

LINUS J. LUOTSIMEN, FREDRIK JOHANSSON,  
MIKAEL LUNDIN, PETTER ÖGREN, EMIL SALLING

FOI är en huvudsakligen uppdragsfinansierad myndighet under Försvarsdepartementet. Kärnverksamheten är forskning, metod- och teknikutveckling till nyta för försvar och säkerhet. Organisationen har cirka 1000 anställda varav ungefär 800 är forskare. Detta gör organisationen till Sveriges största forskningsinstitut. FOI ger kunderna tillgång till ledande expertis inom ett stort antal tillämpningsområden såsom säkerhetspolitiska studier och analyser inom försvar och säkerhet, bedömning av olika typer av hot, system för ledning och hantering av kräver, skydd mot och hantering av farliga ämnen, IT-säkerhet och nya sensorers möjligheter.

Linus J. Luotsinen, Fredrik Johansson, Mikael Lundin, Petter Ögren,  
Emil Salling

## Årsrapport 2012, Syntetiska aktörer

**Titel** Årsrapport 2012, Syntetiska aktörer

**Title** Annual report 2012, Synthetic actors

**Rapportnr / Report no** FOI-R--3557--SE

**Månad / Month** December

**Utgivningsår / Year** 2012

**Antal sidor / Pages** 64p

**ISSN** 1650-1942

**Kund / Customer** FM

**FoT område** Modellering och simulering

**Projektnr / Project no** E36702

**Godkänd av / Approved by** Lars Höstbäck

**Ansvarig avdelning** Informations- och aerosystem

Detta verk är skyddat enligt lagen (1960:729) om upphovsrätt till litterära och konstnärliga verk. All form av kopiering, översättning eller bearbetning utan medgivande är förbjuden.

This work is protected under the Act on Copyright in Literary and Artistic Works (SFS 1960:729). Any form of reproduction, translation or modification without permission is prohibited.

## Sammanfattning

Denna rapport beskriver verksamhet och resultat från projektet *Synthetiska aktörer* (FoT nr 922:01.03) under året 2012. Syftet med projektet är:

- tillgodose Markstridsskolans behov av förbättrad simuleringsbaserad träning av staber vid militära insatser i urban miljö med fokus på populationen och dess tillstånd,
- anskaffa kunskap, utveckla verktyg, metoder och algoritmer med ändamålet att skapa eller underlätta skapandet av synthetiska aktörer för användning i FMs nuvarande och framtidiga simuleringsbaserade verktyg för träning och beslutsstöd.

Projektet har sedan 2009 utvecklat en prototyp, POPIM, som är en simulator där populationer och dess beteenden modelleras och simuleras på individnivå i stadsmiljö. Vidareutveckling av POPSIM har varit huvudaktiviteten i projektets verksamhet under 2012. POPSIM består idag utöver själva populationsmodellen även av modeller vilka representerar omvärld och infrastruktur (byggnader, vägnät och mobiltelefoni), irreguljära styrkor samt militära insatsstyrkor. Några av höjdpunkterna i årets verksamhet med avseende på populationsmodellen har varit införandet av relationer mellan individer i populationen samt införandet av opinionsdynamik för modellering av t.ex. populationens inställning till de militära insatsstyrkorna.

Utöver vidareutveckling av POPSIM har verksamheten under 2012 bestått av mindre studier med inriktning på beteendemodellering med avseende på imitering, optimering och detektion av beteenden. Syftet med denna verksamhet har främst varit att på lång sikt stötta beteendemodellering i POPSIM men anses även vara relevant i andra liknande simuleringsbaserade verktyg.

Slutligen har projektet under 2012 medfinansierat och deltagit i projektet *European Urban Simulation for Asymmetric Scenarios* (EU-SAS).

## Nyckelord

Intelligenta agenter, multi-agent system, multi-agent simuleringsbaserad modellering, populationssimuleringsbaserade aktörer, beteendeimitering, beteendeoptimering, beteendedetektion

## Abstract

This report describes the work that was conducted within the project *Synthetic actors* (FoT nr 922:01.03) in 2012. The purpose of the project is:

- to provide the Swedish ground combat school with tools targeting the modeling and simulation of populations to improve the training of military personnel in military operations in urban terrain,
- to acquire knowledge, develop tools, methods and algorithms targeting the modeling of synthetic actors for use in today's as well as the future simulator systems of the Swedish Armed Forces.

The project has since 2009 developed a prototype, POPSIM, which is a tool developed to simulate population behaviors in urban areas on an individual level of abstraction. The development of POPSIM has been the main activity of 2012. In addition to the population behavior model, POPSIM also include models to represent environment and infrastructure (buildings, road-network and mobile communication), irregular forces and military forces. Some of the highlights of this year's work has been the addition of relationships within the population and the development of opinion dynamics to model, for instance, the population's attitude towards the military forces.

The project has, in addition to the POPSIM activity, also conducted several smaller studies focusing on behavior modeling. Specifically, these studies explored the possibilities to imitate, optimize and recognize behaviors. The purpose of these studies has primarily been to support the development of POPSIM but are also considered relevant in other similar simulation tools.

Finally, the project has in 2012 co-financed and participated in the *European Urban Simulation for Asymmetric Scenarios* (EUSAS) project.

## Keywords

Intelligent agents, multi-agent systems, multi-agent simulation, agent-based modeling, population simulation, computer generated forces, behavior imitation, behavior optimization, behavior recognition

# Innehåll

<b>1 Introduktion</b>	<b>8</b>
1.1 Bakgrund . . . . .	8
1.2 Projektet syntetiska aktörer . . . . .	8
1.3 Verksamhet . . . . .	8
1.4 Rapportens syfte . . . . .	9
1.5 Avgränsningar . . . . .	9
1.6 Genomförd rapportering och leveranser . . . . .	9
1.7 Tillgång till resultat . . . . .	9
1.8 Läsanvisning . . . . .	10
<b>2 Populationssimulering</b>	<b>11</b>
2.1 Populationssyntes . . . . .	14
2.2 Infrastruktur och omvärld . . . . .	17
2.3 Beteendemodeller . . . . .	19
2.3.1 Rutinbeteende . . . . .	20
2.3.2 Inspel . . . . .	20
2.4 Effektmodeller . . . . .	22
2.4.1 Hälsoeffekter vid utsläpp av luftburna kemikalier . . . . .	22
2.4.2 Opinionsdynamik . . . . .	25
2.4.3 Icke vetenskapliga modeller . . . . .	27
2.5 Distribuerad simulering . . . . .	28
2.6 Visualisering . . . . .	28
<b>3 Beteendemodellering</b>	<b>29</b>
3.1 Imitering . . . . .	29
3.1.1 Imitering av passningsmönster hos hockeyspelare . . . . .	31
3.1.2 Slutsatser . . . . .	37
3.2 Optimering . . . . .	38
3.2.1 Tillämpningsdomänen luftstrid . . . . .	38
3.2.2 Taktik vid luftstrid . . . . .	40
3.2.3 Scenario . . . . .	40

3.2.4	Syntetiska aktörer för luftstrid . . . . .	40
3.2.5	Optimizeringsalgoritmen differential evolution . . . . .	41
3.2.6	Preliminära resultat: tester av kvaliteten hos de syntetiska aktörerna . . . . .	42
3.3	Detektering . . . . .	43
<b>4</b>	<b>Slutsatser</b>	<b>45</b>
4.1	Planerad verksamhet under 2013 . . . . .	45
	<b>Litteraturförteckning</b>	<b>46</b>
<b>A</b>	<b>Cellular communications model</b>	<b>49</b>
A.1	Introduction . . . . .	49
A.2	Modeling cell phone reception . . . . .	49
A.2.1	Calculating signal strength, $S_r$ . . . . .	49
A.2.2	Calculating noise, $N$ . . . . .	50
<b>B</b>	<b>Chemical exposure model</b>	<b>51</b>
B.1	Introduction . . . . .	51
B.2	The A EGL program . . . . .	51
B.3	Modeling chemical exposure . . . . .	52
<b>C</b>	<b>Literature review: Opinion dynamics</b>	<b>53</b>
C.1	Introduction . . . . .	53
C.2	Overview of Opinion Dynamic Models . . . . .	54
C.3	Discrete models . . . . .	55
C.3.1	Voter model . . . . .	55
C.3.2	Majority rule model . . . . .	56
C.3.3	Sznajd model . . . . .	56
C.4	Continuous models . . . . .	57
C.4.1	The Deffuant model . . . . .	57
C.4.2	The Hegselmann-Krause (HK) model . . . . .	59
C.4.3	The relative agreement (RA) model . . . . .	59
C.5	Other aspects to take into consideration . . . . .	61
C.5.1	The impact of the social structure . . . . .	61
C.5.2	The influence of extremists . . . . .	62

### C.5.3 Connections to the “real world” . . . . . 63

# 1 Introduktion

## 1.1 Bakgrund

Simuleringsbaserade verktyg används idag flitigt inom Försvarsmakten (FM) för tränings- och beslutsstödsändamål samt för att generera stimuli vid test, verifiering och utveckling av materiel. Simulatorer används i situationer som anses vara alltför tidskrävande, kostsamma, farliga eller av andra skäl oetiska att öva på, analysera eller utvärdera i verkligheten.

En viktig komponent i flertalet simulatorer är de agenter, eller syntetiska aktörer, som helt eller delvis autonomt medverkar i den simulerade omgivningen. Agenter används redan idag bland annat för att simulera pilotbeende i Flygvapnets Luftstridssimuleringscentrum (FLSC) samt inom FM och Markstridsskolan (MSS) för att simulera soldater i taktiska markstridsträningssimulatorer, t.ex. Virtual Battlespace 2 (VBS2).

## 1.2 Projektet syntetiska aktörer

*Syntetiska Aktörer* (SA) är ett FoT-projekt (FoT nr 922:01.03) inom området Modellering och Simulering (M&S) vars syfte är att:

- tillgodose Markstridsskolans behov av förbättrad simuleringsbaserad träning av staber vid militära insatser i urban miljö med fokus på populationen och dess tillstånd,
- anskaffa kunskap, utveckla verktyg, metoder och algoritmer med ändamålet att skapa eller underlätta skapandet av syntetiska aktörer för användning i FMs nuvarande och framtida simuleringsbaserade verktyg för träning och beslutsstöd.

Nyttan som projektet ämnar tillföra FM är expertstöd i form av kunskap, verktyg, metoder, modeller och prototyper vid framtagning av individuella och samverkande agenter för användning i FMs simuleringsbaserade verktyg. Projektet förväntas även resultera i: ökad förmåga hos FM och MSS att bedriva operativ samt taktisk träningsverksamhet i simulerade stadsmiljöer; ökad förståelse för simuleringsverksamhet i urbana samhällen och komplexa socio-tekniska system; samt ökad förståelse för skadeutfallet vid t.ex. en olycka eller ett antagonistiskt angrepp hos en befolkning.

## 1.3 Verksamhet

Projektet har sedan 2009 utvecklat en prototyp, POPSIM, som är en simulator där populationer och dess beteenden modelleras och simuleras på individnivå i stadsmiljö. Vidareutveckling av POPSIM har varit huvudaktiviteten i

projektets verksamhet under 2012. POPSIM består idag utöver själva populationsmodellen även av modeller vilka representerar omvärld och infrastruktur (byggnader, vägnät och mobiltelefoni), irreguljära styrkor samt militära insatsstyrkor. Några av höjdpunkterna i årets verksamhet med avseende på populationsmodellen har varit införandet av relationer mellan individer i populationen (se Kapitel 2.1) samt införandet av opinionsdynamik för modellering av t.ex. populationens inställning till de militära insatsstyrkorna (se Kapitel 2.4.2).

Utöver vidareutveckling av POPSIM har verksamheten under 2012 bestått av mindre studier med inriktning på beteendemodellering med avseende på imitering, optimering och detektion av beteenden. Syftet med denna verksamhet har främst varit att på lång sikt stötta beteendemodellering i POPSIM men anses även vara relevant i andra liknande simuleringsbaserade verktyg.

## 1.4 Rapportens syfte

Syftet med denna rapport är att sammanställa och redovisa verksamhet och resultat av projektet *Syntetiska Aktörer* under 2012.

## 1.5 Avgränsningar

Projektet levererar resultat i form av rapporter, vetenskapliga artiklar och prototyper. Validering av framtagna modeller anses ligga utanför projektets ramar.

## 1.6 Genomförd rapportering och leveranser

Leverans per 2012-06-10:

- Statusrapport, redovisas i FOI Memo, [1].

Leverans per 2012-12-06:

- Demonstration av POPSIM, redovisas i FOI Memo, [2].
- Årsrapport (denna rapport).
- Konferensbidrag, redovisas i FOI Memo, [3].

## 1.7 Tillgång till resultat

Projektets resultat i form av rapporter och publikationer redovisas i Kupal<sup>1</sup>. Resultat i form av implementerade prototyper, mjukvara och källkod finns tillgänglig på begäran.

