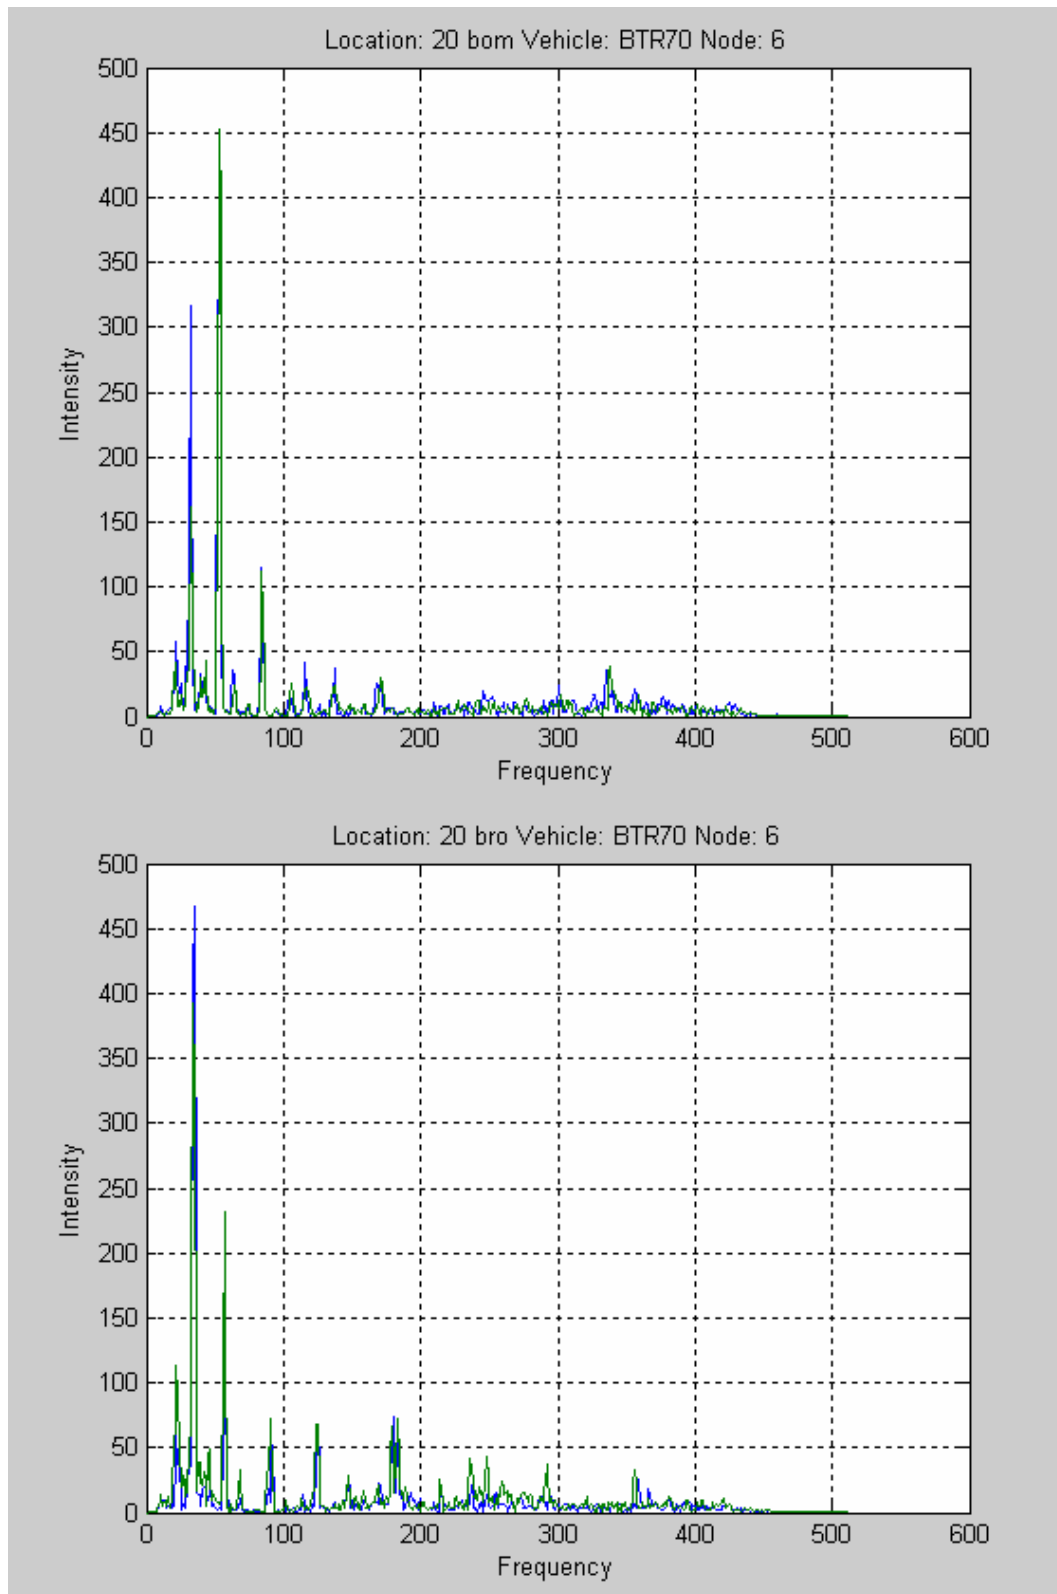
Jämförs resultaten för övriga mikrofonnoder visar även dessa att FFT ger en bättre modell för valideringsdata. I Tabell 1 jämförs FFT och AR, och för alla noder (förutom för träningsdata)

ger FFT tydligt bäst resultat. Sammanfattningsvis ger FFT koefficienterna en modell med bättre generaliseringsförmåga och lägre fel än AR koefficienterna. Den framtagna FFT modellen är dessutom enklare än motsvarande AR modell.

Nästa uppgift är att hitta en optimal dimensionallitet i PCA reduceringen. Kriteriet här är att hitta en så enkel (få PC) modell som möjligt, där valideringsdata ger ett tillräckligt bra resultat (Figur 4). Vid 10 PC finns ett knä där felet för valideringsdata inte minskar med ökande antal PC. En lämplig komplexitet är alltså 10 PC för detta problem. Notera att AR ger bäst resultat utan en PCA dimensionsreducering.




**Figur 1.** AR koefficienter för två körningar med BTR70. Blå resp. grön kurva är mätpunkter separerade med 0.5 sekunder.



**Figur 2.** FFT koefficienter för två köringar med BTR70. Blå resp. grön kurva är mätpunkter separerade med 0.5 sekunder.







**Figur 3.** T72, 20 bro, nod 3, registreringar under en 5 sekunders passage.

<b>Andel korrekta klassificeringar (%)</b>	<b>AR parametrar</b>	<b>FFT parametrar</b>
<b>Nod 6 (train)</b>	96	93
<b>Nod 3 (valid)</b>	70	88
<b>Nod 5 (valid)</b>	79	88
<b>Nod 8 (valid)</b>	73	86
<b>Nod 10 (valid)</b>	81	90

**Tabell 1.** Klassificeringsprestanda för olika noder med AR respektive FFT parametrar som input i klassificeraren. En standard Bayes klassificerare har använts med alla AR koefficienter respektive 10 PC från FFT som insignaler till klassificeraren.



Figur 4. Klassificeringsprestanda vs. modellkomplexitet för FFT parametrar.



Figur 5. Klassificeringsprestanda vs. modellkomplexitet för AR parametrar.

### 2.3.3 Jämförelse mellan klassificeringsalgoritmer

Frågeställningar:

1. Vilken klassificerarstruktur ger bäst resultat?
2. Kan de olika klasserna antas ha samma kovarians?

För att jämföra olika klassificerare gjordes modellering av ett antal olika klassificerarstrukturer. I Tabell 2 visas resultaten för tränings- och valideringsdata.

Slutsatser:

- Effekten av val av klassificerare verkar inte vara kritiskt i denna applikation. Andelen korrekt klassificerade observationer varierar mellan 82 – 91 % för valideringsdata.
- Ett antagande om gemensam klasskovarians verkar inte ha stöd i dessa resultat, utan Bayes modellen med olika klasskovarians ger bättre resultat.
- Bayes med olika klasskovarians ger en enkel modell med hög noggrannhet, vilket är den rekommenderade modellstrukturen för dessa data.
- Den mer (beräknings-/minnesmässigt) komplicerade kNN modell ger aningen bättre resultat än Bayes modellen. Detta tyder på att antagandet om Gaussiska fördelningar inte är helt korrekt. Dock är det svårt att rekommendera en kNN modell här, pga. större beräknings- och minnesbehov för denna modelltyp. Dessutom är en Bayes modell lättare att tolka och illustrera än en kNN modell.

