

# Att upptäcka onormalt beteende till sjöss för sjöövervakningsbehov - Ämnesbeskrivning

Markus Koivisto

1 februari 2010

## Sammanfattning

I övervakningssammanhang är man i allmänhet intresserat av det som kan klassas till onormalt beteende. Det är dock väldigt svårt även för en erfaren operator att kunna märka onormala händelserna inom ett tätt informationsflöde. Det finns flera metoder för att upptäcka onormalt beteende. Denna avhandling presenterar och jämför de olika metoderna, och presenterar ett nytt sätt för att upptäcka onormalt beteende.

## Innehåll

<b>1</b>	<b>Introduktion</b>	<b>3</b>
1.1	Typer av onormalt beteende . . . . .	3
<b>2</b>	<b>Expert-system</b>	<b>3</b>
2.1	Tidsbaserade resonemang . . . . .	4
<b>3</b>	<b>Statistiska och probabilistiska metoder</b>	<b>4</b>
3.1	Modeller utan historia . . . . .	4
3.1.1	Tvådimensionell basmodell . . . . .	4
3.1.2	GMM/EM . . . . .	4
3.1.3	ARTMAP och Fuzzy ARTMAP . . . . .	4
3.1.4	SOM/GMM . . . . .	4
3.1.5	GMM med träd . . . . .	5
3.2	Modeller med historia . . . . .	5
3.2.1	Körbansklusterering . . . . .	5
3.2.2	Area-kodad körbansklusterering . . . . .	5
3.2.3	Prediktiv körbansklusterering . . . . .	5
3.3	Domän-specifika modeller . . . . .	5
3.4	Modeller för fartygsinteraktion . . . . .	5

<b>4</b>	<b>Kombination av modeller via halv-övervakad upplärning</b>	<b>6</b>
<b>5</b>	<b>Kombinering av statistiska metoder med expert-system</b>	<b>6</b>
<b>6</b>	<b>Metodologi</b>	<b>6</b>
<b>7</b>	<b>Experimentell evaluering</b>	<b>6</b>
7.1	Allmän prestanda . . . . .	6
7.2	Prestanda vid förbestämda typfall . . . . .	6
	<b>Referenser</b>	<b>7</b>

# 1 Introduktion

Introduktionen kartlägger vad sjöövervakning går ut på, hur ett modernt sjöövervakningssystem ser ut, och varför det är önskvärt att automatiskt upptäcka onormalt beteende.

OODA-cykeln och JDL-modellen presenteras.

## 1.1 Typer av onormalt beteende

Genom att intervjuja erfarna operatörer, kan man identifiera vilken typ av onormalt beteende är av särskilt intresse. Från trygghetssynpunkt är följande typer av särskilt intresse

- Fartyg som rör sig för snabbt / för långsamt
- Fartyg som rör sig åt fel håll inom trafikdelningsområden
- Fartyg som avviker från en etablerad rutt
- Fartyg som korsar trafikdelningsområden med en för liten vinkel
- Fartyg som ligger i kollisionsfara
- Fartyg som är i fara för att åka på grund

Från en säkerhetssynpunkt är följande intressanta:

- Fartyg som potentiellt är inblandade i smuglingsoperationer
- Fartyg som har fel identifikationer
- Fartyg som beter sig på oväntade sätt
- Fartyg som genskjuter andra fartyg
- Fartyg som närmar sig vissa mål utan tidigare tillstånd

## 2 Expert-system

Expert-system använder statiska regler, och avfyrrar varningar då reglerna bryts. Expertsystem är enkla att implementera - deras svaghet är att det ofta är väldigt svårt att formulera vettiga regler. Dessutom är de oflexibla. Intervjuer med experter kan användas för att skapa nya regler.

## 2.1 Tidsbaserade resonemang

Tidsbaserade regler (avfyra en varning då ett fartyg brytit mot en regel för 5 min) är också populära, och mera flexibla än rent statistiska regler. De lider dock till en stor del av samma problem.