---

<sup>1</sup><https://kupal.se/Dokument/Projekt/99900.aspx>

## **1.8 Läsanvisning**

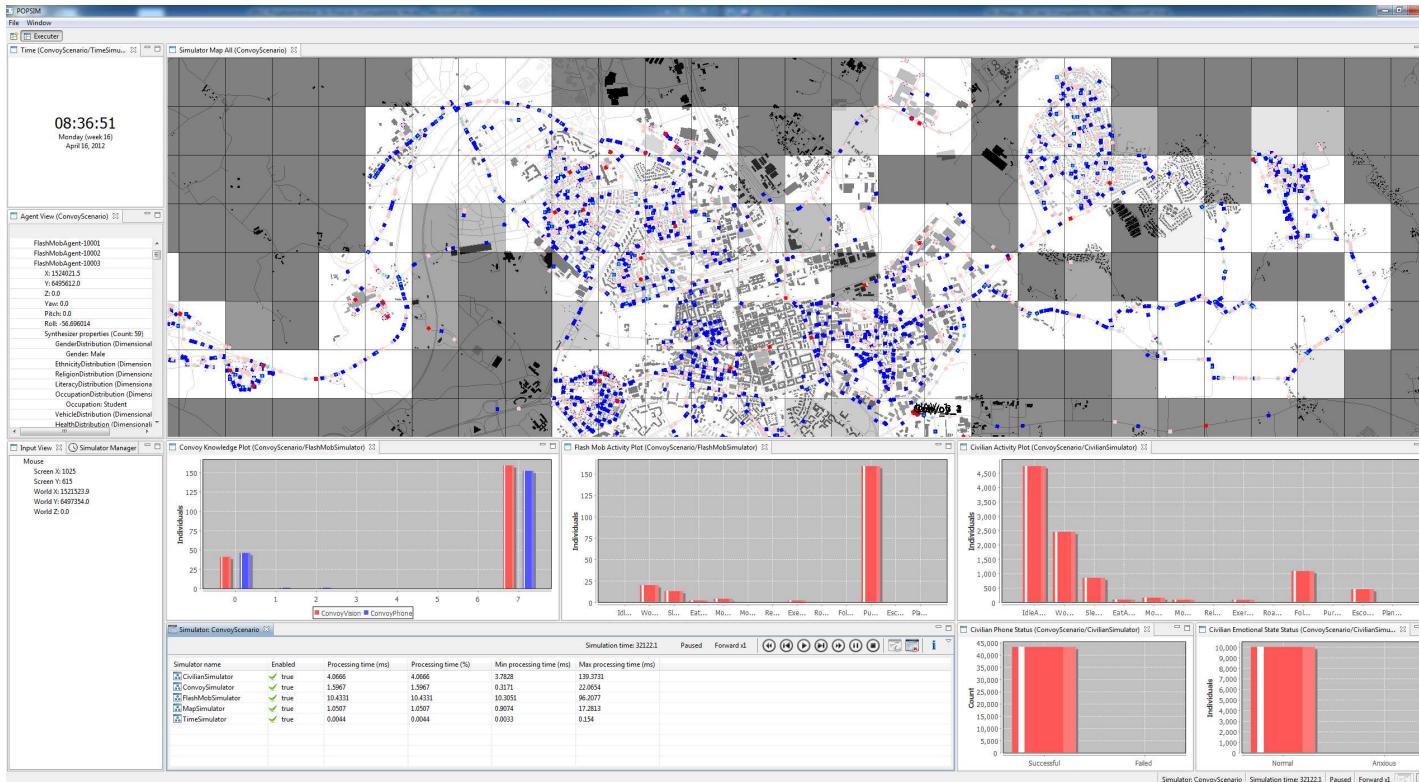
Vidareutvecklingsarbetet med avseende på populationssimulering och POPSIM prototypen beskrivs i Kapitel 2. I Kapitel 3 presenteras idéer, metoder och algoritmer från flertalet studier vilka berör forskningsfronten inom beteende-modellering med avseende på imitering, optimering och detektering. Slutsatser presenteras i Kapitel 4.

## 2 Populationssimulering

Markstridsskolan (MSS) har ett uttryckt behov av simulatorer för träning av staber med fokus på populationen och dess tillstånd vid militära insatser i urban miljö [4]. Detta är en utmanande uppgift då urbana miljöer är komplicerade socio-tekniska system som består av ett stort antal samverkande aktörer och vars beteende därför är svårt att överskåda och modellera i sin helhet.

Projektet har under föregående år utvecklat en prototyp, POPSIM [5], för modellering och simulering av populationer i stadsmiljö. POPSIM är en multi-agentsimulering där varje agent representerar en individ i den simulerade populationen. Fördelarna med den här typen av representation är dels att den är naturlig och intuitiv men även att den är flexibel, modulär och utbyggbar jämfört med t.ex. ekvationsbaserade modeller. Nackdelarna är att representationen kräver stor datorkapacitet i form av minne och processorkraft samt att dess komplexitet med avseende på det stora antalet parametrar som skall konfigureras och kalibreras potentiellt kan vara en begränsande faktor i modelleringarsbetet.

Figur 2.1 visar en skärmdump av den senaste versionen av POPSIM. Figuren visar hela POPSIM miljön som bland annat består av: en tidsvy; kartvy där agenter, byggnader och vägnät visualiseras; samt ett antal diagram för att visualisera populationens aktuella tillstånd (lägesbild). I kartvyn används en intensitetskarta för visualisering av populationstäthet där ljusa områden representerar hög täthet och mörkgrå områden låg täthet. I kartvyn används färgkodade rektanglar för att representera agenter med olika egenskaper i det här fallet män (blå), kvinnor (rosa), barn (ljusblå) och demonstranter (röd). Ljusgrå polygoner och linjer representerar byggnader och vägnät.



Figur 2.1: Skärmdump från POPSIM. Överskådliga lägesbilder av simuleringsens tillstånd presenteras i stapeldiagram samt i GIS kartor där individer och deras positioner projiceras i form av färgkodade rektanglar.

I detta kapitel har vi delat upp POPSIM i ett antal komponenter som i resterande delar av kapitlet kommer att beskrivas var för sig. Tabell 2.1 beskriver övergripande alla POPSIMs komponenter inklusive de funktioner som utvecklades under 2011 samt de funktioner som vidareutvecklats och adderats under 2012.

Komponent	Funktioner 2011	Funktioner 2012
Populationssyntes (se Kapitel 2.1)	<ul style="list-style-type: none"> <li>• Demografi</li> <li>• Geografi</li> </ul>	<ul style="list-style-type: none"> <li>• Relationer</li> </ul>
Infrastruktur och omvärd (se Kapitel 2.2)	<ul style="list-style-type: none"> <li>• Byggnader</li> <li>• Vägnät</li> <li>• Ruttplanerare</li> </ul>	<ul style="list-style-type: none"> <li>• Mobiltelefoni</li> <li>• Elevationsdata</li> </ul>
Beteendemodeller (se Kapitel 2.3)	<ul style="list-style-type: none"> <li>• Rutinbeteende hos befolkning</li> </ul>	<ul style="list-style-type: none"> <li>• Förbättrad rutinbeteendemodell (relationer till familj och vänner samt kommunikation via mobiltelefoni)</li> <li>• Inspel för patrullering, vägspärr, transport (av t.ex. VIP eller materiel) och störning av mobiltelefoni</li> </ul>
Effektmodeller (se Kapitel 2.4)	<ul style="list-style-type: none"> <li>• -</li> </ul>	<ul style="list-style-type: none"> <li>• Hälsoeffekter vid exponering av luftburna kemikalier</li> <li>• Opinionsdynamik (litteraturstudie)</li> <li>• Emotionellt tillstånd</li> <li>• Framkomlighet</li> </ul>
Distribuerad simuler- ring (se Kapitel 2.5)	<ul style="list-style-type: none"> <li>• -</li> </ul>	<ul style="list-style-type: none"> <li>• HLA Evolved via MOSART</li> </ul>
Visualisering (se Ka- pitel 2.6)	<ul style="list-style-type: none"> <li>• Karta (bygg- nader, vägnät, agenter)</li> <li>• Tid</li> <li>• Agenttillstånd</li> <li>• Stapeldiagram (aktiviteter, hälsa)</li> </ul>	<ul style="list-style-type: none"> <li>• Karta med intensitetslager (popu- lationstäthet, täckningsdiagram, koncentration av kemikalier, op- inion)</li> <li>• Inspelsvy</li> <li>• Stapel- och linjediagram (mobil- telefoni, emotionellt tillstånd)</li> <li>• Videoinspelning</li> </ul>

Tabell 2.1: Översikt av de POPSIM komponenter och funktioner som utvecklades under 2011 och de som adderats samt vidareutvecklats under 2012.

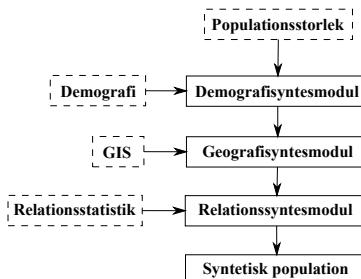
## 2.1 Populationssyntes

Som nämnts tidigare är POPSIM en multi-agentsimulering där varje individ i den simulerade populationen representeras av en simulerad agent som består av ett antal egenskaper vilka bl.a. representerar tillstånd och kunskap. Detta angreppssätt medför, då det inte är rimligt att manuellt konfigurera alla egenskaper för alla agenter, för att POPSIM skall vara användbar i praktiken, att lämpliga modelleringsverktyg finns att tillgå.

Populationssyntesverktyget har till uppgift att från given statistik generera egenskaper och data vilken utgör agenternas *initiala* tillstånd i simuleringen. Vilka egenskaper som genereras beror på vilka beteende- och effektmodeller som skall användas i simuleringen.

Populationssyntesverktyget är modulbaserat för att kunna tillgodose framtida behov av beteende- och effektmodeller. Föregående år utvecklades en demografisynthesmodul och en geografisynthesmodul vilka används för att överföra demografier (ålder, kön, inkomst, yrke, etc.) samt geografiska positioner (bostad, arbetsplats, etc.) till agenterna. Under 2012 har verktyget vidareutvecklats med en modul för att hantera relationer i form av familjer/hushåll samt vänskap mellan agenter.

Figur 2.2 beskriver övergripande flödet i populationssyntesverktyget där ovan nämnda moduler ingår.



Figur 2.2: Flödesdiagram av populationssyntesverktyget.

Modellereraren tillgodoser önskad populationsstorlek, en demografi, en geografisk databas (GIS) och relationsstatistik som input (streckade rektanglar). Demografen används för att skapa de mest grundläggande egenskaperna (t.ex. ålder, kön och yrke) hos individerna i populationen. Individerna i den syntetiska populationen skickas sedan vidare till geografimodulen vilken ansvarar för att tilldela geografiska positioner där individen t.ex. förväntas bo och arbeta gi-  
vet de redan befintliga demografiska egenskaperna. Geografimodulen beräknar dessutom rutter mellan alla för individen kända platser. Slutligen kopplas med hjälp av relationsmodulen individer samman i form av relationsnätverk vilka representerar individens familj/hushåll samt vänner. Värt att notera är att flödet med enkelhet kan byggas på med ytterligare moduler (vilket också gjorts)

bland annat för att modellera opinioner i Kapitel 2.4.2).

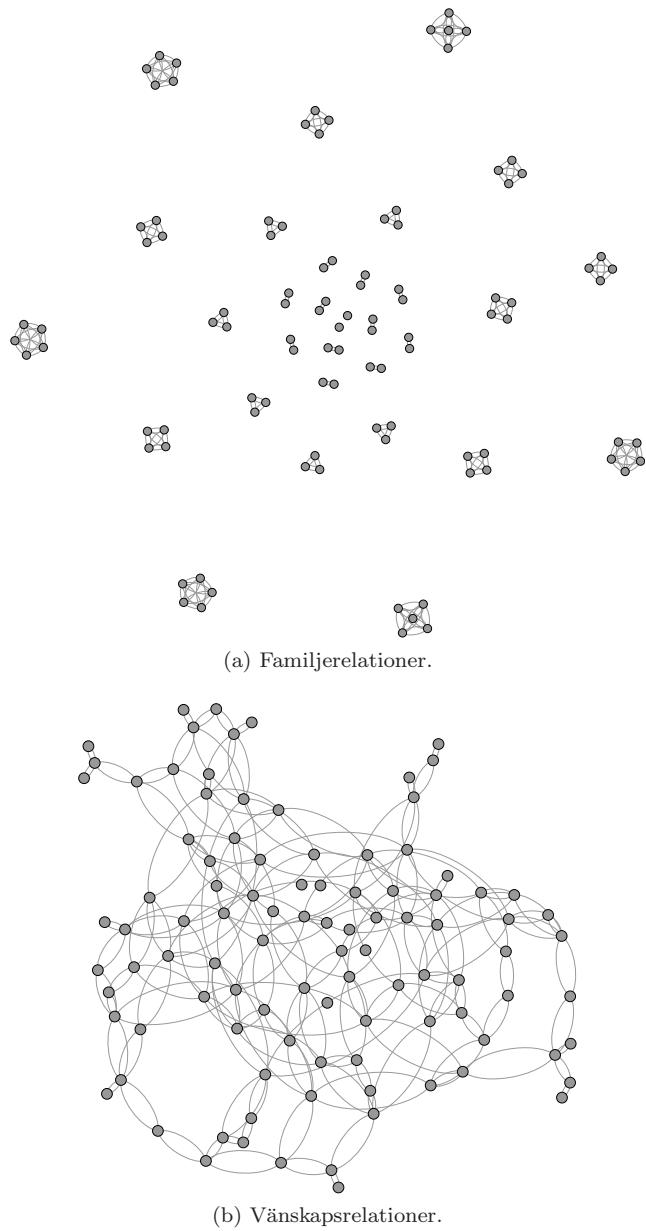
Populationssyntesverktyget bygger på redan befintliga och återanvändbara verktyg (t.ex. JaHMM<sup>1</sup> och Apache Commons Math<sup>2</sup>) vilka kan användas för att överföra given statistik eller data till både diskreta och kontinuerliga distributioner. Egenskaper skapas sedan genom att slumpmässigt sampla dessa distributioner för ett givet antal individer. Även om idén i sig är enkel så kan syntesmodulerna vara mycket komplicerade då egenskaper ofta har flertalet beroenden innehållande. T.ex. visar de flesta demografier att män och kvinnor tenderar att ha olika yrkesfördelningar. Samband av den här typen modelleras idag i verktyget med hjälp av flerdimensionella distributioner (t.ex. Gaussiska Mixtur Modeller) som i sin tur medför begränsningar i antalet beroende variabler man kan modellera. Tumregeln är att desto fler beroende variabler desto mer data krävs för att skapa en rättvisande distribution.

Årets införande av relationssyntesmodulen möjliggör att informationsspridning t.ex. via mobiltelefoni kan ske på ett realistiskt sätt mellan agenterna i simuleringen. Utöver informationsspridning bidrar modulen till att beteenden där exempelvis föräldrar skjutsar sina barn till skola eller dagis med enkelhet kan modelleras vilket i sin tur påverkar populationens rörelsemönster.

Figur 2.3 illustrerar en population bestående av 100 individer där relationssyntesmodulen används för att skapa familje- och vänskapsrelationer mellan individer. Värt att notera är att uppsättningen av både familje- och vänskapsrelationer med enkelhet kan varieras med endast ett fåtal parametrar.

---

<sup>1</sup><http://code.google.com/p/jahmm/>  
<sup>2</sup><http://commons.apache.org/math/>



Figur 2.3: Relationer skapade med relationssyntesmodulen för 100 individer. Individer representeras av punkter och relationer mellan individer representeras av länkar mellan punkterna.

## 2.2 Infrastruktur och omvärld

POPSIM är designad för att vara en geo-specifik simuleringsmodell vilket betyder att omvärld och infrastruktur skall kunna modelleras utifrån verlig geografisk information. I POPSIM används därför GIS-databaser (Geographical Information Systems) för att representera positioner och egenskaper hos t.ex. byggnader, vägar, basstationer, osv. En stor fördel med GIS är att FM och MSS sedan tidigare har stor erfarenhet av dess användning och att stora mängder verklig data redan existerar i de städer (t.ex. Mazar-e-Sharif) där insatser pågår. GIS-databaserna utgör ofta indata till de infrastrukturmodeller som tillhandahåller de tjänster som agenterna i POPSIM interagerar med. Redan 2011 utvecklades grundläggande infrastrukturmodeller för byggnader och vägnät.