Andel korrekta klassificeringar (%)	Nod 6 (träning)	Nod 3 (validering)
Bayes med olika kovarians för olika klasser	93	88
Bayes med gemensam kovarians	82	82
PCR	84	83
kNN	99	91
Tree	98	82
Simca	90	86

Tabell 2. Klassificeringsprestanda för mikrofonnoder med olika algoritmer.

### 2.3.4 Klassificerare för mikrofoner

Frågeställningar:

1. Kan en gemensam modell hittas för alla mikrofonnoder?
2. Hur kan klassificeraren optimeras för mikrofonnoder?

För mikrofonnoderna användes nod 6 för att ta fram en klassningsmodell. Tabell 1 visar att en modell framtagen för nod 6 också fungerar bra för övriga mikrofonnoder. Felen för valideringsdata är aningen större än för träningsdata men i samma storleksordning (~10 %). Detta visar att det är möjligt att hitta en klassificerare för mikrofonnoderna som är gemensam för alla noder.

Vidare visar resultaten att en klassificerare där indata reducerats med PCA till 10 insignaler ger en enkel modell där resultatet i valideringsdata inte förbättras av att ytterligare öka

komplexiteten i modellen. Ett antagande om olika kovarians hos de 6 klasserna ger bättre resultat än om samma kovarians antas för alla klasser.

Den framtagna klassificeraren ger ett fel på i storleksordningen 10 % både för tränings- och valideringsdata. Notera dock att ett antagande om att en mätning alltid tillhör en av de kända klasserna har gjorts i denna analys. Inkludering och analys av den ”okända klassen” görs i ett senare avsnitt. Detta är rimlig felnivå, eftersom en passage innehåller kraftigt varierande ljud p.g.a. växlingar, backar, etc.

### 2.3.5 Klassificerare för geofoner

Frågeställningar:

1. Kan en gemensam modell hittas för alla geofonoder?
2. Hur kan klassificeraren optimeras för geofonoder?

I Tabell 3 visas klassificeringsresultaten för AR respektive FFT parametrar. För AR användes alla 27 koefficienterna, och för FFT gjordes en PCA dimensionsreducering till 10 PC. Notera först den dåliga klassningen för valideringsdata. Det är alltså inte möjligt att med detta angreppssätt hitta en gemensam modell som kan användas på alla geofonoder. FFT modellen har genomgående en högre andel korrekta klassificeringar, men en prestanda på mindre än 50 % är inte tillfredställande.

Andel korrekta klassificeringar (%)	AR parametrar	FFT parametrar	FFT parametrar (Alla noder tränade separat)
<b>Nod 1 (train)</b>	97	88	88
<b>Nod 2 (valid)</b>	31	63	68
<b>Nod 5 (valid)</b>	11	45	87
<b>Nod 7 (valid)</b>	14	18	63
<b>Nod 9 (valid)</b>	13	38	91

Tabell 3. Klassificeringsprestanda för olika geofonoder.

Om separata modeller tas fram för de olika geofonoderna uppnås en högre andel korrekta klassificeringar. Dock bör nod 7 ej användas, eftersom den även för målspårsberäkningarna gav tveksam prestanda. Att använda separata modeller för respektive nod är dock en nödlösning som inte kommer att vara praktiskt möjlig att applicera i den verkliga applikationen.

Slutsatsen måste bli att det inte finns tillräckligt med generell information som möjliggör en klassificering, och därmed går det inte att hitta en gemensam modell för geofonerna. Detta beror troligen på att den uppmätta signalen påverkas starkt av kanalen (det vill säga marken mellan källan och sensorerna) och att dess egenskaper varierar med sensor positionen.

### 2.3.6 2 vs. 6-klass problemet

Här studeras möjligheten att särskilja hjul och band fordon. Frågeställningar:

1. Hur bra fungerar en 2-klassmodell jämfört med 6-klassmodellen?
2. Är det någon skillnad mellan mikrofoner och geofoner?

I Tabell 4 visas klassificeringsresultat för 2-klassproblemet med akustiska data. För FFT gjordes en initial dimensionsreducering med PCA till 5 dimensioner. Jämför dessa resultat med Tabell 2, där resultaten visas för 6-klassproblemet. I det enklare 2-klassproblemet blir resultatet endast aningen bättre (~2 %) än för 6-klassproblemet. Samma tendens ses i Tabell 5 för geofonerna, där 2-klassproblemet klassificeras endast aningen bättre än 50 %, dvs. slumpen.

Slutsatsen av detta är att två-klass problemet är i princip lika svårt som 6-klassproblemet. Detta innebär att det i data inte finns någon specifik information som klassificeraren hittar som kan separera hjul från bandfordon, vilket kan vara aningen förvånande. Notera dock att detta gäller för de särdrag som använts i denna analys.

För mikrofonerna förbättrades inte klassningen nämnvärt i 2-klassproblemet, jämfört med 6-klassproblemet. Slutsatsen av detta är att om klassificering ska göras i de två klasserna hjul och band, kan detta på enklast sätt göras med en initial klassificering i de 6 fordonsklasserna, följt av en tabellslagning för att ge 2 klasser.

För geofonerna var 2-klassmodellen knappt bättre än slumpen. Slutsatsen av detta måste vara att det inte finns någon enkel beslutsgräns som separerar de 2 klasserna. I stället måste de två klasserna i sig utgöra mer än ett kluster, där respektive klass inte kan separeras med en enkel gräns. Geofonerna bidrar inte till att förbättra klassificeringen i 2-klassfallet.

<b>Andel korrekta klassificeringar (%)</b>	<b>Nod 6 (träning)</b>	<b>Nod 3 (validering)</b>
<b>Bayes med olika kovarians för olika klasser</b>	90	90
<b>Bayes med gemensam kovarians</b>	90	90
<b>PCR</b>	90	90
<b>kNN</b>	99	94
<b>Tree</b>	98	92
<b>Simca</b>	91	91

Tabell 4. Klassificeringsprestanda i två-klassproblemet för mikrofonnoder (FFT) med olika algoritmer.

<b>Andel korrekta klassificeringar (%)</b>	<b>AR parametrar</b>	<b>FFT parametrar</b>
<b>Nod 1 (train)</b>	96	73
<b>Nod 2 (valid)</b>	49	64
<b>Nod 5 (valid)</b>	49	58
<b>Nod 7 (valid)</b>	52	48
<b>Nod 9 (valid)</b>	62	58

Tabell 5. Klassificeringsprestanda i två-klassproblemet för geofonnoder.

### 2.3.7 Effekter av okänd klass modellering

Frågeställningar:

1. Hur påverkas klassificeringen om en ”okänd klass” införs?

Med det valda angreppssättet för mätningar som inte faller i någon av de kända klasserna, påverkas självklart klassificeringsnoggrannheten. Med det aktuella datasetet/modellen kommer observationerna vilka klassas som okända i själva verket tillhöra en av de kända klasserna.

I Tabell 6 och Tabell 7 visas klassificeringsresultat för nod 3 med och utan att den okända klassen modelleras. För en perfekt klassificerare är sann klass = predikerad klass för alla observationer, dvs. alla observationer hamnar i diagonalen. Jämför man resultaten ses att klassificeringsnoggrannheten sjunker från 88 % till 86 % om den okända klassen inkluderas.

Andelen observationer i den okända klassen påverkas av den statistiska gräns som räknats fram. Ett större värde på  $P_{\chi^2\text{-limit}}$  kommer att ge fler observationer klassade som okänd. I det undersökta datasetet fungerar det  $\chi^2$ -baserade gränsvärdet tillfredställande. Ytterligare undersökningar är dock nödvändiga för att analysera inställningen av gränsvärdet.


För att exemplifiera effekten av modelleringen av okända observationer visas i Figur 6 och Figur 7 en körning med BRT70. I Figur 6 är prediktioner med 6-klassmodellen, och i Figur 7 visas prediktioner där den korrekta klassen är borttagen ur klassificeringsmodellen. Då den korrekta klassen tas bort ur modellen fås som väntat en klassning i ”okänd klass”, med vissa störningar initialt där säkerheten i särdrag inte är så stor som i senare skede.