## 3 Statistiska och probabilistiska metoder

Statistiska metoder utgår från antagandet “onormalt beteende är det som är icke-normalt”. Genom att via statistiska klusterings-metoder etablera en modell för normalt beteende, kan man jämföra nya observationer mot modellen, och på så sätt utan förkunskap märka onormalt beteende.

### 3.1 Modeller utan historia

Modell utan historia har ingen kunskap om det som skett tidigare - de evaluerar all beteende i “nuet”.

#### 3.1.1 Tvådimensionell basmodell

Basmodeller tar endast  $u$ - $v$ -komponenterna i beaktning. Kartan indelas i rutor, och ett medeltal samt standardavvikelse mäts på basen av träningsdata. De som ligger utanför  $n$  sigma anses vara onormala.

#### 3.1.2 GMM/EM

Modellen ovan tas vidare via en gaussisk mixture, som tillåter en kombination av flera kluster.

Modellen utvidgas vidare till en fyrdimensionell  $[x \ y \ u \ v]$ -modell.

#### 3.1.3 ARTMAP och Fuzzy ARTMAP

ARTMAP är en modell som använder sig av neurala nätverk för att hitta onormalt beteende.

#### 3.1.4 SOM/GMM

SOM eller Kohonen Maps används för att bygga upp ett träd. GMM används för att hitta mått på hur onormalt nytt beteende är.

### **3.1.5 GMM med träd**

En ny metod presenterad på NATO-konferens i höst. GMM-kluster placeras i ett träd via en online-metod. Trädet upprätthålls och beskärs vid behov.

## **3.2 Modeller med historia**

Modeller med historia tar i beaktan tidigare kunskap av fartygets beteende.

### **3.2.1 Körbansklusterering**

Vi delar upp fartygets körbana i segment. Fartyg som har en onormal kombination av segment (u-sväng etc.) anses vara onormala.

### **3.2.2 Area-kodad körbansklusterering**

Körbanorna delas upp i bitar på basen av vilka kartrutor/övriga areor de korsat. (AABB CD kan vara t.ex. Hamnen, Hamnen, Ärstan, Ärstan, etc). De som visar avvikande kodning anses vara onormala

### **3.2.3 Prediktiv körbansklusterering**

Fartygets körbana används för att förutspå vart fartyget åker till nästa. Om prediktionen och observationen inte stämmer överens, anses fartyget bete sig onormalt.

## **3.3 Domän-specifika modeller**

Vi går nu upp längs med JDL-modellen och tar i beaktan fartygsidentifikation etc. Vi kan märka att olika typer av fartyg beter sig annorlunda - t.ex. beter sig passagerarfartyg och nöjesfartyg på olika sätt - likväl oljetankers och lastfartyg. Genom att använda oss av denna kunskap, kan vi märka fartyg som beter sig normalt i allmänhet, men onormalt för just den fartygstypen.

## **3.4 Modeller för fartygsinteraktion**

Vi går upp längs med JDL-modellen igen till nästa nivå, och försöker ta i beaktan interaktion mellan fartyg.

## **4 Kombination av modeller via halv-övervakad upplärning**

Vi implementerar flera modeller, och använder oss av neuralt nätverk eller annat upplärningssystem för att lära oss vad som är onormalt beteende genom användarintervention vid gränstal. Tänk på spam-klassifiering.

## **5 Kombinerad av statistiska metoder med expert-system**

Vi kombinerar dynamiska metoder med statistiska metoder - fartyg som är suspekta har mindre utrymme för onormalt beteende. Fartyg som är t.ex. underhållsfartyg får mera utrymme för avvikande beteende.

## **6 Metodologi**

AIS- och radar-data från finskt övervakningsnät används för att lära upp modellerna.

## **7 Experimentell evaluering**

Modellerna evalueras i MATLAB.