Till infrastrukturmodellen för vägnät utvecklades även en ruttplanerare som används för att beräkna kortaste vägen mellan två godtyckliga punkter i vägnätet. Ruttplaneraren bygger på befintliga och återanvändbara verktyg (t.ex. JUNG<sup>3</sup> och Gephi<sup>4</sup>) vilka kan användas för avancerad grafanalys inklusive "kortaste vägen"-sökningar. En förutsättning för att kunna återanvända funktionalitet i ovan nämnda grafverktyg är att data kan representeras i ett av verktygagens tillgängliga format (t.ex. *GraphML*). I POPSIM har därför en algoritm implementerats för att konvertera GIS data i *Shape*-format till *GraphML*-format. Värt att notera är också att ruttplaneraren i årets verksamhet har vidareutvecklats för parallell (multi-core) exekvering vilket signifikant förbättrat prestandan hos ruttplaneraren.

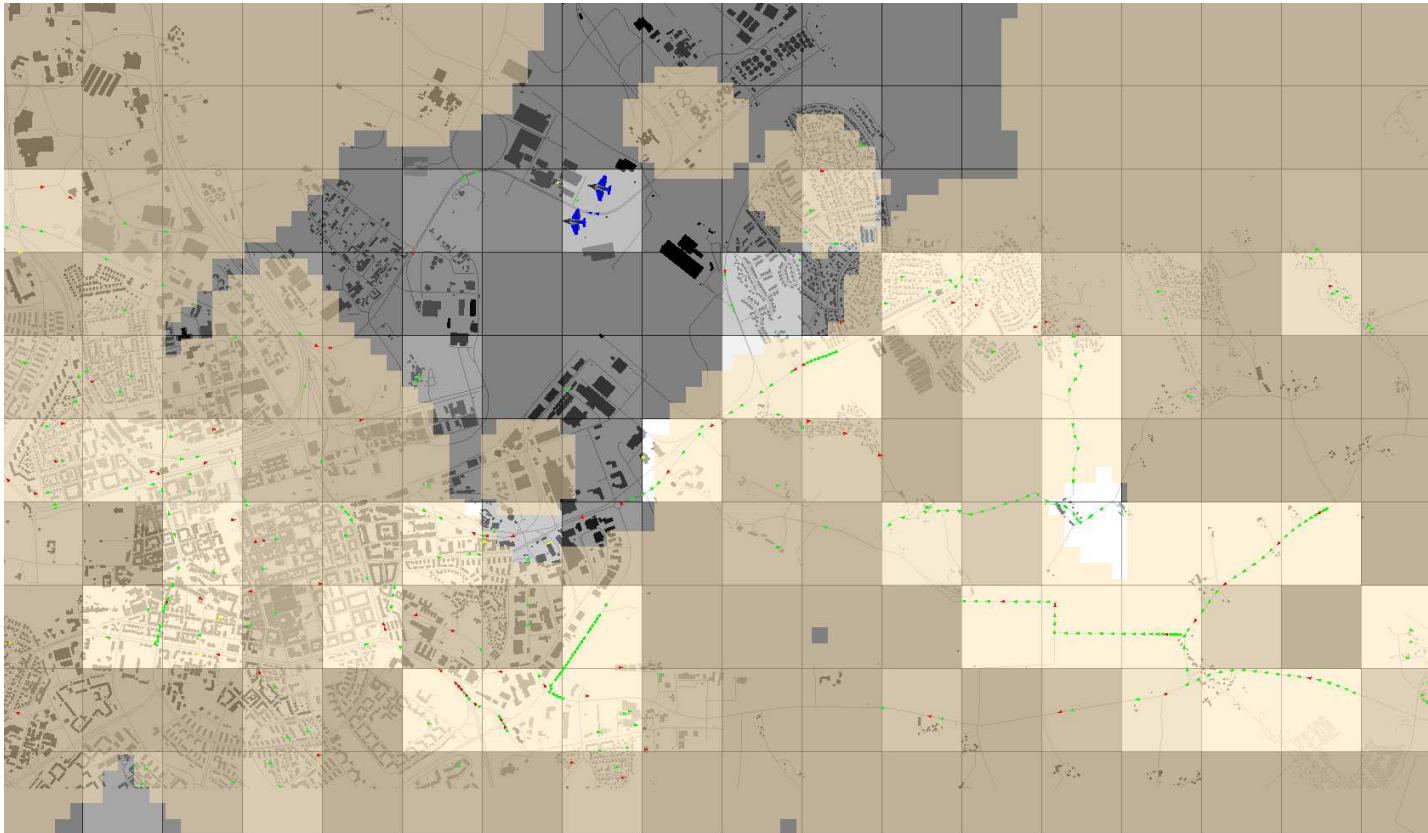
I årets verksamhet har elevationsinformation (d.v.s. markhöjd) representerat i *GeoTIFF*-format adderats för att t.ex. möjliggöra beräkning av hälsoeffekter vid exponering av luftburna kemikalier eller för att i framtiden bättre kunna modellera synfält hos agenterna via line-of-sight beräkningar.

Under 2012 har POPSIM även utökats med en infrastrukturmodell för simulering av mobiltelefoni. Modellen tar som input ett GIS-lager i vilket basstationers position och dess effekt definieras. Modellen beräknar utifrån dessa ett täckningsdiagram som i sin tur används i POPSIM för att avgöra om en individ har täckning och kan kommunicera med en annan individ eller ej. I modellen ingår även möjlighet att störa kommunikationen med hjälp av störsändare. Figur 2.4 illustrerar en skärmdump av POPSIMs kartvy med ett täckningsdiagram. Täckningsdiagrammet renderas ovanpå den befintliga kartvyn som beskrivs tidigare i detta kapitel (se Figur 2.1). Agenter som finns inom ljusbruna områden har täckning och kan därmed kommunicera med andra agenter som också återfinns i de ljusbruna områdena. En detaljerad matematisk beskrivning av modellen finns att tillgå i Appendix A.

---

<sup>3</sup><http://jung.sourceforge.net/>

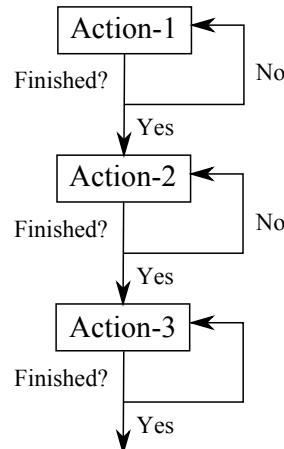
<sup>4</sup><https://gephi.org/>



Figur 2.4: Skärmdump av POPSIMs kartvy med ett täckningsdiagram. I täckningsdiagrammet representerar ljusbruna områden tillräcklig signalstyrka för kommunikation. Alla områden utanför de ljusbruna är områden som saknar täckning.

## 2.3 Beteendemodeller

I POPSIM modelleras beteenden med hjälp av specifika och i många fall även generella och återanvändbara aktioner vilka sätts samman i olika konstellationer för att bilda aktiviteter. Aktioner representerar alltså den lägsta nivån vid skapandet av beteendemodeller. Ett exempel på en grundläggande aktion som används i de allra flesta aktiviteter i POPSIM är förflyttning från en punkt till en annan. Förflyttning används i aktiviteter som transport av VIP eller materiel samt vid upprättande av vägspår och vid patrullering för att nämna några. Figur 2.5 illustrerar flödet vid exekvering av en aktivitet vilken består av tre aktioner. En aktion består i stort av kod vilken modellerar beteendet hos aktionen samt kod vilken avgör om aktionen uppnått sitt måltillstånd (t.ex. kommit fram till slutdestination vid förflyttning). När en aktion uppnått sitt utsatta måltillstånd fortsätter aktiviteten att exekvera nästkommande aktion tills dess att inga fler aktioner finns att exekvera vilket i sin tur resulterar i att aktiviteten exekverat klart. Aktioner exekverar normalt sekventiellt inom en aktivitet men kan även avbrytas och ersättas med aktioner från en ny aktivitet. En avbruten aktivitet kan dessutom återupptas om så önskas av beteendemodellen.



Figur 2.5: Exekveringsflöde hos en aktivitet bestående av tre aktioner.

### **2.3.1 Rutinbeteende**

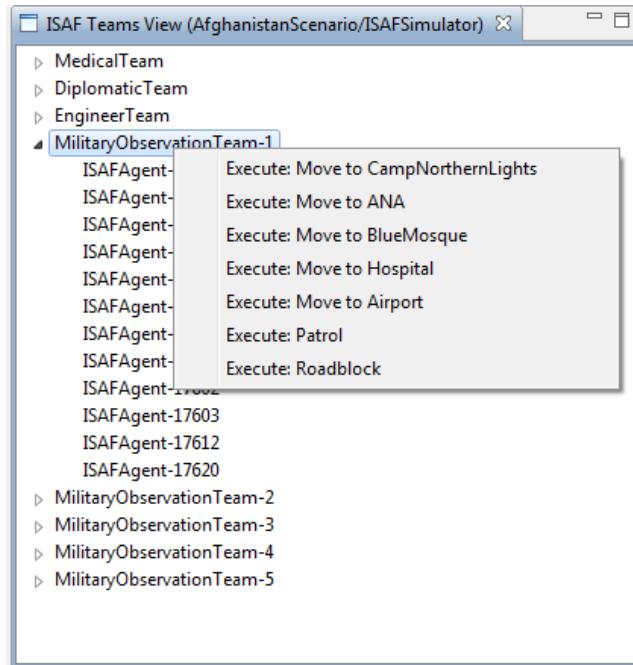
Givet ovan nämnda tillvägagångssätt för beteendemodellering har sedan tidigare en modell för rutinbeteende hos den simulerade populationen skapats. Idén med rutinbeteendemodellen är att den skall utgöra ett normaltillstånd vilket sedan kan påveraks via diverse inspel eller externa händelser. I POPSIM skapas rutinbeteenden ”offline” för att möjliggöra simulering av större populationer samt för att garantera deterministisk exekvering vilket är en förutsättning för repeterbarhet vid analys och träning. Rutinbeteendemodellen bygger till stor del på användandet av populationssyntesverktyget för att omvandla statistik i form av dagsscheman där datum och tid kopplas samman med aktiviteter för ett antal individer till motsvarande dagsscheman hos den simulerade populationen. De aktiviteter som ingår i agenternas dagsscheman översätts till en exekverbar aktivitet implementerad enligt ovan nämnda modell. Nytt för 2012 är att rutinbeteendemodellen tar hänsyn till relationer mellan individer. Relationer används främst för informationsspridning inom populationen t.ex. har rutinbeteendemodellen kopplats till användning av mobiltelefoni vilket är av intresse i scenarier där störsändare används för att rubba informationsflödet i en population.

### **2.3.2 Inspel**

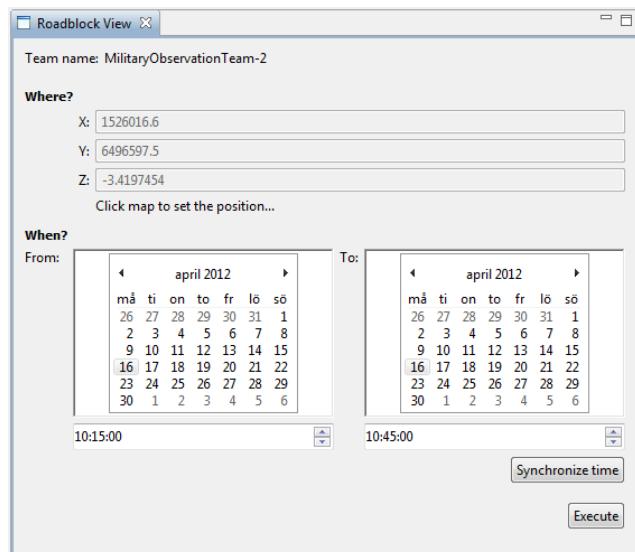
En viktig komponent i POPSIM är de beteendemodeller som används för inspel av den som tränar i simulatorn. I POPSIM finns ett grafiskt gränssnitt där inspel kan ske t.ex. för att beordra patrullering eller uppsättande av vägspärr någonstans i staden. Inspel sker på individ eller team-basis. Team är skapade med inspiration av den struktur som används i ISAF *Provincial Reconstruction Team* (PRT). I POPSIM finns idag möjlighet att genomföra följande inspel:

- Förflyttning till en känd plats (t.ex. camp, sjukhus, flygplats, etc.).
- Patrullering (förflyttning mellan av användaren utvalda positioner).
- Vägspärr.

Figur 2.6 illustrerar gränssnittet som används för inspel. Figur 2.7 illustrerar den inspelsvy som används för att konfigurera en vägspärr i POPSIM (aktiveras via den förstnämnda inspelsvyn).



Figur 2.6: Inspelsvy i POPSIM.



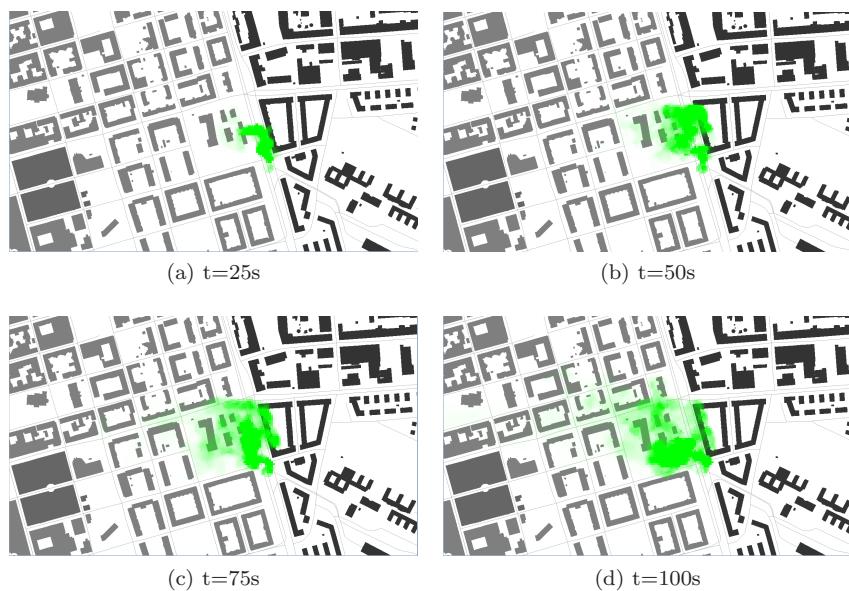
Figur 2.7: Inspelsvy för vägspärr.