	1	2	3	4	5	6	Okänd
1	378	12	0	0	15	13	0
2	101	809	2	0	19	5	0
3	9	1	318	0	26	0	0
4	6	0	2	383	52	1	0
5	13	0	13	8	340	2	0
6	5	23	5	3	9	397	0
okänd	0	0	0	0	0	0	0

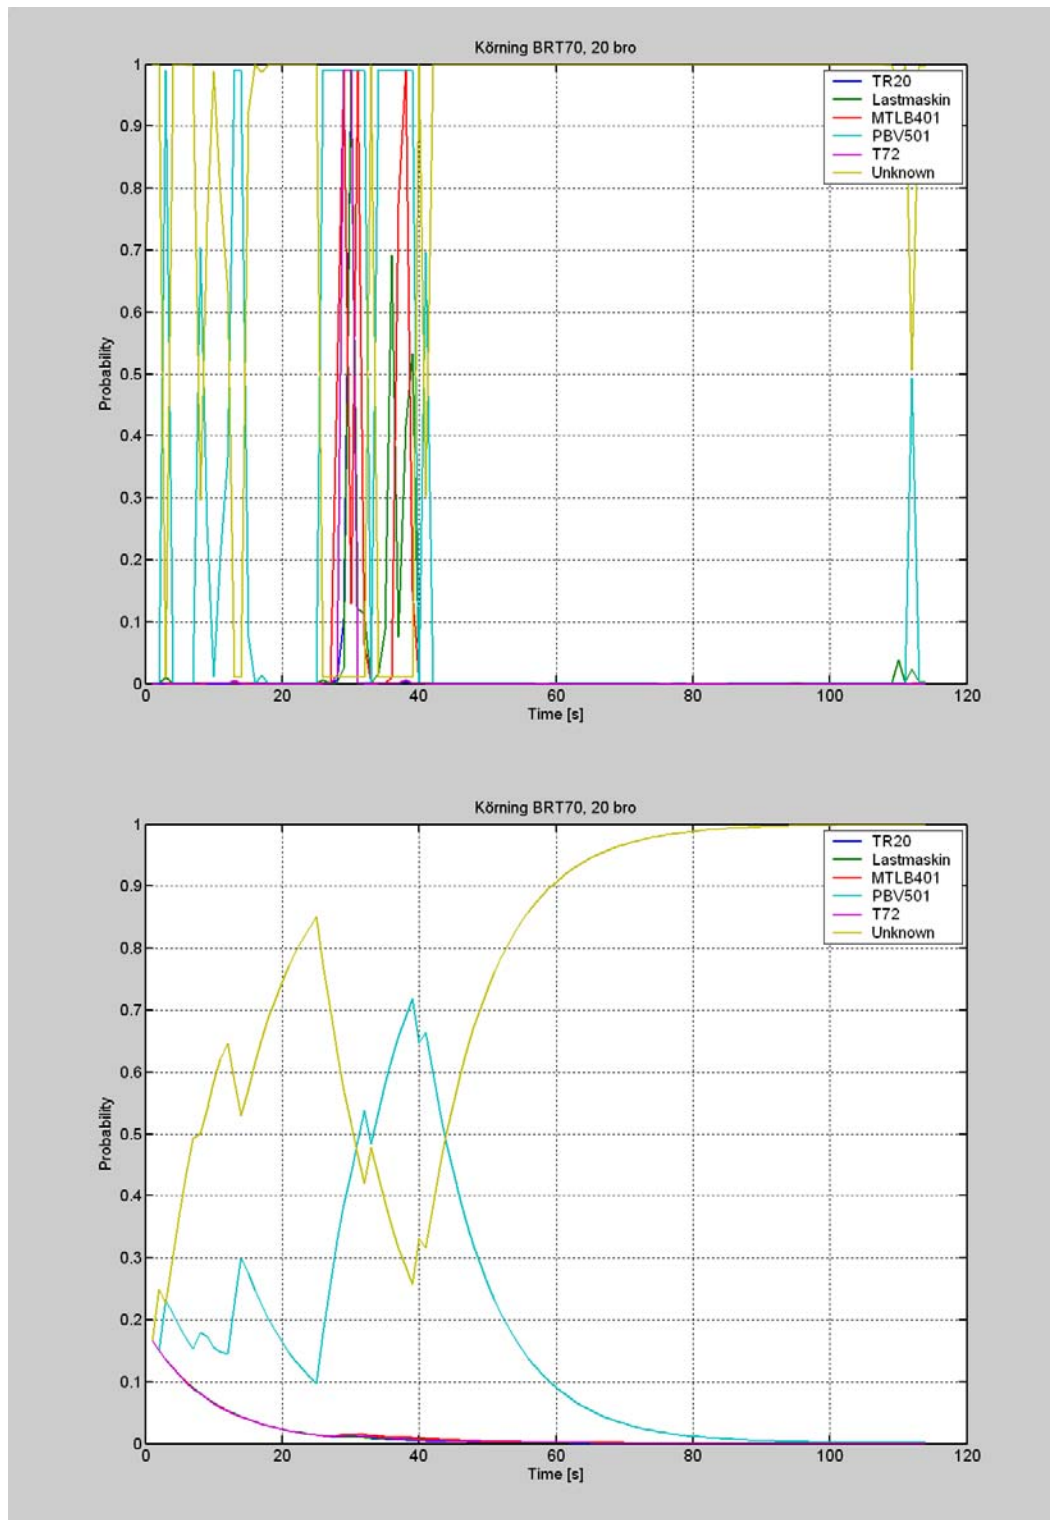
**Tabell 6.** Valideringsresultat med antagandet om att alla klasser är kända och att en mätning tillhör alltid någon av dessa. Sann klass i kolumner och predikerad klass i rader.

	1	2	3	4	5	6	Okänd
1	365	12	0	0	9	13	19
2	84	768	2	0	14	4	64
3	9	0	309	0	23	0	13
4	4	0	1	378	49	1	11
5	13	0	12	8	336	2	5
6	3	23	4	3	6	396	7
okänd	0	0	0	0	0	0	0

**Tabell 7.** Valideringsresultat med okänd klass. Sann klass i kolumner och predikerad klass i rader.



**Figur 6.** Körning 20 bro med BTR70, före (ovan) och efter (nedan) filtrering.



**Figur 7.** Körning 20 bro med BTR70, före (ovan) och efter (nedan) filtrering. I prediktionen är den "sanna" klassen (BTR70) ej medtagen.



### 2.3.8 Optimering av temporal filtrering

Frågeställningar:

1. Förbättras klassificeraren om tidigare klassningar nyttjas?
2. Förändras snabbheten med denna typ av algoritm?

I Figur 8 visas ett exempel på nyttan av temporal filtrering. Till vänster har utsignalen under en fordonspassage från en Bayes klassificerare plottats som funktion av tiden. Klassificeringarna varierar betydligt under passagen, och konfidensen i prediktionerna är relativt låg. Den gröna klassen ger mestadels högst värde. Genom att nyttja tidigare klassningar fås i den högra figuren tydligare information. Efter en insvängningsperiod, når den gröna klassen upp i hög konfidens, och en klassning kan göras med relativt stor säkerhet.


Tiden för insvängning har två orsaker. Den första osäkerheten är att informationen osäkrare när fordonet är på stort avstånd från sensorn (spektrat varierar mer), vilket avspeglas som en osäkrare klassificering. Den andra orsaken är  $\alpha$ -faktorn som ska kompensera för beroendet mellan näraliggande observationer. Den fungerar som ett lågpasfilter, som under konstanta förhållanden ger ett T90 % ungefär lika med 20 tidssteg för  $\alpha = 0.1$ . Ett större  $\alpha$  ger snabbare anpassning till nuvarande utsignal, med riskerar att ge för snabba anpassningar för förändringar i klassningen.  $\alpha$  är för denna applikation vald för att ge ett intuitivt korrekt utseende för klassning över tiden.

I Figur 9 respektive Figur 10 visas resultaten före och efter temporal filtrering för en verklig körning med optimerad klassificerare och filter. Klassificeringsmodellen inkluderar här den "okända klassen", vilket gör att sannolikheterna för fler än en klass ligger nära 1. I utsignalen från klassificeraren ligger sannolikheterna för klasserna "Lastmaskin" och "T72" initialt nära 1, och övriga klasser har låg sannolikhet.


Tittar man i detalj på klassningarna klassas dock mer än 95 % av observationerna till den korrekta klassen T72 (med maximum probability klassning), även om lastmaskinen ligger högt större delen av tiden.

För filtrerade signalen pekar utsignalen initialt på någon av de två mest troliga klasserna. Efter en viss tid, när tillräcklig information kommit in blir klassningen tydlig för klass T72. Filtringen medför alltså en säkrare och tydligare klassificering. Dessutom blir utsignalen efter filtrering mer lättolkad, och lättare att observera.


Nackdelen med filtreringen är att en tidsfördröjning introduceras i storleksordningen 10 sekunder. Tidsfördröjningen bestäms av samplingshastigheten och  $\alpha$ . Notera att denna fördröjning minskas med en högre samplingshastighet.



**Figur 8.** Exempel på före och efter temporal filtrering.



**Figur 9.** Klassificering under en körning med T72 för nod 3



**Figur 10.** Klassificering under en körning med T72, efter temporal filtrering.

### 2.3.9 Fusion mellan noder

Frågeställningar:

1. Hur ska fusion mellan noder utformas för bästa resultat?
2. Klarar nätverket av att klassificera hela körningar korrekt?

Dessa aspekter har inte undersökts i denna studie, utan kommer att belysas vid implementeringen/testningen av demonstratorn. Alla resultat tyder dock på att en Bayes-baserad sammanvägning av signifikanta sensorer kommer att lösa uppgiften tillfredställande. Detta motiveras framförallt med att de individuella sensorerna klarar klassificeringsuppgiften med hög prestanda, vilket innebär att en sammanvägd fusion kommer att bete sig minst lika bra.