### **7.1 Allmänna prestanda**

Vad är CFAR och övriga allmänna faktorer?

### **7.2 Prestanda vid förbestämda typfall**

Vi identifierar förbestämda olyckor / andra suspekta fall. Hur klarar sig modellerna då de jämförs mot dessa?

## Referenser

- [1] Awm. Microsoft powerpoint - gmm14. pages 1–30, Nov 2004.
- [2] Neil A Bomberger, Bradley J Rhodes, M Seibert, and A Waxman. Associative learning of vessel motion patterns for maritime situation awareness. *Proceedings of the 9th International Conference on . . .*, Jan 2006.
- [3] Craig Carthel, Stefano Coraluppi, and P Grignan. Multisensor tracking and fusion for maritime surveillance. *Information Fusion*, Jan 2007.
- [4] A Dahlbom and L Niklasson. Trajectory clustering for coastal surveillance. *Information Fusion, 2007 10th International Conference on*, pages 1–8, 2007.
- [5] C Fraley and AE Raftery. How many clusters? which clustering method? answers via model-based cluster analysis. *The Computer Journal*, 41(8):578–588, 1998.
- [6] M Guerriero, Peter Willett, Stefano Coraluppi, and Craig Carthel. Radar/ais data fusion and sar tasking for maritime surveillance. *Information Fusion*, Jan 2008.
- [7] T Izo and WEL Grimson. Unsupervised modeling of object tracks for fast anomaly detection. *IEEE International Conference on Image Processing, 2007. ICIP 2007*, 4, 2007.
- [8] J Kraiman, S Arouh, and M Webb. Automated anomaly detection processor. *Proceedings of SPIE*, Jan 2002.
- [9] R Laxhammar. Anomaly detection for sea surveillance. *Information Fusion, 2008 11th International Conference on*, pages 1–8, 2008.
- [10] L Niklasson, Maria Riveiro, F Johansson, and A Dahlbom. Extending the scope of situation analysis. *Information Fusion*, Jan 2008.
- [11] M Nilsson, J van Laere, T Ziemke, and J Edlund. Extracting rules from expert operators to support situation awareness in maritime surveillance. *Information Fusion, 2008 11th International Conference on*, pages 1–8, 2008.
- [12] Bradley J Rhodes, Neil A Bomberger, M Seibert, and A Waxman. Maritime situation monitoring and awareness using learning mechanisms. *IEEE Military Communications Conference*, Jan 2005.

- [13] B Ristic, B La Scala, M Morelande, and N Gordon. Statistical analysis of motion patterns in ais data: Anomaly detection and motion prediction. *Information Fusion*, Jan 2008.
- [14] Maria Riveiro. Final year projects: maritime anomaly detection. pages 1–3, Nov 2008.
- [15] Maria Riveiro, Göran Falkman, and T Ziemke. Improving maritime anomaly detection and situation awareness through interactive visualization. *Information Fusion, 2008 11th International Conference on*, pages 1–8, 2008.
- [16] Maria Riveiro, Göran Falkman, and T Ziemke. Visual analytics for the detection of anomalous maritime behavior. *Information Visualisation*, Jan 2008.
- [17] Maria Riveiro, F Johansson, Göran Falkman, and T Ziemke. Supporting maritime situation awareness using self organizing maps and gaussian mixture models. *Tenth Scandinavian Conference on Artificial Intelligence: ...*, Jan 2008.
- [18] M Seibert, Bradley J Rhodes, Neil A Bomberger, and P Beane. Seecoast port surveillance. *Proceedings of SPIE Vol. 6204: Photonics for Port and Harbor ...*, Jan 2006.
- [19] RR Sillito and RB Fisher. Semi-supervised learning for anomalous trajectory detection.
- [20] J Verbeek, N Vlassis, and B Krose. Efficient greedy learning of gaussian mixture models. *Neural Computation*, Jan 2003.