## 2.4 Effektmodeller

Till effektmodeller räknas de modeller som utöver beteendemodellerna på något sätt påverkar en eller flera egenskaper hos agenterna i den simulerade populationen. Även om effektmodeller liksom beteendemodellerna i många fall är återanvändbara så är de ofta framtagna för användning i specifika scenarier.

### 2.4.1 Hälsoeffekter vid utsläpp av luftburna kemikalier

Under 2012 har POPSIM tillämpats i projektet *Simuleringsbaserat krishanteringsslabb* (SBKL) [6] för beräkning av skadeutfallet på en population vid vådautsläpp i stadsmiljö. I den här typen av scenarier krävs utöver effektmodell för beräkning av individers hälsotillstånd även en modell för beräkning av utsläppets spridning. I POPSIM har en redan befintlig modell som tar hänsyn till vindriktning samt byggnadernas storlek och form återvänts i enlighet med [6]. Figur 2.8 illustrerar ett exempel på hur ett gasmoln sprids i simuleringen vid olika tidpunkter.



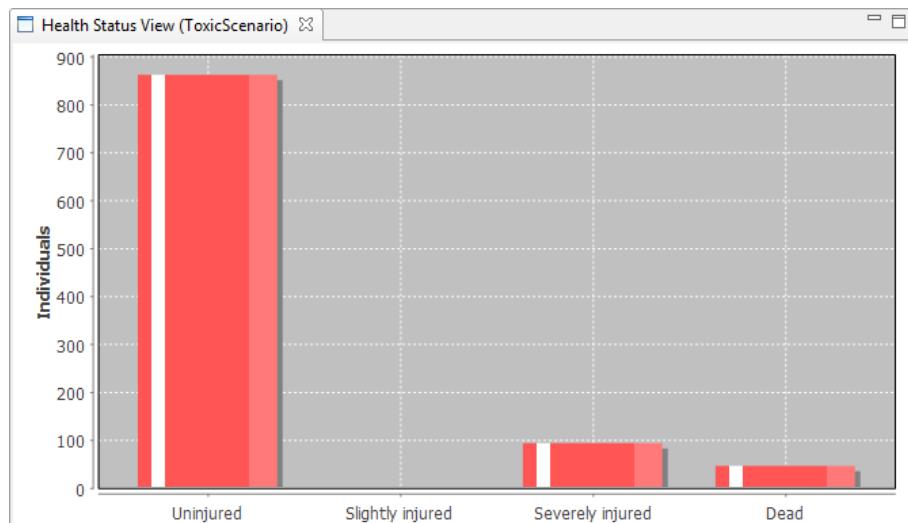
Figur 2.8: Spridning av gasmoln i stadsmiljö.

Givet gasmolnets koncentration och spridning över tid är det möjligt att med hjälp av gränsvärden som är empiriskt framtagna i redan befintliga studier beräkna hälsoeffekter på den simulerade populationen. För att detta skall vara möjligt krävs dock att varje agent kontinuerligt registrerar hur länge samt i vilken koncentration agenten varit exponerad för kemikalien i simuleringen.

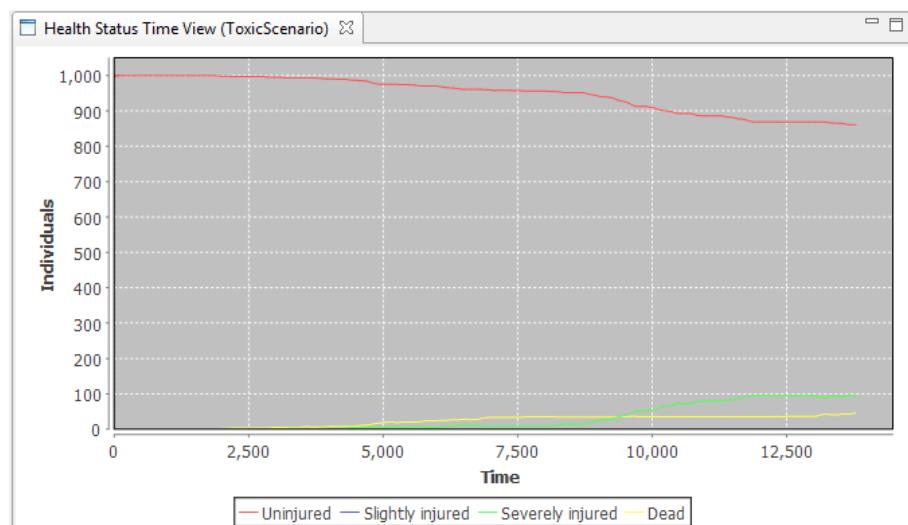
I POPSIM har gränsvärden från *Acute Exposure Guideline Level*-programmet (AEGL) [7] använts för att beräkna hurvida en agent som exponerats för en kemikalie är oskadad, lätt skadad, svårt skadad eller död. I AEGL återfinns gränsvärden för ett stort antal luftburna kemikalier. I Tabell B.1 ges ett exempel på gränsvärden som kan användas vid beräkning av skadeutfall vid utsläpp av svaveldioxid,  $SO_2$ . Utöver AEGL har stöd för beräkning av gränsvärden utgående från s.k. probitfunktioner utvecklats. En beskrivning av probitfunktionerna finns att tillgå i [6].

I POPSIM visualiseras skadeutfall med stapel- och linjediagram enligt Figur 2.9. Aktuellt hälsotillstånd representeras av stapeldiagrammet i Figur 2.9a medans hälsotillstånd över tid representeras av linjediagrammet i Figur 2.9b.

En detaljerad beskrivning av effektmodellen finns att tillgå i Appendix B.



(a) Stapeldiagram.



(b) Linjediagram.

Figur 2.9: Skadeutfall vid exponering av luftburna kemikalier. Stapeldiagram används för att visualisera aktuellt hälsotillstånd. Linjediagram används för att visualisera hur hälsotillståndet förändrats över tid.

## 2.4.2 Opinionsdynamik

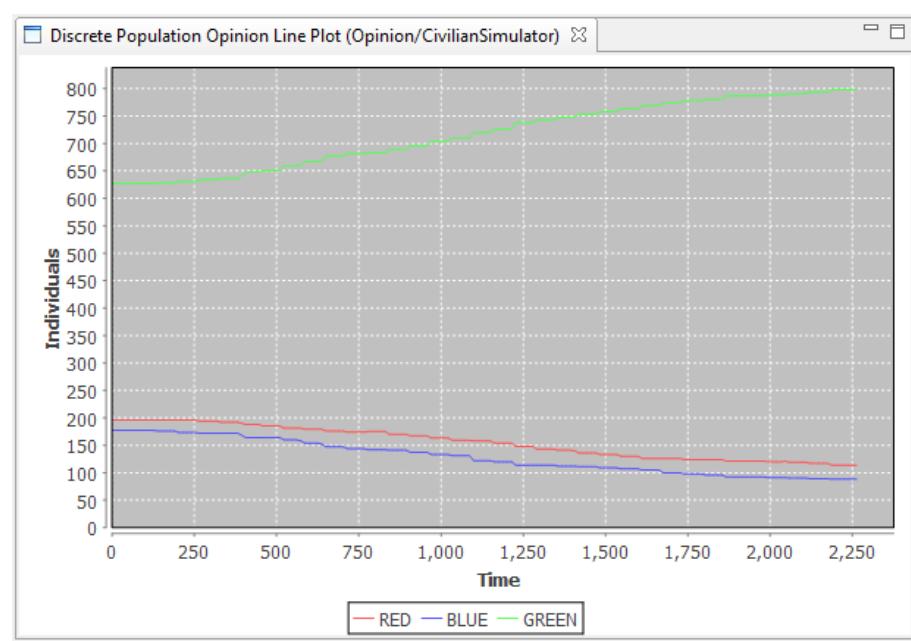
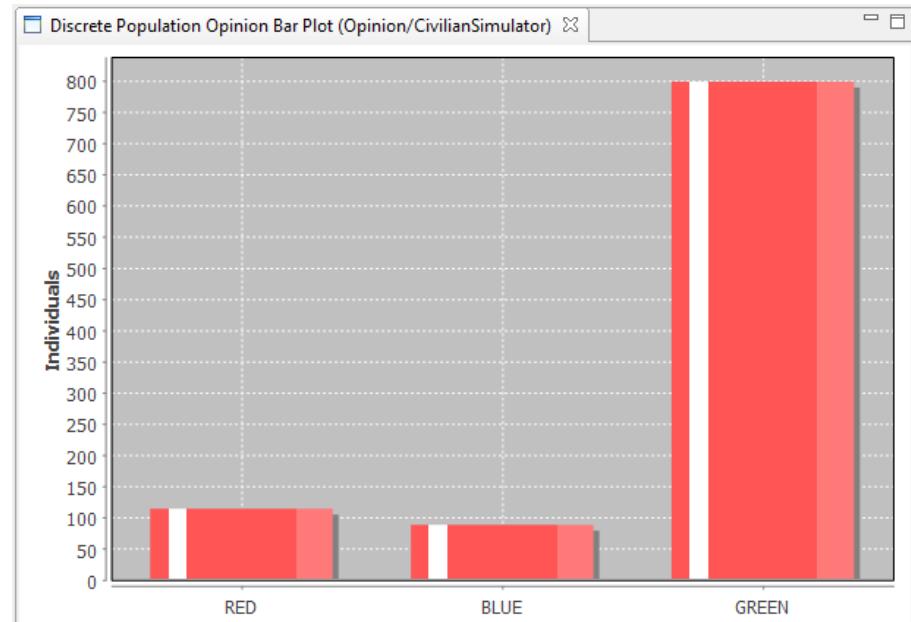
MSS har uttryckt ett behov av att kunna modellera och simulera hur den simulerade populationens opinioner och åsikter förändras över tid. Ett typiskt exempel som är av intresse för MSS ur ett träningsperspektiv är att via inspel (t.ex. patrullering) bilda en lägesbild av populationens inställning/opinion till de militära insatsstyrkorna och sedan nyttja denna lägesbild som underlag för beslut om vilka inspel som skall utföras t.ex. för att förbättra populationens opinion i den aktuella frågan.

I en första ansats att tillgodose detta behov har projektet under 2012 genomfört en litteraturstudie där ett antal relevanta opinionsdynamikmodeller har identifierats. Tabell 2.2 sammanfattar kortfattat de modeller som ansågs mest relevanta för användning i POPSIM. Literaturstudien återfinns i sin helhet i Appendix C.

Modell	Beskrivning
Deffuant	Om två individer med tillräckligt lika opinion kommunicerar med varandra sker en uppdatering av bådas opinion, där styrkan på uppdateringen bestäms av parametern $\mu$ . Se Appendix C.4.1
Hegselmann-Krause (HK)	Likvärdig med Deffuant, där skillnaden består i att individer inte enbart påverkar varandra parvis. Mer lämplig för att modellera gruppdiskussioner. Se Appendix C.4.2
Relative agreement (RA)	Utökning av Deffuant där hänsyn tas till att individer kan vara olika övertygade i sina åsikter och därmed mer eller mindre lätt att påverka. Uppdatering av opinion bestäms av överlappet mellan två individers åsikter. Se Appendix C.4.3

Tabell 2.2: Översikt av de opinionsdynamikmodeller som finns implementerade i POPSIM.

Under 2012 har dessutom de modeller som finns listade i Tabell 2.2 implementerats i POPSIM. Varje individ i populationen förses med ett initialt opinionsvärde samt värden för modellens parametrar via populationssyntesverktyget. Opinioner uppdateras i dagsläget olika beroende på vilken relation individer har till varandra. Det är fullt möjligt att konfigurera modellen så att individer i samma familj påverkar varandras opinion mer än individer som enbart är vänner eller som inte har någon relation till varandra. I Figur 2.10 ges ett exempel på hur en populations opinion kan tänkas se ut i POPSIM. Röd, blå och grön representerar i det här fallet antal individer som har negativ, positiv och neutral inställning till den militära närvaren.



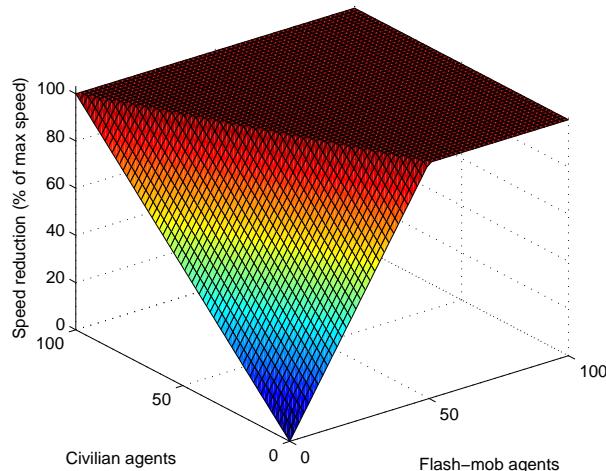
Figur 2.10: Opinionsdynamiken i en population. Stapeldiagram används för att visualisera aktuellt opinionstillstånd. Linjediagram används för att visualisera hur opinionstillståndet förändrats över tid.

### 2.4.3 Icke vetenskapliga modeller

Under 2012 har även ett antal icke vetenskapliga modeller utvecklats. Tanken med modellerna är att kunna påvisa effekter i demonstrationssyfte och att de på lång sikt skall ersättas med mer vetenskapligt grundade modeller. Modellerna som diskuteras i det här kapitlet är därför mycket förenklade och grundar sig i dagsläget enbart på författarnas erfarenheter och kunskap.

#### Framkomlighet i trafik

Under 2012 har POPSIM utökats med en effektmodell för framkomlighet i trafik. Modellen är enkel, desto fler agenter som rör sig i vägnätet desto sämre framkomlighet. I Figur 2.11 visas ett exempel på hur framkomlighetsmodellen kan konfigureras med avseende på två olika agenttyper (civila och demonstranter). I det här fallet påverkar demonstranterna framkomligheten dubbelt så mycket som de civila agenterna.



Figur 2.11: Framkomlighetsmodell.

#### Emotionellt tillstånd

Under 2012 har POPSIM utökats med en modell för emotionellt tillstånd. Modellen baserar sig på att individer har en drivkraft att kontinuerligt hålla kontakten med familj och vänner. Om en agent vid upprepade tillfällen inte kan kommunicera med sin familj övergår agenten från normalt till oroligt tillstånd vilket i sin tur medför beteendeförändringar som slutligen resulterar i ökad tra-

fik och minskad framkomlighet. I modellen nyttjas infrastrukturmodellen för mobiltelefoni för att möjliggöra kommunikation mellan agenter i populationen.