### 2.3.10 Validering med tidigare genomförda mätningar

Frågeställningar:

1. Kan den framtagna modellen nyttjas för mätningar gjorda vid ett annat tillfälle?

För att undersöka frågeställningen ovan, nyttjades den tidigare beskrivna optimerade Bayes klassificeraren. Data insamlade vid ett tidigare tillfälle (juni 2003) används i valideringen. Tre mikrofonnoder använder (3, 8, 10). Tre olika fordon ingick i denna mätserie (BTR70, T72, Trettonbil), och mätningar gjordes vid ett antal passager vid olika hastigheter. Data in till klassificeraren var likvärdiga med tidigare beskrivna data, så data bör vara jämförbara.

Resultaten från alla relevanta körningar i valideringen visas i Tabell 8. Resultaten tyder på en betydande skillnad mellan mättillfällena. De två fordon som ingick i båda mätserierna,


BTR70 och T72, klassificeras inte alls lika bra som för den tidigare undersökta mätserien. För BTR70 ligger den korrekta klassificeringsgraden på 53 % och för T72 ligger den på 21 %, vilket ska jämföras med 90 % som var resultaten för den andra mätserien.

Undersöks enskilda körningar är tendensen liknande. För en BTR70 körning (Figur 11) dominerar initialt ”okänd klass”, och under senare skede finns en period en korrekt klassificering. För T72 (Figur 12) klassas körningen initialt som ett flertal olika fordon, däribland T72. Notera att dessa endast är exempel, och andra mönster är synliga för andra körningar.

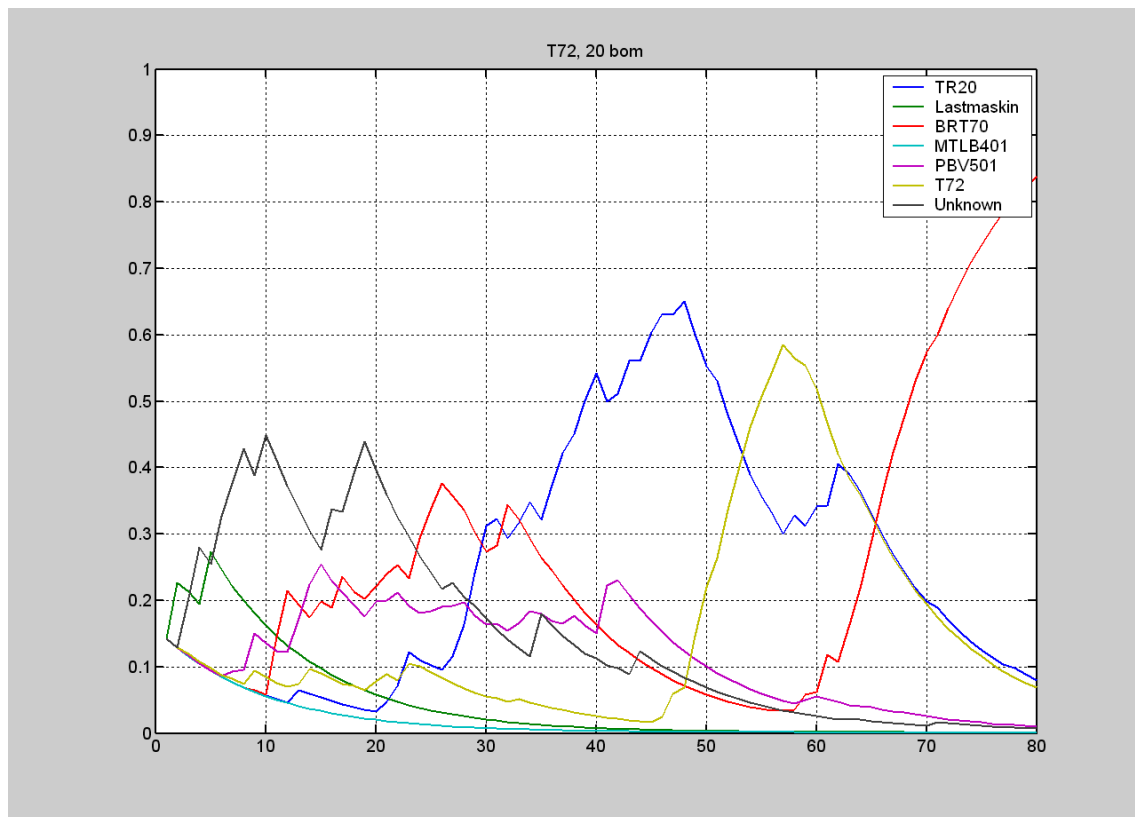
Slutsatsen av detta är att sensorsignalerna vid de två mättillfällena skiljer sig åt väsentligen, vilket omöjliggör en korrekt klassificering. Dessa skillnader kan bero på ett flertal olika faktorer, t.ex. sensorerna, placering, omgivning, väder, fordon,... Dessa orsaker har inte analyserats vidare. Konstaterandet måste dock vara att robustheten i de framtagna metoderna inte är tillräckligt stor. Den stora förbättringen i robusthet kan troligtvis göras genom att ta fram robustare särdrag som på ett tydligare sätt beror på skillnader mellan klasser, och inte beror i så stor utsträckning på omgivning, fordonsidentitet, mätbetingelser etc.

	TR20	Lastmaskin	BTR70	MTLB401	PBV501	T72	Okänd
BTR70	17 %	3 %	53 %	0 %	9 %	4 %	13 %
T72	29 %	2 %	23 %	0 %	7 %	21 %	18 %
Trettonbil	54 %	35 %	0 %	0 %	0 %	5 %	6 %

**Tabell 8.** Prediktionsresultat för mätningar gjorda i Kvarn under juni 2003. Kolumner motsvarar andel predikerad/klass och rader motsvarar den verkliga identiteten för fordonen.



**Figur 11.** Klassificering av BTR70 körning 20 bro, gjord i juni 2003.




**Figur 12.** Klassificering av T72 körning 20 bom, gjord i juni 2003.

## 2.4 Slutsatser för klassificering

- För mikrofoner kan en modell framtagen för en nod användas för klassning för övriga noder av samma typ. En klassifikationsnoggrannhet på 90 % är möjlig att uppnå både för 2- och 6-klass problemen.
- Geofonerna har ett tveksamt värde för klassificeringen av fordon.
- De flesta körningar (>90 %) klassas kumulativt korrekt om hela körningen studeras.
- FFT koefficienter + PCA dimensionsreducering ger en bättre klassificerare än AR koefficienter.
- De resulterande klassificeringsmodellerna blir dock relativt komplexa/svåra att tolka och kan därmed brista i robusthet. För ett större antal klasser/större variation inom klasserna är det tveksamt om den beskrivna algoritmen kommer att fungera väl.

## 3 Riktningbestämning

För att skatta riktningen till ett stridsfordon som kör i eller i närheten av det utplacerade marksensornätet använder vi en korrelationsmetod tillsammans med antagande om plana vågor<sup>2</sup>. Nätverket består av fem mikrofonnoder och fem geofonnoder. I varje sensornod finns tre sensorer (mikrofoner eller geofoner) placerade (med 120 graders mellanrum) så att de bildar en cirkulär array, se Figur 13.



**Figur 13.** En cirkulär array med tre sensorer s1, s2 och s3 som är placerade med 120 graders mellanrum.

För att skatta infallsvinkeln  $\theta$  beräknar vi först korskorrelationen mellan de uppmätta signalerna i sensor  $s_i$  och  $s_j$  enligt

$$C_{ij}(k_{ij}) = \frac{1}{N} \sum_{n=1}^N x_i(n)x_j(n-k)$$

där  $N$  är fönsterlängden och  $x_i(n)$  är den uppmätta signalen i sensor  $s_i$ . För att minska effekten av tillfälliga störningar i signalerna medianfiltreras de beräknade korskorrelationerna. Sedan söker vi de tidsförskjutningar  $k_{ij}$  som maximerar  $C_{ij}(k_{ij})$  då dessa ger skillnaden i ankomsttid för respektive sensorpar. Det sensorpar som har den minsta skillnaden i ankomsttid används vidare för att skatta riktningen till källan. Antag till exempel att den minsta skillnaden i ankomsttid hittas mellan signalerna uppmätta av sensor  $s_2$  och  $s_3$ . Riktningen till källan  $\theta$  ges då av



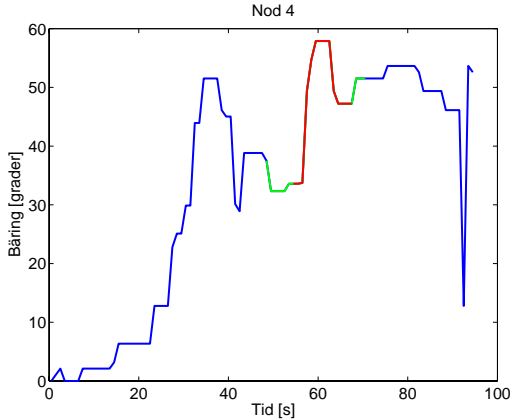



$$\theta = \arcsin\left(\frac{c k_{23} T}{2r \cos(\pi/6)}\right)$$

där  $c$  är utbredningshastigheten och  $T$  är samplingsintervallet. Metoden finns mer i detalj beskriven i <sup>2</sup>.