## 2.5 Distribuerad simulering

För att möjliggöra nytta av POPSIM inom Försvarsmaktens nuvarande och framtida simulatorer har POPSIM under 2012 anpassats för att exekvera i distribuerade simuleringsmiljöer enligt HLA (High-Level Architecture) standard via MOSART-ramverket [8]. Arbetet har resulterat i att POPSIM under 2012 används för simulering av populationer i följande projekt:

- SBKL: Simuleringsbaserat krishanteringslabb [6], FOI
- HBR: Human Behavior Representation, FoT nr 921:01.02, FMV

POPSIM:s HLA-koppling förväntas framöver möjliggöra en ökad simuleringsbaserad träningsförmåga även på taktisk nivå då det via HLA-kopplingen finns möjligheter att kombinera POPSIM med avancerade taktiska simulatorer såsom VBS2 (Virtual Battlespace 2)<sup>5</sup>.

## 2.6 Visualisering

De förbättringarna som skett under 2012 med avseende på visualisering har delvis presenterats i tidigare sektioner av detta kapitel. Nedan ges en kort sammanfattning av de huvudsakliga förbättringarna.

Under 2012 har POPSIM utökats med intensitetskort för att visualisera populationstäthet (se Figur 2.1), spridning och koncentration av kemikalier (se Figur 2.8) samt mobiltelefonitäckning (se Figur 2.4).

Utöver intensitetskort har POPSIM utökats med funktionalitet för att visualisera dynamiken hos en population över tid med hjälp av linjediagram (se Figur 2.9b, Figur 2.10b). Till skillnad från stapeldiagrammen som enbart visualiseras simuleringens nuvarande tillstånd återger linjediagrammen historik inom ett givet tidsfönster.

Värt att notera är också att videoinspelning kan ske på innehållet som presenteras i kartvyn. Filerna som skapas kan med fördel användas för kommunikations- och demonstrationssyften.

---

<sup>5</sup><http://armory.bisimulations.com/>

## 3 Beteendemodeller

I detta kapitel presenteras idéer och resultat från projektaktiviteter vilka berör verktyg, metoder och algoritmer som ligger i framkant inom projektets forskningsområden. Under året har projektet främst fokuserat på att anskaffa kunskap och utveckla prototyper för utvärdering av följande beteendemodelleringstekniker:

- Imitering - I denna aktivitet har projektet undersökt hurvida maskininlärningsalgoritmer kan användas för att imitera beteenden från inspelad data.
- Optimering - I denna aktivitet har optimeringsalgoritmer använts för att kalibrera eller parametersätta en beteendemodell.
- Detektering - Projektet har under året anlitat en examensarbetare från Mälardalens högskola som i sitt examensarbete utvecklat en metod för att detektera mänskligt beteende i syftet att förbättra anpassningsförmågan hos en autonom agent (t.ex. en robot) som medverkar i ett mänskligt lag.

I resterande delar av detta kapitel beskrivs ovan nämnda projektaktiviteter samt de huvudsakliga resultaten från dessa.

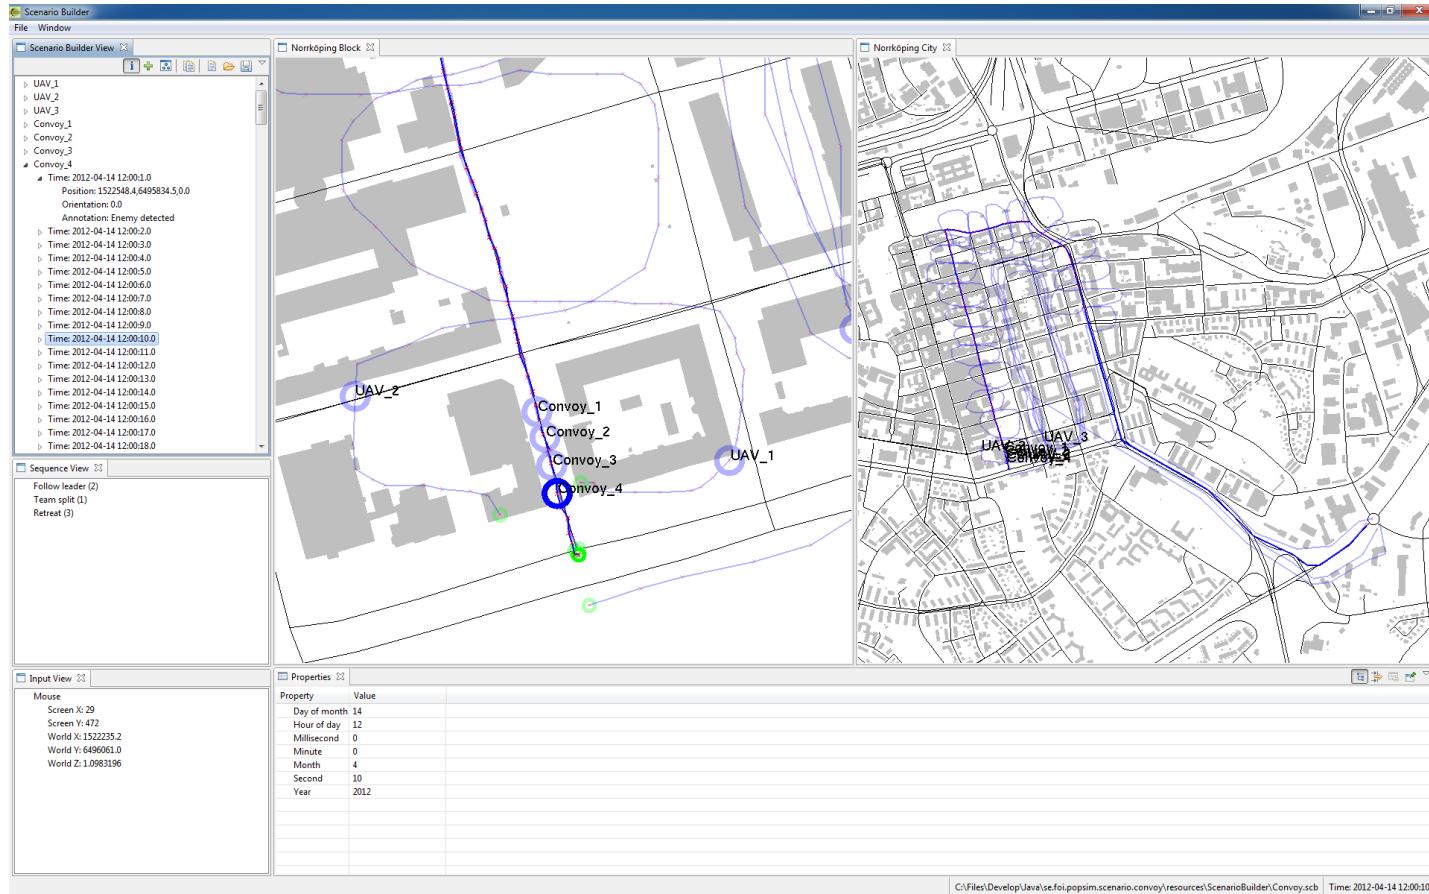
### 3.1 Imitering

Beteendeimitering handlar i stort om att från inspelad data från t.ex. en övning eller en verlig insats kunna återskapa exekverbara beteendemodeller vilka imiterar beteendet i ursprunglig data. Projektet har under året undersökt möjligheterna att nyttja maskininlärningsalgoritmer för att automatiskt återskapa beteenden från både verlig och syntetisk data.

Nyttan med den här typen av beteendemodelleringsteknik är främst att:

- Via "what-if"-simulering analysera beteenden för att identifiera svagheter och styrkor hos enskilda eller samverkande aktörer.
- Förenkla skapandet av beteendemodeller genom att via maskininlärningsalgoritmer delvis ersätta den logik som annars måste programmeras manuellt.

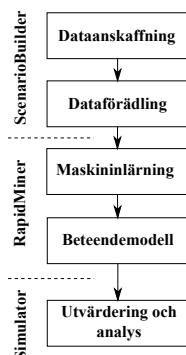
I en första ansats att utvärdera möjligheterna med beteendeimitering har projektet utvecklat ett dataanskaffningsverktyg, *ScenarioBuilder*, som används för att visualisera, skapa och editera data. I Figur 3.1 visas en skärmdump av *ScenarioBuilder*. Verktyget innehåller en modul som förädlar data innan den används som input i utvalda maskininlärningsalgoritmer. Förädlingsprocessen är nödvändig för att den slutgiltiga beteendemodellen skall, om så önskas, vara oberoende av diverse transformationer (t.ex. skala, rotation, osv.).



Figur 3.1: Skärmdump av ScenarioBuilder. I applikationen skapas dataset som kan användas som input till maskininlärningsalgoritmer med syftet att imitera och detektera beteenden (se Kapitel 3.3).

Vidare har projektet återanvänt implementationer av de vanligast förekommande maskininlärningsalgoritmerna från RapidMiner<sup>1</sup>. RapidMiner är ett *state-of-the-art* verktyg avsett för data-mining [9] som utöver maskininlärningsalgoritmer tillhandahåller moduler för import/export av data och modeller samt algoritmer för analys och utvärdering resultat.

Flödet i Figur 3.2 beskriver övergripande beteendemodelleringsprocessen från anskaffning av data till färdig beteendemodell som kan utvärderas, analyseras och användas i en simulator.



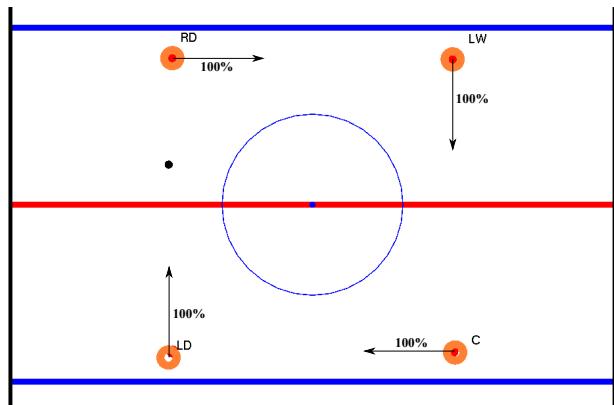
Figur 3.2: Övergripande flöde av beteendemodelleringsprocessen som används för att imitera beteenden från data med maskininlärningsalgoritmer.

### 3.1.1 Imitering av passningsmönster hos hockeyspelare

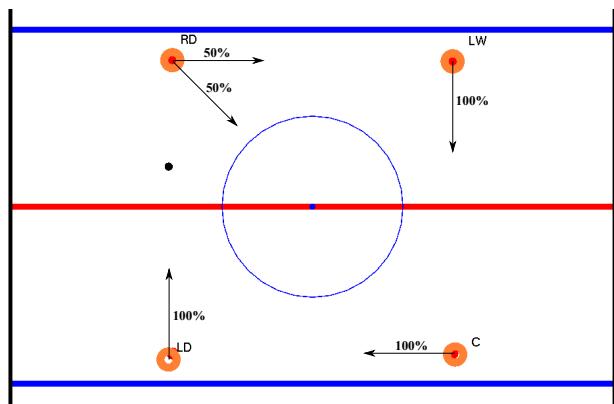
Projektet har i år fokuserat på imitering av mycket primitiva beteenden i syftet att säkerställa att implementationen av beteendemodelleringsprocessen i Figur 3.2 fungerar men även för att på ett systematiskt kunna identifiera under vilka omständigheter beteenden kan och inte kan imiteras.

I den här sektionen presenteras resultat där data från tre passningsövningar har använts för att imitera passningsbeteenden hos hockeyspelare. I den första övningen som illustreras i Figur 3.3 passar hockeyspelarna pucken till varandra med sols. I den andra övningen som illustreras i Figur 3.4 passar spelarna pucken till varandra återigen med sols men skillnaden att spelaren högst upp till vänster (*RD*) väljer att till hälften av gångerna passa diagonalt till *C* istället för till *LW*. I den sista övningen har en motspelare adderats till passningsövningen enligt Figur 3.8. I övningen undviker spelare att passa pucken till medspelare som p.g.a. motspelaren står i passningsskugga.

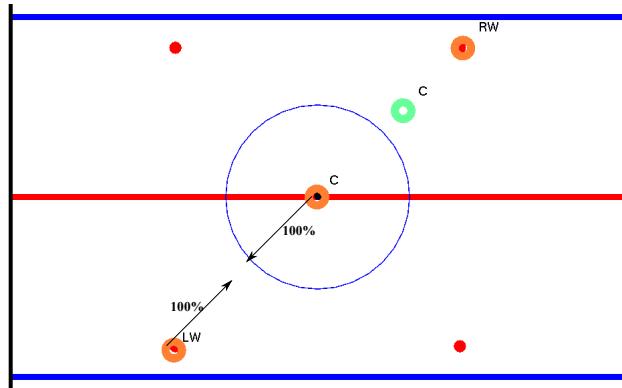
<sup>1</sup><http://rapid-i.com/>



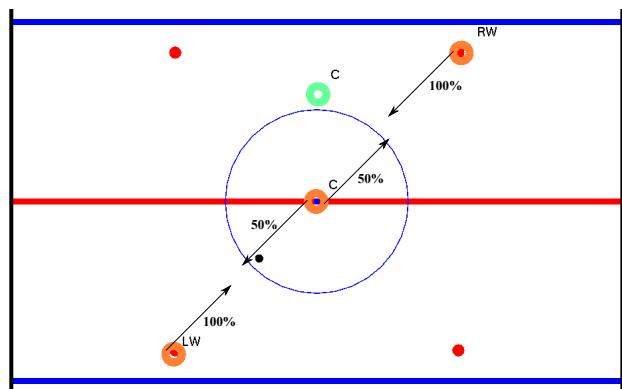
Figur 3.3: Dataset där spelare passar pucken till varandra medsols.



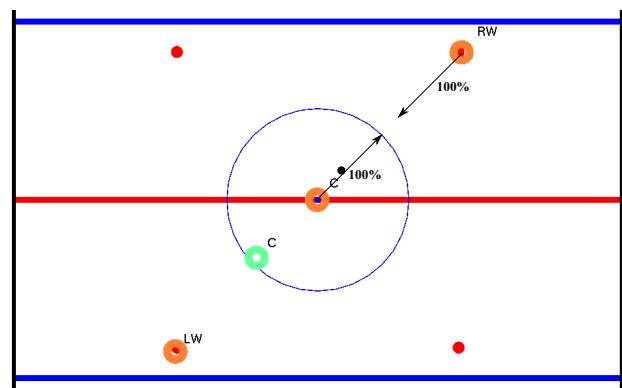
Figur 3.4: Dataset där spelare passar pucken till varandra medsols. RD passar hälften av gångerna till LW och den andra hälften till C.



(a) Orange C och LW passar pucken till varandra. Orange RW är blockerad av grön C.



(b) Orange LW, C och RW passar pucken till varandra. C passar hälften av gångerna till LW och den andra hälften till RW. Grön C blockerar ingen orange spelare.



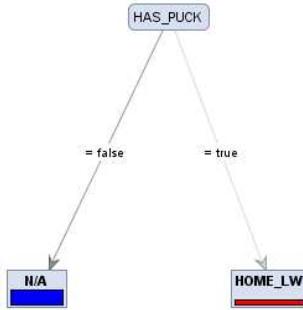
(c) Orange C och RW passar pucken till varandra. Orange LW är blockerad av grön C.

Figur 3.5: Dataset där orange spelare undviker att passa pucken till grön spelare (motståndare).

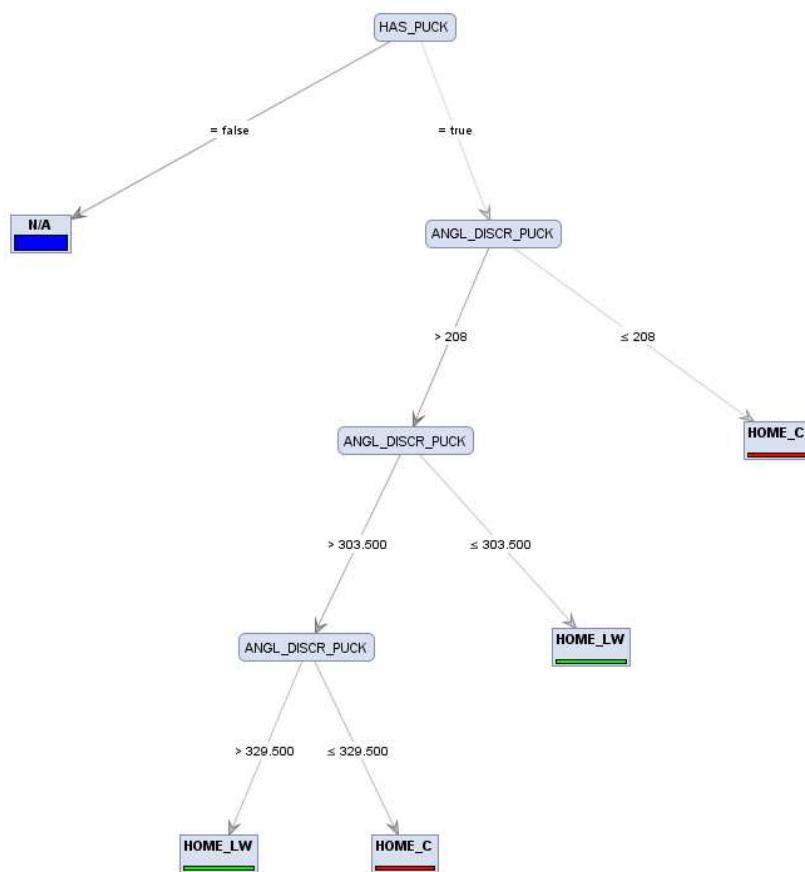
Givet datasetet ovan har beteendemodeller för varje spelares passningsförmåga automatiskt genererats m.h.a. RapidMiner:s maskininlärningsalgoritm för beslutsträd. I Figur 3.6 och Figur 3.7 illustreras beslutsträdens för spelare *RD* givet data från den första och andra passningsövningen. Från det första beslutsträdet i Figur 3.6 kan man utläsa att *RD* kommer passa *LW* givet puckinnehav. Detta stämmer mycket väl överens med det förväntade beteendet enligt träningsdata.

Beslutsträdet i Figur 3.7 är något mer komplicerat. Givet att *RD* har pucken kommer spelaren att passa till antingen *LW* eller *C* baserat på puckens position eller vinkel gentemot spelaren. En visuell analys av beteendemodellen har genomförts i en simulator och resultatet har visat att ca. hälften av passningarna från *RD* går till *C* medan den andra hälften går till *LW*. Modellen stämmer alltså överens med träningsdata.

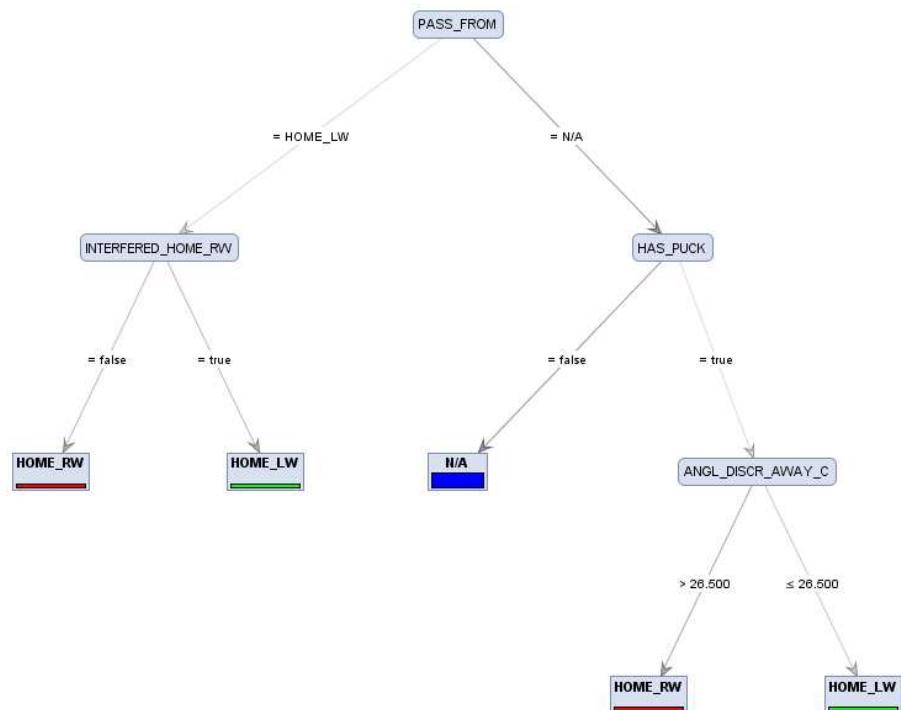
Slutligen, i Figur 3.8 visas beslutsträdet som imiterar spelare *C* i Figur 3.5. Visuell analys av modellen i en simulator har även här visat att modellen stämmer överens med det inspelade beteendet.



Figur 3.6: Beslutsträd skapat för spelare *RD*. Genererat från dataset i Figur 3.3.



Figur 3.7: Beslutsträd för spelare RD. Genererat från dataset i Figur 3.4.



Figur 3.8: Beslutsträd för orange C. Genererat från dataset i Figur 3.5.

### **3.1.2 Slutsatser**

Sammanfattningsvis kan sägas att resultaten från experimenten är mycket uppmuntrande. Alla experiment resulterade i korrekta beteenden i enlighet med den data som användes som input till maskininlärningsalgoritmerna. Det skall dock poängteras att förädlingsprocessen i det här fallet anpassats till just hockeydomänen. Önskvärt vore att i framtiden vidareutveckla förädlingsprocessen så att den i största mån kan användas oberoende av domän.

## 3.2 Optimering

I avancerade modeller av syntetiska aktörer finns ofta flera parametrar som påverkar olika saker, t.ex. i vilken hastighet en styrd farkost skall framföras, hur länge en viss aktivitet skall genomföras, eller på vilket avstånd ett vapen skall avfyras.

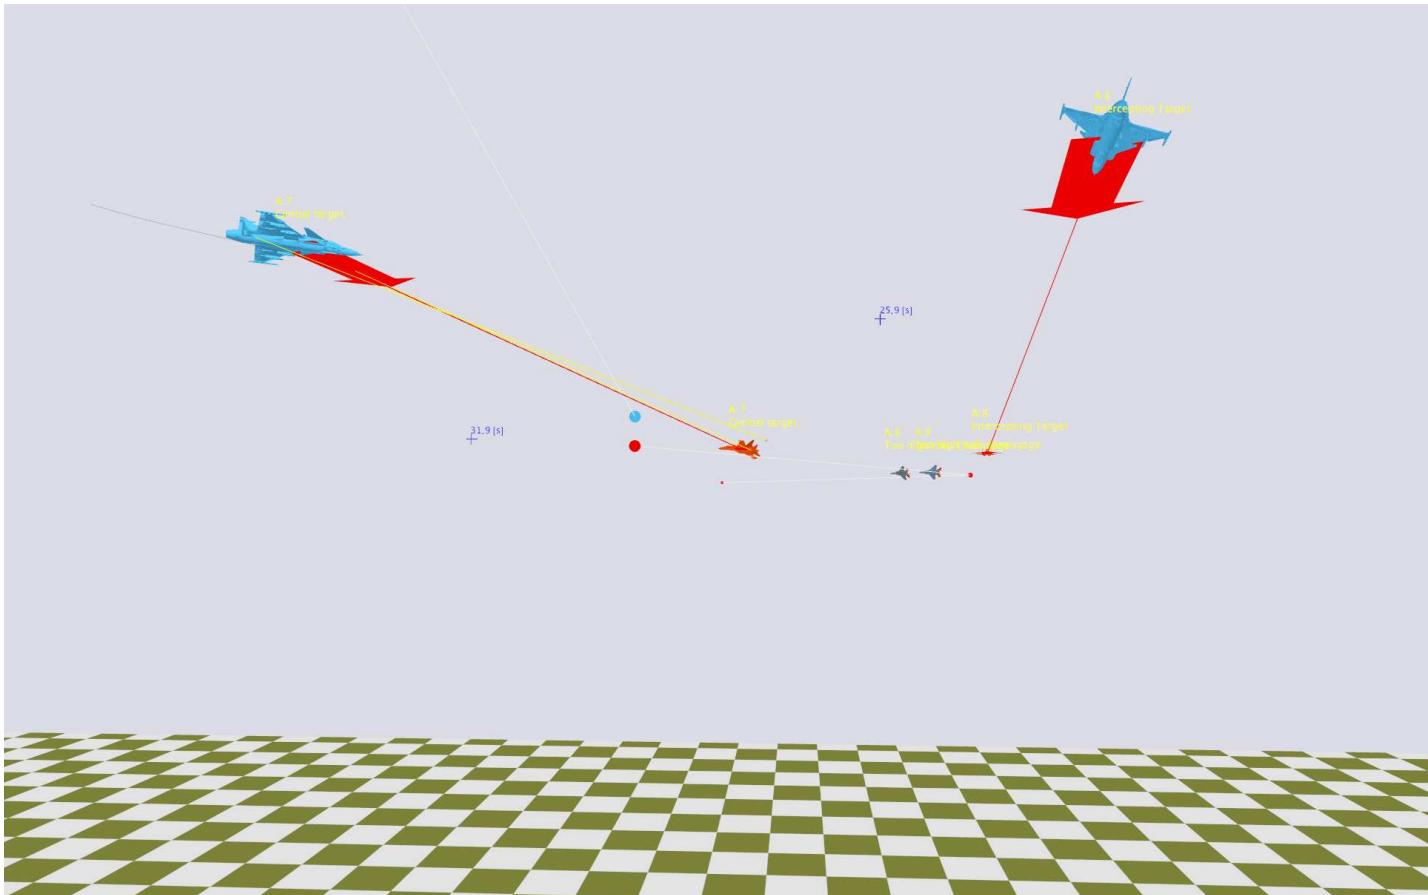
Att välja bra värden på sådana parametrar kan emellertid vara svårt och tidsödande. Därför kommer vi i denna aktivitet utforska möjligheterna att välja parametrarna med hjälp av optimeringsmetoder. Detta görs genom att vi först sätter upp ett mål, att aktören skall genomföra något så bra som möjligt, och sedan låter en optimeringsalgoritm välja värdet på parametrar vi inte vill välja manuellt.

Nedan skall vi först beskriva luftstrid, den tillämpningsdomän vi valt för aktiviteten, samt den tillhörande taktik som skall genomföras. Sedan redogör vi kort för Differential Evolution, den optimeringsalgoritmen vi valt. Slutligen presenterar vi det scenario som skall användas och resultat från preliminära kvalitetstester av agenterna. Själva optimeringskörningarna kommer att genomföras efter denna rapports tryckning.

### 3.2.1 Tillämpningsdomänen luftstrid

Nedan skall vi först motivera valet av tillämpningsdomän, sedan kort beskriva, dels hur luftstrid går till, och dels det scenario och de syntetiska aktörer som vi använder.

Luftstrid, eller förmågan att bekämpa och skydda mål i luften, är en mycket central förmåga för Försvarsmakten. Denna förmåga tränas bland annat i FLSC (Flygvapnets Luftstridssimuleringscenter) på FOI i Kista, där man precis är på väg att införa de syntetiska aktörer som bl.a. utvecklats inom detta projekt, för att stötta träningen, se Figur 3.9. Detta gör att luftstrid är ett område där vi redan har tillgång till sofistikerade syntetiska aktörer, samtidigt som ytterligare förbättringar i dessa omedelbart skapar nytta hos Försvarsmakten.



Figur 3.9: Luftstrid mellan våra syntetiska aktörer.

FOI-R--3557--SE

### 3.2.2 Taktik vid luftstrid

Vi fokuserar i detta arbete på luftstrid på långa avstånd, så kallad BVR-strid (Beyond Visual Range). I sådan strid används långräckviddiga målsökande robotar. Dessa har maximala hastigheter över 3 gånger ljudhastigheten, och maximala flygtider över en minut.

En vanlig taktik vid BVR-strid är att flyga växelvis mot och ifrån motståndaren på ett sådant sätt att man alltid har minst ett eget flygplan riktat framåt, utan att komma för nära hotet. Strävan att kunna hota motståndaren innan han hotar det egna flygplanet gör att man ofta skjuter på mycket långa avstånd, så att roboten precis når fram innan den tappat för mycket fart. Detta gör i sin tur att man kan överleva en tidigt skjuten robot genom att vända om och flyga bort från hotet. Att flyga bort från hotet för att minska sin risk innebär emellertid två nackdelar, dels ser man inget med sina sensorer och dels kan man inte hota motståndaren med sina vapen. Detta gör att man strävar efter att hela tiden ha minst ett eget flygplan riktat framåt, och för att kunna göra detta utan att utsätta sig för alltför stor risk är det lämpligt att det framåtriktade flygplanet kommer från en position längre bak. Under sin väg framåt kommer det så att passera det bakåtriktade flygplanet på väg bort från hotet. Efter ett tag vänder båda flygplanen, och rollerna är ombytta, den längst fram minskar sin risk, och den längst bak vender upp emot fienden och hotar dem.