Bäringar har beräknats (med den beskrivna metod) för alla inspelningar som gjordes vid fältförsöket i Kvarn i oktober 2003<sup>1</sup>. Samplingsfrekvensen 44 kHz användes vid insamling av rådata. För riktningberäkningar har rådata sedan lågpasfilterats och nedsamplats till 12kHz. Signalerna delas därefter upp i observationsfönster av längden 1 sekund som flyttas med 1 sekund åt gången (det vill säga ej överlappande fönster). Bäringar beräknas slutligen för varje sådant observationsfönster vilket betyder att en bäring per sekunden och nod skattas.

Figur 14 visar skattade bäringar för alla noder för en inspelning av en BTR70 som körde med cirka 35 km/h (löpan BTR70 35 bom) längs den grusväg som gick genom sensornätverket. I figuren har olika energinivåer markerats med färg, i det rödmarkerade området är signalenergin minst fem procent av den maximala energin respektive minst en procent i det grönmarkerade området. De flesta noderna ger rimliga bäringar inom fem procents intervallet, och visa noder fungerar tillfredställande under hela passagen. Nod fyra och sju (båda är geofon-noder) fungerar dåligt under hela passagen, vilket också visar sig vara fallet för de flesta körningarna. Bäringar från dessa noder nyttjas följaktligen inte till målspårsberäkningar. Nod sju fungerar dåligt på grund av för lågt SNR, vilket man kan se i Figur 14 (signalenergin faller aldrig under fem procents nivån). Det är svårare att förklara varför nod fyra fungerar dåligt, men troligtvis beror det på varierande markförhållanden för de tre geofonerna i noden.

Sammanfattningsvis så fungerar riktningbestämning bra för de flesta passagera med både mikrofoner och geofoner. Mikrofonerna ger dock något stabilare resultat och är ofta enklare att placera ut i terrängen.







**Figur 14** Skattade bäringar för en passage av en BTR70 som körde med cirka 35 km/h på den grusväg som gick genom sensornätverket. Geofoner var placerade i nod 1,2,4,7,9 och mikrofoner var placerade i nod 3,5,6,8 och 10.

## 4 Målsparsberäkningar

### 4.1 Följefilter

Observationerna från varje sensornod kännetecknas av en mycket utdragen osäkerhetsellips med liten utsträckning i sida (bäringsled) och stor utsträckning i avstånd. Två olika följefilter studerades, båda baserade på Kalmanfilter. **1. Informationsfilter.** Alla noder kör var sitt filter och utbyter information (tillståndsvektor och inversen av kovarians), som enkelt adderas till en total information vilket ger stor redundans till priset av relativt stor dataöverföring. Har testats och funnits fungera väl. **2. Standard Kalmanfilter.** Alla bäringar kommuniceras till en ”agent” som ensam svarar för följningen. Relativt liten dataöverföring men risk för kollaps om agenten fallerar. Algoritmen är lånad från internet (ett paket sammanställt av Kevin Murphy). Har testats med en variant där ”samtidiga” observationer viks ihop m.a.p. läge och kovarians och fungerar bra. Något mindre bra resultat fås om observationerna istället läggs efter varandra. Förväntat problem med dynamiken pga mix av observationer väl åtskilda i tiden och nästan samtidiga observationer. Återstående avvikelse (medeltal) från vägen orsakas troligen av naturliga störningar i signalvägarnas utbredningsriktningar.

### 4.1.1 Multi Sensor Fusion

Med *datafusion* menas en process som kombinerar data och kunskap från olika källor med syfte att maximera nyttot innehåll i data, som kan vara osäkra, ofullständiga eller motsägelsefulla. Ofta arbetar sensorerna på kompletterande sätt med rådata i olika format - i vårt fall alstrade från mikrofoner och geofoner. Datafusion innefattar flera samverkande moment som delvis överlappar varandra. Upptäckt och (del)klassificering görs vanligen 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.

### 4.1.2 Informationsfilter

Ett *decentraliserat* datafusionssystem består av ett nätverk av sensornoder med var sin processorkapacitet. I ett sådant system sker datafusion lokalt vid varje nod baserat på egna observationer samt översänd information från närbelägna noder. (I ett *distribuerat* system "hoppas" information från nod till nod via en agent.) 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 sätt 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 Kalmanfilter i decentraliserad form

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  
 $\mathbf{P}(i|j) = E\{(\mathbf{x}(i) - \hat{\mathbf{x}}(i|j))(\mathbf{x}(i) - \hat{\mathbf{x}}(i|j))^T | \mathbf{Z}^j\}$  ..... estimatets kovarians

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

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

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

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

Informationen associerad med en observation kan då skrivas på formen

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

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

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. Det är spåragentens ansvar att hålla informationsutbytet via  $\mathbf{i}_i$  och  $\mathbf{I}_i$  vid ett minimum, samtidigt som spårstatimatet ändå följer målet. 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)

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

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

med matriserna

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

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

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

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

Med restriktionen om ett nätverk i två dimensioner (x-y planet) ges i det följande exempel på strukturen av grundläggande matriser i Kalmanfiltret, där  $T$  = tidsintervall för uppdatering,  $q$  = (liten) faktor,  $a^2$  = varians i bäringens riktning och  $b^2$  = varians tvärs bäring. Vid behov (avståndsmått) beräknas estimatets kovarians ur  $\mathbf{P} = \mathbf{Y}^{-1}$ .

$$\mathbf{F} = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad \mathbf{Q} = \begin{bmatrix} q & 0 \\ 0 & q \end{bmatrix}, \quad \mathbf{G} = \begin{bmatrix} T^2 & 0 \\ T & 0 \\ 0 & T^2 \\ 0 & T \end{bmatrix}, \quad \mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \quad \mathbf{R} = \begin{bmatrix} a^2 & 0 \\ 0 & b^2 \end{bmatrix}$$

Spårstart görs med ”tum-regel” parametervärden för mätbrus och processbrus, samt information och kovariansmatris för tillståndsvektorn. Speciellt gäller före första giltiga observation att informationsvektorn sätts till noll, tillståndsestimatet flaggas som obestämt och kovariansen startar som en diagonalmatris med mycket små elementvärden (liten information). Ett nytt mål observeras normalt först av en sensor i utkanten av nätverket. Osäkerhetsområdet för observationen, definierad av en medroterande  $\mathbf{R}$ -matris, markeras av en mycket utsträckt ellips i bäringens riktning. Det första lägesestimaten läggs i centrum av denna ellips. Åtföljande observationer från samma sensor adderar ytterligare information med tendens att artificiellt ”dra” målsåret mot sensorn. Efter hand bidrar andra sensorer med oberoende bäringar som kan förbättra spårföljningen. En viktig punkt

är här associationen observation - mål. Normalt släpps ("gating") giltiga observationer in genom ett största tillåtna fönster definierad av ett normaliserat avståndsmått,  $(\mathbf{z} - \hat{\mathbf{x}})^T \mathbf{P}_p^{-1} (\mathbf{z} - \hat{\mathbf{x}}) < maxgate$ , där  $\mathbf{P}_p$  är en delmatris av kovariansmatrisen  $\mathbf{P}$ , innehållande endast lägesdelen. Närliggande mål kan dock störa tolkningen av detta mått. Givet sannolikhet för att visst mål observerats av samma sensorer (ID-fusion) utesluts vid summeringen av  $\mathbf{i}_i$  och  $\mathbf{I}_i$  termer som inte ligger inom gränsen för avståndsmåttet. Detta har gjorts med framgång i ett simulerat scenario, diskuterat i avsnittet Modellsenario.

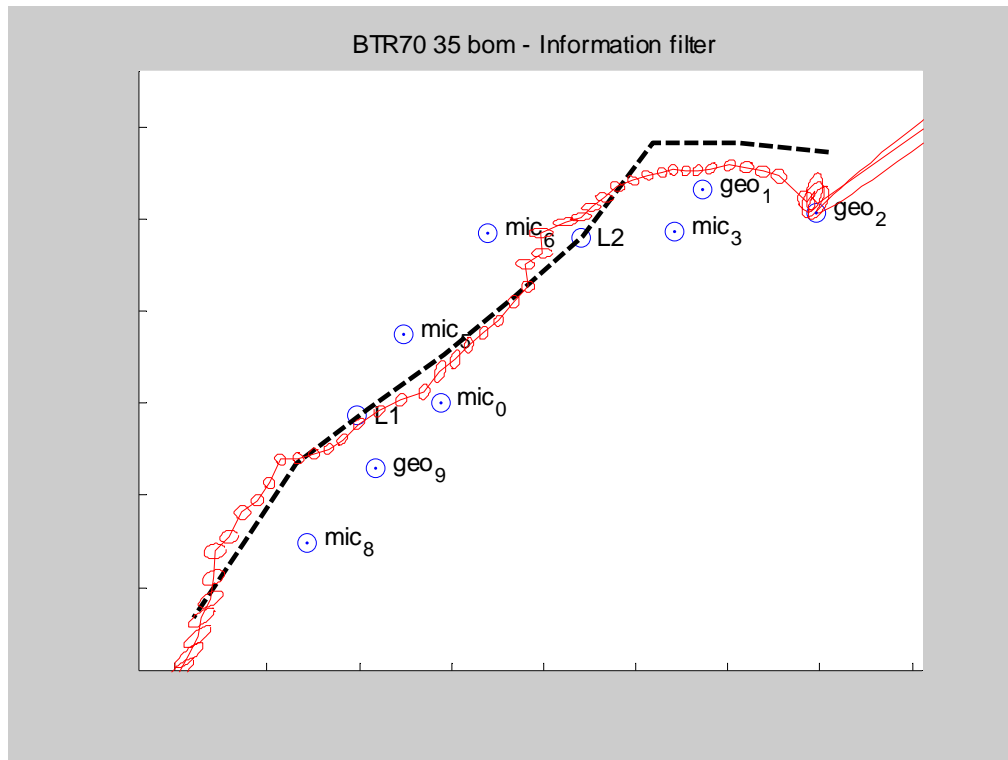
#### 4.1.3 Målsparberäkningar utifrån experimentella data

Bäringar har beräknats från experimentella data (enligt tidigare avsnitt). Med hjälp av dessa bäringar samt kännedom om nodernas positioner har målspar estimerats med hjälp av Kalmanfilter i såväl informationsform som standardform.

#### Utvärdering av Kalmanfilter i informationsform

Detta *informationsfilter* 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.

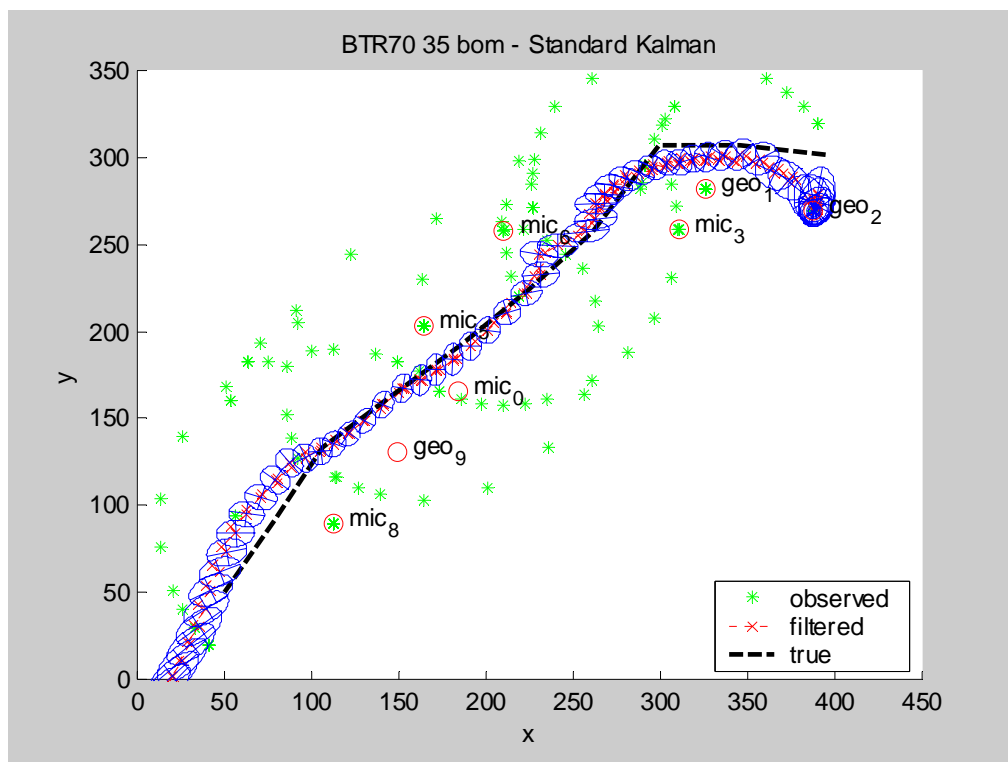
Figur 15 visar estimerat spår med tillhörande kovariansellipser (observera att kovarianserna pga mätosäkerheten är mycket större) av BTR70 observerade från 8 stationer med 5 mikrofonnoder och 3 geofonnoder (2 geofonnoder med misstänkta data röstades bort). Totala väglängden är omkring 450 m. Notera att 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.) Spårestimat med Kalmar filter i informationsform baseras enbart på bäringar som tillhör fem procent energinivå (rödmarkerat i Figur 14). Avvikelse från den sanna vägen (streckad linje) beror huvudsakligen på tre faktorer: 1) bias i nodernas lägen och orientering, 2) avvikande bäringar orsakade av naturliga störningar, 3) försummade tidsfördröjningar i signalvägarna. En del skarpa manövrer i spårestimaten kan antagligen också förklaras av ovan nämnda orsaker. Märk att kovariansellipserna inte täcker vägbanan, vilket kan bero på två faktorer: a) de aktuella kovarianserna täcker inte hela osäkerheten i tillståndsvektorn, b) återstår bias i observationerna (fel i nodpositionerna, störningar i vågutbredning; jämför Figur 16 med betydligt större kovariansellipser resulterande från standard Kalman). Beräknat på kortaste medelavstånd från vägen blir RMS felen i läge 5 m. Felet i fart, relativt en medelfart beräknad från tiderna för passagen vid två lasertriggar L1 och L2, är ca 1,8 m/s (7 km/h).



**Figur 15.** BTR70 35 bom körande med medelfart 35 km/h på en grusväg (streckad linje) med start uppifrån höger. Spårestimatet med tillhörande kovariansellipser baserat på Kalmanfilter i informationsformat, ett för varje nod. Mikrofonnoder (mic) och geofonnoder (geo) markeras med cirklar. Observationerna baseras på medianfiltrerade bäringar beräknade för varje sekund.