Det hela komplickeras ytterligare av att man på väg framåt vid något tillfälle ofta, men inte alltid, väljer att avfyra en robot. Med en robot i luften måste man skicka information om målets position från sin radar, ända till dess att roboten öppnar sin egna, mindre kraftfulla, radar och själv kan styra mot målet. Tvingas man vända innan dess är det mycket osannolikt att roboten träffar.

### 3.2.3 Scenario

För att utvärdera de syntetiska aktörerna väljer vi ett scenario där båda sidor i en konflikt vill få luftherravälde i ett visst geografiskt område. Vi antar att en avgörande strid utkämpas på marken, och att båda sidor vill sätta in sina luftstridskrafter i denna strid.

I praktiken startar vi från båda sidor ett flygföretag bestående av både attackförband, med ett bombmål i området, och eskorterande jaktförband. Dessa flygplan möts sedan över området, och genomför luftstrid för att mota bort motståndaren, och möjliggöra egen bombfällning. Den sida som lyckas fälla flest bomber mot sitt mål har lyckats med sitt uppdrag.

### 3.2.4 Syntetiska aktörer för luftstrid

För att genomföra scenariot ovan använder vi dels jaktförband, som bedriver BVR-strid enligt taktiken som beskrivs ovan, och dels mycket enkla attackförband, som flyger mot sina mål, men backar så fort de kommer för nära fientliga flygplan, eller får en varning om annalkande robot. Den sida som lyckas

kas skjuta ned, eller tvinga bort, motsidans jakt kommer följdakligen lyckas fälla sina bomber mot målen.

Parametrarna i jaktbeteendet som vi vill optimera över är:

- Vid vilket avstånd de avfyrar sina robotar (i procent av den så-kallade skjutlappen, vilken mäter nominell räckvidd vid given höjd och fart)
- Vid vilket avstånd de upplever hotet från motståndaren så stort att de vänder bort från hotet
- Vid vilket djup, bakom egna flygplan, ett defensivt flygplan väljer att vänta tillbaka och bli offensivt
- På vilken höjd de väljer att plana ut från en dykande undanmanöver

### **3.2.5 Optimeringsalgoritmen differential evolution**

I detta avsnitt skall vi först kort beskriva vad en optimeringsalgoritm är, och sedan titta närmare på en speciell sådan algoritm, nämligen *differential evolution*.

Optimeringsalgoritmer är algoritmer som given en funktion som skall minimeras, och ett antal parametrar som kan varieras, försöker hitta den parameterkombination som ger minsta möjliga värde på funktionen. Vid valet av optimeringsalgoritm lönar det sig ofta att utnyttja den information som man har om det problem som skall lösas. År funktionen som skall minimeras t.ex. kontinuerlig, eller deriverbar, så kan det utnyttjas. I vårt fall är emellertid funktionen resultatet av simuleringen av ett helt scenario, vilket gör att vi kan garantera väldigt få egenskaper hos den. I sådana fall finns det få skräddarsydda optimeringsalgoritmer att tillgå, utan man tvingas använda mer generella varianter, så kallade heuristiker för global optimering. Anledningen att de kallas heuristiker är att de har få, eller mycket svaga, garantier för kvalitén på den lösning de hittar, och tiden de behöver för att hitta den. I de fall då man har begränsad information om sin målfunktion är de emellertid de enda verktyg som finns till hands, och beroende problem och tillgängliga beräkningsresurser kan deras prestanda ofta vara fullt tillräckliga.

En effektiv och enkel heuristik för global optimering är *differential evolution* [10]. Jämfört med algoritmer som genetiska algoritmer och *simulated annealing* har den färre inställningsparametrar och bättre, eller likvärdig, prestanda.

I likhet med många andra heuristiker jobbar den med ett antal parallella lösningskandidater, ur vilka nya kandidater skapas och förkastas baserat på deras funktionsvärde. I Differential Evolution skapas de nya kandidaterna på två sätt, dels genom *crossover*, kopiering av delar av andra kandidater, och dels genom *mutation*, addering av en skalad differens av två andra kandidater.

### **3.2.6 Preliminära resultat: tester av kvaliten hos de syntetiska aktörerna**

Som nämntes ovan, har vi vid tiden för skrivandet av denna rapport ännu inte påbörjat körningarna för parameteroptimeringen. Vi har dock genomfört kvalitetstester av de grundbeteenden som utvecklats. Den 9/11 och den 15/11 har vi låtit de syntetiska aktörerna bedriva luftstrid mot riktiga pilot från Flygvapnet. Genomgående är piloterna mycket nöjda med beteendena, vilket exemplifieras av utlåtande som t.ex. ”Bra!”, och ”Detta är inte långt från verkligheten, hade man inte vetat att de var datorgenererade hade man inte misstänkt något”. Dock är de mänskliga piloterna fortfarande något bättre än de datorgenererade. Det sker nedskjutningar på båda sidor, men människorna vinner i längden. Att ytterligare höja prestandan hos de syntetiska aktörerna är därför önskvärt, och denna aktivitet är ett steg på vägen.

### 3.3 Detektering

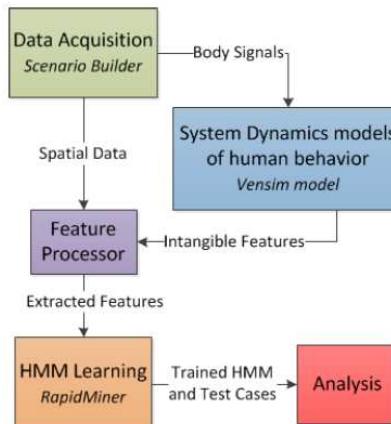
Beteendedetektering handlar om att agenter i t.ex. POPSIM, simulerade soldater i VBS2 eller fysiska robotar skall förses med förmågan att autonomt analysera en situation för att identifiera beteenden hos t.ex. en eller flera mänskliga aktörer. Idén är att t.ex. en robot som medverkar i ett mänskligt lag skall kunna anpassa sitt beteende för att på bästa sätt stötta och hjälpa det mänskliga laget.

Nytta med den här typen av beteendemodellerings teknik är främst:

- Förbättrade aktörsmodeller som autonomt kan anpassa sitt beteende för att stötta medspelare eller för att motverka motspelare.
- Automatisk annotering eller ”taggning” av databaser skapade vid t.ex. militära övningar som sträcker sig över flera dagar.
- Syntetiska kommentatorer för spel och övning.

Under året har projektet finansierat ett examensarbete med inriktning på detektering av beteenden. Examensarbetet bygger vidare på forskning som pågått under flertalet år hos *The Networking and Mobile Computing Laboratory* (NetMoc) på University of Central Florida<sup>2</sup> [11].

Till skillnad från tidigare arbete där beteendedetektering utgått enbart från rörelsemönster har detta examensarbetet fokuserat på att inkludera *Human Behavior Representation* (HBR) aspekter i detekteringsalgoritmen. Figur 3.10 visar överskådligt hur detekteringssystemet är uppbyggd.



Figur 3.10: Översikt av beteendedetekteringssystemet.

<sup>2</sup><http://hector.cs.ucf.edu/teamwork/>

På samma sätt som i Kapitel 3.1 har *ScenarioBuilder* använts för visualisering och editering av data. Förädlingsprocessen i *ScenarioBuilder* har utökats med HBR aspekter representerade i systemdynamikmodeller. Förädlad data används sedan som input till *RapidMiner* vars maskininlärningsalgoritmer används för att skapa Hidden Markov Modeller (HMM) en för varje beteendemönster som skall kunna detekteras.

Examensarbetet visar att det är fullt möjligt att utöka existerande beteendedetekteringsalgoritmer med HBR aspekter. En stor utmaning i arbetet har varit att identifiera relevanta HBR modeller som inte bara är konceptuellt beskrivna utan som även är implementerade och exekverbara. Examensarbetet i sin helhet finns att tillgå på begäran.

## 4 Slutsatser

Årets verksamhet inom projektet har främst fokuserat på populationssimulatorn, POPSIM, som är tänkt att stötta MSS i framtida övning och träning av strid i bebyggelse. POPSIM har under året utökats med modeller på i stort sett alla fronter vilket har resulterat i att POPSIM utöver MSS:s användningsområde har nyttjats i studier finansierade av det FOI interna SBKL-projektet och FMV:s HBR-projekt. Det är dock viktigt att poängtala att även om POPSIM har stor potential att utvecklas till en mycket användbar produkt (inte bara för MSS utan även för andra aktörer inom FM) i dagsläget endast är en prototyp och att en större insats kommer att krävas för att produktifiera POPSIM i framtiden.

Utöver POPSIM har projektet ägnat sig åt idéverksamhet och utvärdering av lovande och framtida tekniker för beteendemodellering i stort. Mycket uppmuntrande resultat har påvisats kanske främst inom beteendeimitering där maskininlärningsalgoritmer har nyttjats för att automatiskt skapa beteende-modeller som sedan kan användas i t.ex. POPSIM eller andra simulatorer. Vid demonstrationsmötet hos MSS i slutet av året [2] framkom dessutom ett behov av förbättrade aktörsmodeller i VBS2 något som ovan nämnda arbete delvis berör.

### 4.1 Planerad verksamhet under 2013

Projektet kommer även att under 2013 fokusera på vidareutveckling av POPSIM. Stor vikt kommer att läggas på att skapa ett scenario där MSS nyttjar POPSIM i sin träningsverksamhet för att tidigt identifiera vad som måste förbättras till projektets slutdemonstration som är planerad att genomföras under 2014. Nedan listas några av de aktiviteter som planeras att genomföras med avseende på POPSIM under 2013:

- Framtagning av scenario där POPSIM används för träningsändamål. I scenariot skall ingå att via befintliga inspel anskaffa information om exempelvis uppskattat opinionsläge samt identifiering av inflytelserika aktörer. Scenariot skall väga informationsanskaffning mot risk. Framtaget scenario skall implementeras under 2013 för att sedan vidareutvecklas under 2014.
- Framtagning av två perspektiv (där varje perspektiv består av ett antal vyer) vilka representerar lägesbilden för övningsledaren (d.v.s. facit) samt lägesbilden för spelaren vilken kan vara felaktig, osäker och ofullständig.
- Möjlighet att koppla hur inspel påverkar populationens opinion i tid och rum. Opinion skall t.ex. påverkas mer om ett patrulleringsinspel sker vid högtider och i närheten av fredade byggnader.

## Litteraturförteckning

- [1] Linus J. Luotsinen, Fredrik Johansson, Mikael Lundin, Petter Ögren, and Emil Salling. Statusrapport juni 2012, Syntetiska aktörer, FoT nr 922:01.03. *FOI-MEMO-3968*, pages 1–8, 2012.
- [2] Linus J. Luotsinen. Redovisning av milstolpe kv4 2012 för projekt Syntetiska aktörer, FoT nr 922:01.03. *FOI-MEMO-4141*, pages 1–3, 2012.
- [3] Linus J. Luotsinen. Redovisning av milstolpe kv4 2012 för projekt Syntetiska aktörer, FoT nr 922:01.03. *FOI-MEMO-4230*, 2012.
- [4] Mikael Lundin. Beteendemodeller, POPSIM, Utvecklingsmöjligheter. *FOI-MEMO-2739*, pages 22–23, 2009.
- [5] Mikael Lundin and Linus Luotsinen. Simulering av befolkning i stadsmiljö. *FOI-MEMO-3540*, 2011.
- [6] Eric Carlsson. A simulation based crisis management laboratory. *FOI-MEMO-4157*, 2012.
- [7] U.S. Environmental Protection Agency (EPA). Acute Exposure Guideline Levels (AEGLs). <http://www.epa.gov/oppt/aegl/>.
- [8] Tobias Horney, Mikael Brännström, Joakim Bergman, Dennis Andersson, Robert Forsgren, Simon Ahlberg, Björn Lindahl, and Anders Törne. Slutrapport MOSART. *FOI-R-1814*, 2005.
- [9] Ingo Mierswa, Michael Wurst, Ralf Klinkenberg, Martin Scholz, and Timm Euler. Yale: Rapid prototyping for complex data mining tasks. In Lyle Ungar, Mark Craven, Dimitrios Gunopulos, and Tina Eliassi-Rad, editors, *KDD '06: Proceedings of the 12th ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 935–940, New York, NY, USA, August 2006. ACM.
- [10] Rainer Storn and Kenneth Price. Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces. *J. of Global Optimization*, 11(4):341–359, December 1997.
- [11] L. J. Luotsinen, H. Fernlund, and L. Bölöni. Automatic annotation of team actions in observations of embodied agents. In *The Sixth Intl. Joint Conf. on Autonomous Agents and Multi-Agent Systems (AAMAS 07)*, pages 32–34, 2007.
- [12] Lars Tyden, Hanna Andersson, Per Brännström, Leif Festin, Torbjörn Härje, and Mikael Petersson. Planeringsverktyg EWPlan v3.3. *FOI-R-3067-SE*, 2010.

- [13] Daniel W. Franks, Jason Noble, Peter Kaufmann, and Sigrid Stagl. Extremism propagation in social networks with hubs. *Adaptive Behavior - Animals, Animats, Software Agents, Robots, Adaptive Systems*, 16(4):264–274, 2008.
- [14] Haoxiang Xia, Huili Wang, and Zhaoguo Xuan. Opinion dynamics: A multidisciplinary review and perspective on future research. *International Journal of Knowledge and Systems Science*, 2(4):72–91, 2011.
- [15] Claudio Castellano, Santo Fortunato, and Vittorio Loreto. Statistical physics of social dynamics. *Reviews of Modern Physics*, 81:591–646, 2009.
- [16] Jan Lorenz. Continuous opinion dynamics under bounded confidence: A survey. *International Journal of Modern Physics C*, 18:1819–1838, 2007.
- [17] F. Amblard and G. Deffuant. The role of network topology on extremism propagation with the relative agreement opinion dynamics. *Physics A*, 343:725–738, 2004.
- [18] Joel E. Cohen, John Hajnal, and Charles M. Newman. Approaching consensus can be delicate when positions harden. *Stochastic Processes and their Applications*, 22(2):315–322, 1986.
- [19] Noah E. Friedkin and Eugene C. Johnsen. Social influence networks and opinion change. *Advances in Group Processes*, 16:1–29, 1999.
- [20] Rainer Hegselmann and Ulrich Krause. Opinion dynamics and bounded confidence, models, analysis and simulation. *Journal of Artificial Societies and Social Simulation*, 5(3), 2002.
- [21] M. Porfiri, E. M. Bollt, and D. J. Stilwell. Decline of minorities in stubborn societies. *The European Physical Journal B*, 57:481–486, 2007.
- [22] M. F. Laguna, G. Abramson, and D. H. Zanette. Minorities in a model for opinion formation. *Complexity*, 9:31–36, 2004.
- [23] Rainer Hegselmann and Ulrich Krause. Opinion dynamics driven by various ways of averaging. *Computational Economics*, 25(4):381–405, June 2005.
- [24] Guillaume Deffuant, Frédéric Amblard, Gérard Weisbuch, and Thierry Faure. How can extremism prevail? A study based on the relative agreement interaction model. *Journal of Artificial Societies and Social Simulation*, 5(4), 2002.
- [25] P. Erdős and A. Rényi. On random graphs. I. *Publ. Math. Debrecen*, 6:290–297, 1959.
- [26] Duncan J. Watts and Steven H. Strogatz. Collective dynamics of 'small-world' networks. *Nature*, 393(6684):440–442, June 1998.