### Utvärdering av Kalmanfilter i standardform

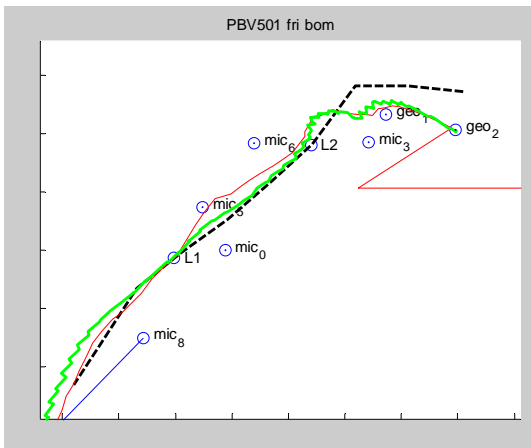
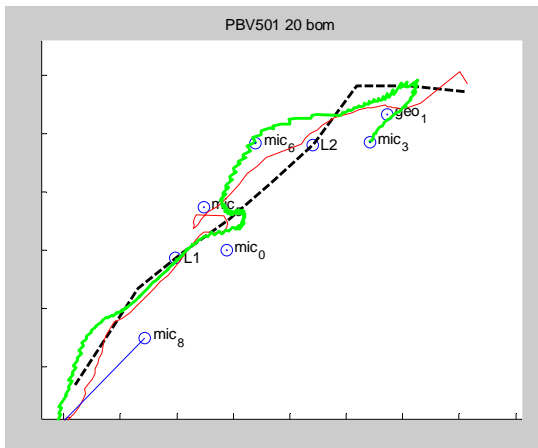
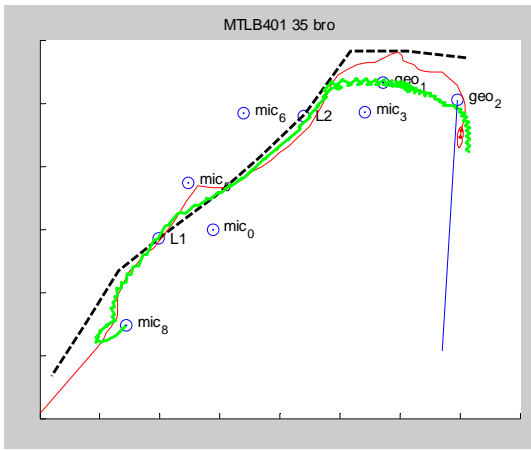
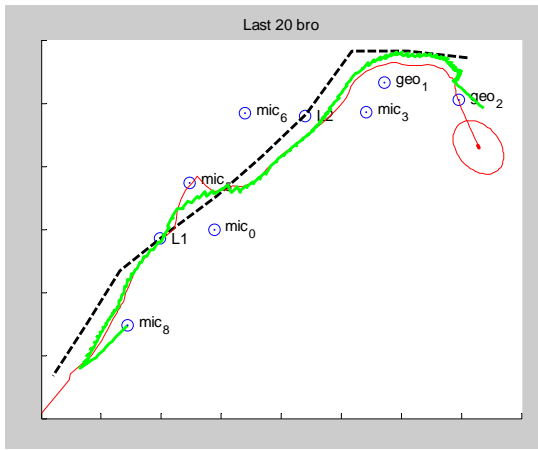
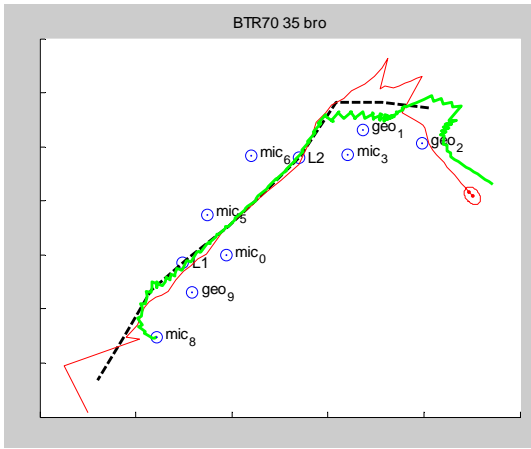
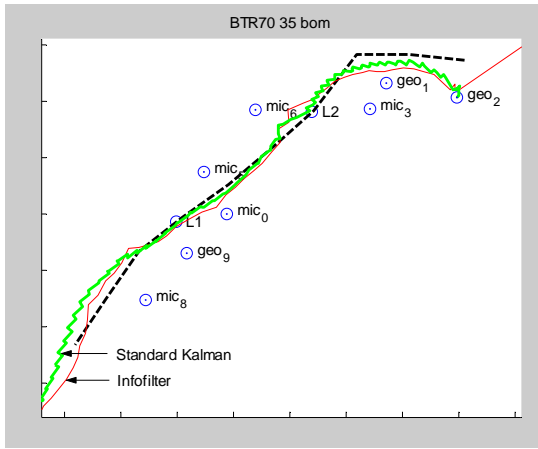
I ett distribuerat system med liten bandbredd i kommunikationsvägarna måste man falla tillbaka på en enklare nätverksmodell. En lösning är ett enda agentstyrt Kalmanfilter i standardform som anropar bäringar från närliggande noder allteftersom målet avlyssnas. Ekvationerna för Kalmanfiltret i standardform liknar de för informationsfiltret med den skillnaden att uppdatering sker på originalformen av tillståndsestimatet  $\hat{\mathbf{x}}$  och dess kovarians  $\mathbf{P}$ . Figur 16 visar spårestimat gjorda med Kalmanfilter i standardform gjord med en modifierad algoritm tagen från <sup>21</sup>. Filtret uppdaterar alla observationer tagna i sekvens med prediktion endast vid riktiga tidshopp (1-sekunds mätperiod; ett också prövat alternativ var att väga ihop alla nästan simultana observationer med sina kovarianser till en gemensam observation). Bäringarna är medianfiltrerade efter ett första urval på 5% energinivå eller högre. Även här har observationerna gallrats m.a.p. villkoret  $(\mathbf{z} - \hat{\mathbf{x}})^T \mathbf{P}_p^{-1} (\mathbf{z} - \hat{\mathbf{x}}) < maxgate$  (här = 18), vilket kan ha exkluderat ett antal extrema bäringar som degraderar spårkvaliteten. Spårstart är alltid en vanskelig historia men därefter sköter sig estimaten bra, i synnerhet omfattas vägen helt i mittsektionen av kovariansellipserna baserade på sekventiella observationer.

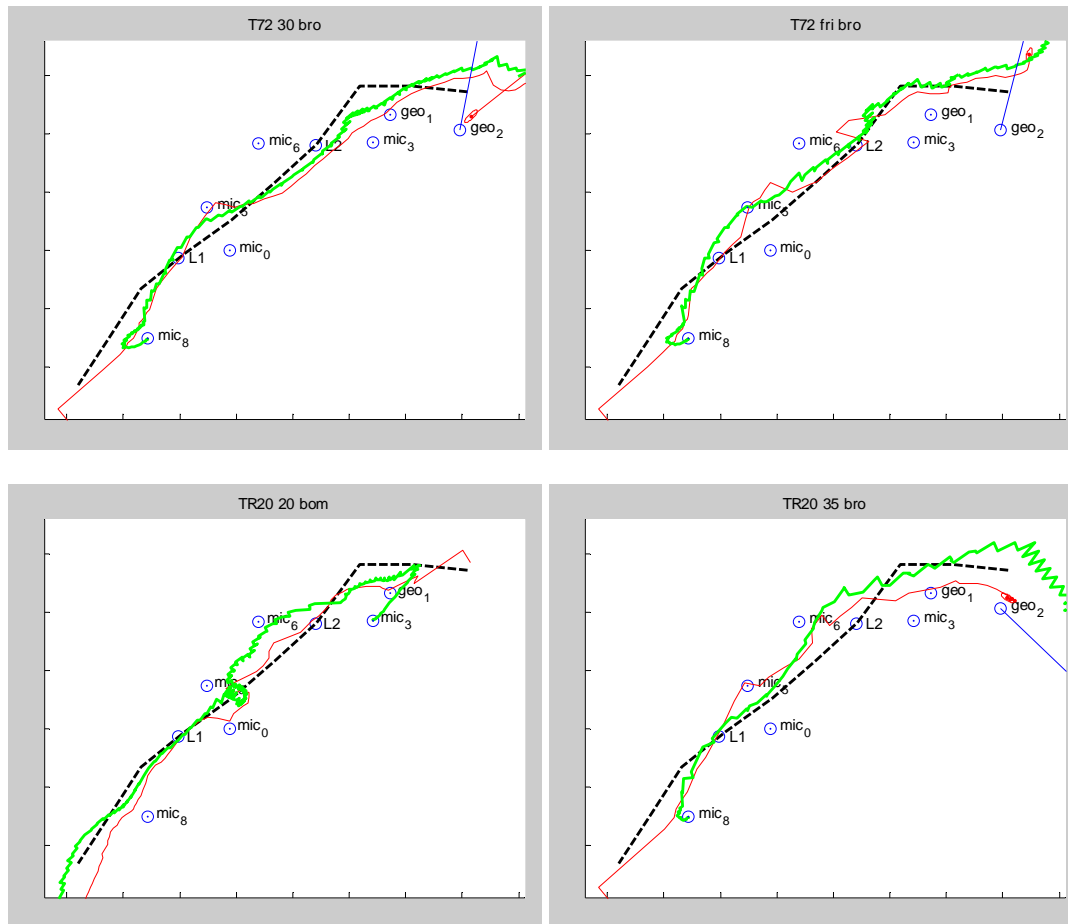


**Figur 16.** BTR70 35 bom körande med medelfart 35 km/h på en grusväg (streckad linje) med start uppfifrån höger. Spårestimatet med tillhörande kovariansellipser baserat på ett Kalmanfilter i standard format. Mikrofonnoder (mic) och geofonnoder (geo) markeras med cirklar. Observationerna (gröna stjärnor) är centrum på osäkerhetsellipser för positioner baserade på medianfilterade bäringar beräknade för varje sekund. Axlarnas koordinater är omräknade till enklare tal så att vägen startar vid (50, 50) i vänstra nedre hörnet.

#### 4.1.4 Jämförelse mellan spårestimat baserat på två olika Kalmanfilter

Bilderna i Figur 17 visar på varandra liggande spårestimat baserade på informationsfilter och standard Kalman. Bäringarna är medianfilterade efter första urval på 5% energinivå eller högre. Åtminstone ett fall från varje fordonstyp BTR70, Lastvagn, MTLB401, PBV501, T72 och TR20 har inkluderats. Exempel från både ”bom” och ”bro” fall visas så långt spårestimaten ser vettiga ut. Kovariansellipserna utelämnas för att inte gröta till bilden mer än nödvändigt. För det mesta följs spårestimaten från informationsfilter och standard Kalman åt väl. Informationsfiltret ger ofta en mjukare gång, men hoppar ut desto mer när något går snett. För tydlighets skull har endast estimatet baserat på informationsfiltret till nod 1 ritats ut (vid obegränsad bandvidd kan alla noder med tiden få samma information; i praktiken måste informationen portioneras ut där den behövs mest, därtill med viss eftersläpning). Standardfiltret startar något senare i ”bro”-fallen, vilket kan bero på att tekniken för spårstart här är annan än för informationsfiltret.





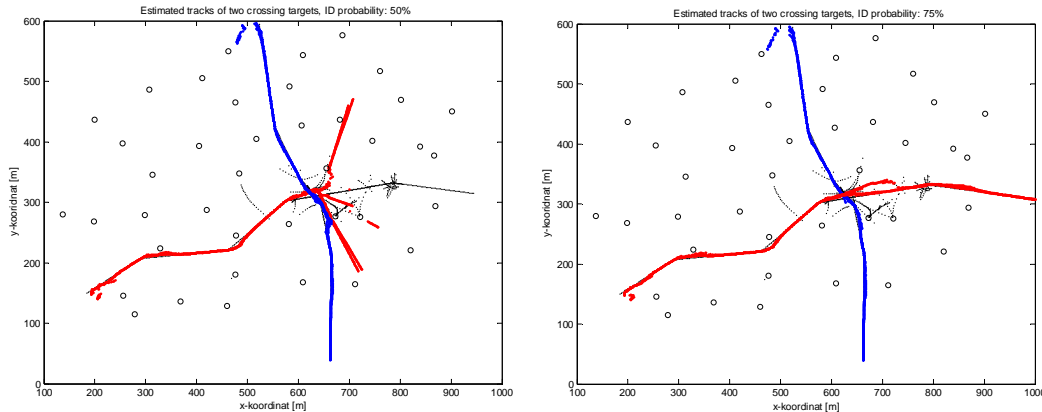
**Figur 17.** Jämförelse mellan spårestimat baserade på informationsfilter (röd smal kurva) och standard Kalman (grön tjock kurva). Vägen (sanna banan) är streckad i svart, noderna markeras med blå cirklar. I allmänhet inkluderas noder nr 1, 2, 3, 5, 6, 8, 9, 10, ibland med undantag för nod 2 och 9 för att inte förstöra spåret. Enstaka blå streck från en nod vid slutet av spårningen markerar en sista bäringsriktning.

## 4.2 Modellscenario

För att simulera effekten av ett trådlöst nätverk studerades rörliga mål i ett modellscenario. I det följande ges ett konstruerat fall med två fordon på nära kollisionskurs. Figur 18 visar ett exempel på två scener med 40 akustiska noder (o) som vid olika tidpunkter uppfångar ljud från två olika fordon (röda och blå spår). Punkterna markerar skärningar mellan bäringar från mikrofoner med nästan samtidigt mätningar. Huvudparten av dessa skärningar ligger på den sanna vägen. För att hålla detaljrikedomen nere har spårestimat från endast 5 sensorer markerats. Vänster bild fokuserar på korsningen där associationen av 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 sensorer. I detta fall sammanfaller huvuddelen av spårestimaten 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 18.** *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. 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.

## 5 Slutsatser

I den här rapporten har de signalbehandlingsmetoder som kommer att användas vid den demonstration som skall hålla inom IAM projektet i november 2004 presenterats. Det är metoder för att kunna klassificera, riktningbestämma samt positionera stridsfordon som kör i eller i närheten av ett sensornätverk. Dessa metoder har utvärderats med data ifrån ett fältförsök som genomfördes i Kvarn i oktober 2003. Vid fältförsöket samlades data in från sex olika fordonstyper (tre bandfordon och tre hjulfordon) som körde genom nätverket med olika fart och färdriktning. Inspelningarna gjordes med mikrofoner och geofoner.

För klassificeringsändamål har två metoder studerats; en som baserar sig på AR-modeller och en baserad på FFT analys. Efter dimensionsreducering med hjälp av PCA har vi funnit att FFT metoden fungerar bäst oavsett sensortyp. För mikrofonerna kan en klassificerare framtagen från en nod användas för klassificering i övriga mikrofonnoder. För geofonerna är detta inte möjligt, vilket gör att data från geofonerna inte är särskilt användbar för klassificeringsändamål. De resulterande klassificeringsmodellerna blir dock relativt komplexa/svårtolkade och kan därmed brista i robusthet. För större antal klasser eller då det är större variation inom klasserna är det därför osäkert om den föreslagna algoritmen kommer att fungera väl. Det är därför önskvärt att hitta andra särdrag som bättre fångar upp skillnader mellan de olika fordonen.

För att skatta riktningen till ett stridsfordon har vi använt en korrelationsmetod tillsammans med antagande om plana vågor. Mikrofonnoderna fungerar bra, dvs. metoden ger stabila och rimliga riktningar för större delen av inspelningarna. Tre av fem geofonnoder ger också rimliga riktningar. Att två geofonnoder inte fungerar beror på att signalnivån var för låg i den ena noden och i den andra är det troligen varierande koppling till marken som orsakar problemen.

Målsvarsberäkningar har gjorts utifrån de skattade bäringarna med hjälp av Kalmanfilter i både standardform som informationsform. Båda metoderna fungerar mycket bra och likvärdigt på de allra flesta inspelningarna. Kalmanfiltret i standardform har dock fördelen att det kräver betydligt mindre dataöverföring mellan noderna i nätverket, varför det är denna metod som kommer att användas vid demonstrationen.

Sammanfattningsvis så är resultaten som presenterats mycket positiva. Vi har metoder som är testade på verklig data som fungerar väl för klassificering, rikttningsbestämning samt målsvarsberäkningar. Det är dock önskvärt att hitta andra särdrag till klassificeringen så att denna kan göras robustare för förändringar i miljö eller signaturer.

## 6 Referenser

- <sup>1</sup> H. Habberstad, *Fältförsök med akustiska och seismiska givare i nätverk*, FOI-R--1087—SE, 2003
- <sup>2</sup> R.K. Lennartsson, *Redovisning av resultat från signalbehandling från fältmätningar gjorda under 2002*, FOI-03-1461, 2003
- <sup>3</sup> H. Martens and T. Naes, *Multivariate calibration*, John Wiley & Sons, 1989
- <sup>4</sup> T. Eklöv, I. Lundström and P. Mårtensson, *Selection of variables for interpreting multivariate gas sensor data*, *Analytica Chimica Acta*, 382, 221-232, 1999
- <sup>5</sup> A. Hyvärinen and E. Oja, *Independent component analysis: algorithms and applications*, *Neural Networks*, 13, 411-430, 2000
- <sup>6</sup> P. Geladi and B. Kowalski, *Partial least squares regression: a tutorial*, *Analytica Chimica Acta*, 185, 1-17, 1986
- <sup>7</sup> K. Fukunaga, *Introduction to statistical pattern recognition*, Academic Press, 1990
- <sup>8</sup> D. Lindgren, *Subspace Selection Techniques for Classification Problems*, Licentiate Thesis no. 995 Linköpings universitet, 2002
- <sup>9</sup> K. Fukunaga, *Introduction to statistical pattern recognition*, Academic Press, 1990
- <sup>10</sup> R. De Maesschalck, D. Jouan-Rimbaud, and DL Massart, *The Mahalanobis distance*, *Chemometrics and Intelligent Laboratory Systems*, 50, 2002, 1-18
- <sup>11</sup> G. Flåten, B. Grung, and O.M. Kvalheim, *A method for validation of reference sets in SIMCA modelling*, *Chemometrics and Intelligent Laboratory Systems*, 72, 101-109, 2004
- <sup>12</sup> L. Breiman, J.H. Friedman, R.A. Olshen, and C.J. Stone, *Classification and regression trees*, Wadsworth Inc., 1984
- <sup>13</sup> M. Barker and W. Rayens, *Partial least squares for discrimination*, *Journal of Chemometrics*, 17, 166-173, 2003
- <sup>14</sup> G.P.Zhang, *Neural networks for classification: a survey*, *IEEE Transactions on Systems, Man, and Cybernetics - Part C*, 30(4), 451-462, 2000
- <sup>15</sup> C.J.C. Burges, *A tutorial on support vector machines for pattern recognition*, *Knowledge Discovery and Data Mining*, 2(2), 121-167, 1998
- <sup>16</sup> S. Blackman, and R. Popoli, *Design and Analysis of Modern Tracking Systems*, Artech House, 1999
- <sup>17</sup> A. D'Costa and A. Sayeed, *Data versus decision fusion for classification in sensor networks*, *IEEE, ICASSP*, 2003, Hong Kong
- <sup>18</sup> E. Nettleton and H. Durrant-Whyte. Delayed and Asequent Data in Decentralised Sensing Networks. *Sensor Fusion and Decentralized Control in Robotic Systems IV*, vol. 4571, Gerard T. McKee and Paul S. Schenker, eds., SPIE Bellingham, Washington, 2001. <http://www.acfr.usyd.edu.au>.

---

<sup>19</sup> H. Durrant-Whyte and M. Stevens. Data Fusion in Decentralised Sensing Networks. *4<sup>th</sup> International Conference on Information Fusion*, Montreal, Canada, 2001.

<sup>20</sup> M. Ridley, E. Nettleton, S. Sukkarieh and H. Durrant-Whyte. Tracking in Decentralised Air-Ground Sensing Networks. *5<sup>th</sup> International Conference on Information Fusion*, Annapolis, U.S.A., 8-11 July, 2002.

<sup>21</sup> K. Murphy. Kalman filter toolbox. Last updated on 18 January 2003.  
<http://www.ai.mit.edu/~murphyk/Software/kalman.html>