- [27] A.L. Barabasi and R. Albert. Emergence of scaling in random networks. *Science*, 286, 1999.
- [28] Guillaume Deffuant. Comparing Extremism Propagation Patterns in Continuous Opinion Models. *Journal of Artificial Societies and Social Simulation*, 9(3), 2006.
- [29] M. N. Kuperman and D. H. Zanette. Stochastic resonance in a model of opinion formation on small world networks. *Eur. Phys. J. B*, 26:387–391, 2002.
- [30] T. Carletti, D. Fanelli, S. Grolli, and A. Guarino. How to make an efficient propaganda. *Europhysics Letters*, 74(2), 2006.

# A Cellular communications model

## A.1 Introduction

This document describes the radio communication model implemented and used in POPSIM [5]. The model was derived from EWPlan [12]. Using the model one individual in POPSIM is able to communicate with another individual given that they both have cellular phones with good enough reception.

## A.2 Modeling cell phone reception

The quality of reception is derived from the signal-to-noise ratio (SNR).

$$SNR = \frac{S_r}{N} \quad (\text{A.1})$$

, where  $S_r$  represents the signal strength received by the cell phone and  $N$  represents noise. The model supports both background noise as well as noise introduced by multiple jamming systems. A threshold parameter,  $SNR_t$  is used to model cell phone service such that:

$$\text{service} = \begin{cases} \text{true,} & \text{if } SNR > SNR_t \\ \text{false,} & \text{otherwise} \end{cases} \quad (\text{A.2})$$

### A.2.1 Calculating signal strength, $S_r$

The signal strength at the receiver,  $S_r$  is calculated as follows:

$$S_r = \frac{P_t \times G_t \times G_r}{L} \quad (\text{A.3})$$

, where  $P_t$  is the effect used by the transmitter.  $G_t$  and  $G_r$  represent the antenna gain at the transmitter and receiver respectively. In our implementation it is assumed that all antennas are isotropic, hence, antenna gain is set to 1 for both receiver and transmitter.  $L$  is the signal attenuation which is calculated as follows:

$$L = \frac{(4\pi \times r)^2}{\lambda^2} \quad (\text{A.4})$$

, where  $r$  is the distance between transmitter and receiver.  $\lambda$  is the wavelength of the transmitted signal. The wavelength of a signal is calculated as follows:

$$\lambda = \frac{c}{F_c} \quad (\text{A.5})$$

, where  $F_c$  is the carrier frequency and  $c$  is the constant representing speed of light (299792458 m/s).

### A.2.2 Calculating noise, $N$

As mentioned above, noise can be both natural and man-made. The noise value,  $N$ , is represented by the sum of all noise sources as follows:

$$N = \sum_{k=1}^K n_k \quad (\text{A.6})$$

, where  $K$  is the total number of noise sources and  $n_k$  is the noise of the  $k^{th}$  source. Let's now describe the noise sources implemented in our model.

#### A.2.2.1 Background noise

Background noise originates from many different sources. Here we model both receiver and man-made noise as follows:

$$n_b = k \times T_0 \times B \times F \quad (\text{A.7})$$

, where  $k$  is the Boltzmann constant ( $1.3806503 \times 10^{-23}$ ),  $T_0$  is the absolute temperature (290K),  $B$  is the bandwidth of the transmitted signal and  $F$  is a man-made noise factor.

#### A.2.2.2 Jamming noise

The noise introduced by jamming devices,  $n_j$ , is calculated as follows:

$$n_j = \sum_{k=1}^K \frac{P_{tk} \times G_{tk} \times G_r}{L} \times Q_k \quad (\text{A.8})$$

, where  $K$  is the total number of jamming devices,  $P_{tk}$  and  $G_{tk}$  is the effect and antenna gain of the  $k^{th}$  jamming device,  $G_r$  is the antenna gain of the receiver,  $L$  is the attenuation value (see Equation A.5) and  $Q_k$  is the  $k^{th}$  jammer bandwidth overlap ratio with respect to the receiver. Note that our model support noise from several jamming devices.

#### A.2.2.3 Summary

The final noise calculated by Equation A.9 using the above noise sources (background and jamming) is:

$$N = n_b + n_j \quad (\text{A.9})$$

## B Chemical exposure model

### B.1 Introduction

This document describes the chemical exposure model implemented and used in POPSIM [5]. The model uses guideline values covering a rich set of chemicals as defined by the Acute Exposure Guideline Levels (AEGL) program [7] to model the degree health effects (slightly injured, severely injured or dead) as a function of each individual's accumulated exposure time and concentration.

When used in POPSIM the model is typically paired with a dispersion model that is responsible for spreading the substance once it has been released. Dispersion models are not discussed in this document.

### B.2 The AEGL program

The AEGL program provides guideline values that describe health effects in three levels [7]:

- *"AEGL 1 is the airborne concentration, expressed as parts per million or milligrams per cubic meter (ppm or mg/m<sup>3</sup>) of a substance above which it is predicted that the general population, including susceptible individuals, could experience notable discomfort, irritation, or certain asymptomatic nonsensory effects. However, the effects are not disabling and are transient and reversible upon cessation of exposure."*
- *"AEGL 2 is the airborne concentration (expressed as ppm or mg/m<sup>3</sup>) of a substance above which it is predicted that the general population, including susceptible individuals, could experience irreversible or other serious, long-lasting adverse health effects or an impaired ability to escape."*
- *"AEGL 3 is the airborne concentration (expressed as ppm or mg/m<sup>3</sup>) of a substance above which it is predicted that the general population, including susceptible individuals, could experience life-threatening health effects or death."*

Each chemical in the AEGL program is associated with a look-up-table (LUT) that defines the threshold values used to classify AEGL levels. Also, a technical support document is provided which describes the threshold values in greater detail. As an example, let's look at the AEGL table for sulfur dioxide.

From Table B.1 it is easy to determine the AEGL level of an individual given its accumulated exposure time and concentration. For instance, an individual is AEGL 1 if it has been exposed to SO<sub>2</sub> for more than 10 minutes at a concentration of 0.20 ppm. Similarly, an individual is AEGL 3 if it has

	10 min	30 min	60 min	4 hr	8 hr
AEGL 1	0.20	0.20	0.20	0.20	0.20
AEGL 2	0.75	0.75	0.75	0.75	0.75
AEGL 3	30	30	30	19	9.6

Tabell B.1: AEGL table of sulfur dioxide.

been exposed to 30ppm for more than 10 minutes or if it has been exposed to 9.6ppm for 8 hr or more.

### B.3 Modeling chemical exposure

POPSIM individuals use histograms to keep track of chemical exposure. Each bin in the histogram represent exposure time at a user defined concentration interval. Exposure time,  $T$ , is calculated using the histogram as follows:

$$T = \sum_{k=1}^K t_k \quad (\text{B.1})$$

, where  $K$  is the total number of bins in the histogram and  $t_k$  the time associated with bin  $k$ . Concentration,  $C$ , is calculated as an weighted average over all bins:

$$C = \sum_{k=1}^K \left( c_k \times \frac{t_k}{T} \right) \quad (\text{B.2})$$

, where  $K$  is the total number of bins in the histogram,  $c_k$  is the mean value of the concentration interval of bin  $k$ ,  $t_k$  is the time of bin  $k$  and  $T$  is the total exposure time (see Equation B.1).

## C Literature review: Opinion dynamics

### C.1 Introduction

As human beings, we have opinions on nearly anything: politics, sports, literature, and religion to name a few topics. In a world without communication and interaction with others, our opinions would most likely be a result of each person's individual reflections. However, in reality we are living in a quite densely connected world with a lot of communication. Our opinions can of course be shaped by individual reflection anyway, but the social context is also heavily influencing our opinions. As argued in [13], our opinions are influenced by who we talk to, and whose opinions we respect. There are a lot of social studies showing that individuals' opinions tend to become more alike as we interact with each other. This is in social science literature often referred to as social influence, while this kind of behavior often is referred to as herd behavior in economics [14]. No matter what term is used, understanding the process of social influence and the social structures that govern our human interaction is very important in order to understand how opinions change in a population. Such research is central for many social scientists, and the results from such studies have got a large impact on the development of opinion dynamics, i.e., the research field in which mathematical and physical models as well as computational tools are utilized to explore the dynamical process of the diffusion and evolution of opinions in human populations [14].

Quite much attention has been given to opinion dynamics in recent years, not least within the statistical physics community. However, the research is according to [14] still quite immature, and the attempts to build reasonable mathematical models of opinion change often lack reference to real sociological studies [15]. Moreover, almost all models of opinion dynamics assume a closed system which is not affected by the outside world.

In this report, we aim at providing readers who are unfamiliar with the research field an overview of the most popular opinion dynamic models. An extra focus is given to so called bounded confidence (BC) models, since these seems most relevant for our purpose of finding suitable models to implement in the multi-agent simulation tool POPSIM. We also describe how this kind of models can be implemented into POPSIM in order to simulate various scenarios of interest for the Swedish Armed Forces. This kind of simulations could potentially be used when testing different strategies or when planning the use of psychological operations (psyops). In order to make such modeling possible, we propose to extend the standard BC models and the relative agreement (RA) model to also take into account external stimuli, such as propaganda and reactions to external events. We also plan to use dynamically evolving social networks rather than static networks, where the latter is used in nearly all

existing research on opinion dynamics.

## C.2 Overview of Opinion Dynamic Models

If we consider a group of interacting agents (be it a small group of experts or an entire society) among whom a process of opinion dynamics takes place, we can after some finite time typically observe one out of three possible cases:

- *Consensus* among the agents.
- *Polarization* into two groups of opinions.
- *Fragmentation* into a larger group of opinions.

There have been numerous attempts in literature to create models of opinion change that share basic high-level features with the social influence observed in sociology and social psychology. In any model of opinion dynamics, an individual's opinion is modeled as a variable or a set of variables, and the problem is to find a set of adequate mathematical rules for describing their change over time as agents interact [15]. As we will see, many of the proposed models are hugely simplified, considering binary opinions only. Binary opinion models can be sufficient for situations where there are only two choices, typically matching a yes/no-decision, or choosing between two alternatives (e.g., buying or selling shares). These kind of simple models have dominated the opinion dynamics research due to their striking analogy with spin models that are popular within the physics field [16, 14], making it possible to simplify the analysis of the models. Although binary models such as voter models and Snzajd models (further described in Section C.3) are favorable due to their close mapping to spin models, they are insufficient for many problem situations [14], dealing with negotiation problems or fuzzy attitudes which does not correspond well to pure yes/no-decisions. Continuous bounded confidence (BC) models (described in Section C.4) relax the binary or discrete assumption and yields more complex non-linear interactions in which two agents influence each other only if their opinion distance is below a certain threshold. For such models, analytical results are harder to obtain. So called master equations (used to describe the time evolution of a dynamical system) have been used with some success in e.g., [16], but in general, results for finite populations are analyzed using agent-based simulations. As mentioned in [14], the recent advances in complex adaptive systems has allowed for agent-based simulations to become an important tool for understanding the social process of opinion change.

Although the opinion dynamics of BC models are quite complex compared to simple binary models, it should be remembered that they too are oversimplified. Looking at existing models from a social science perspective, they often rely on oversimplified assumptions that neglect many physiological and behavioral complexities [14]. However, all modeling of social agents involves large

simplifications of the problem, and no one knows the exact dynamics of single individuals nor the way they interact with each other [15]. The idea with current opinion dynamic models is that the qualitative properties of macro-level phenomena do not depend on the exact micro-level details. Instead, only higher-level features are supposed to be relevant for the global behavior. This means that it (hopefully) is feasible to discover general qualitative features even though only the simplest and most important properties of single individuals are incorporated into the models [15].

### C.3 Discrete models

As noted in [17], most of the opinion dynamic models available in literature are based on simple physical models consisting of binary, or more generally, discrete opinions. We will in this section briefly review three kinds of binary models: the voter model (Section C.3.1), the majority rule model (Section C.3.2), and the Sznajd model (Section C.3.3).

#### C.3.1 Voter model

The voter model is a very simple model where each agent has a binary opinion variable  $x$  that can take on one of the values  $-1$  (negative opinion) or  $+1$  (positive opinion). The updating rule dictates that in each time step an agent  $i$  is randomly selected along with one of its neighbors (agent  $j$ ), whereupon the first selected agent takes the opinion of its selected neighbor, i.e.,  $x_i = x_j$ . In this way the agents are indirectly affected by the majority of their peers, since the probability that an agent takes on an opinion is proportional to the number of its neighbors with that opinion.

Despite its simplicity the voter model has become very popular, due to the fact that it can be solved exactly in any dimension. A number of modifications to the simple model have been suggested, such as [15]:

- possibility for an agent to spontaneously change opinion (even though its earlier opinion is similar to all its neighbors' opinions). This is sometimes referred to as a noisy voter model.
- introduction of “zealots” who does not change their opinion at all.
- checking the state of two neighbors instead of one. The update rule is modified to flip opinion if any of the two neighbors' opinions are different from the agent's current opinion. This is referred to as a vacillating voter model.
- introduction of a counter or memory, demanding  $m$  interactions with positive/negative neighbors before changing opinion. This reduces the noise in the model.

### C.3.2 Majority rule model

The majority rule model was initially suggested for describing public debates. As in the voter model, each agent's opinion variable can take on one of the values  $-1$  and  $+1$ . Having a population of  $N$  agents, we refer to the fraction of agents with positive opinion ( $+1$ ) as  $p_+$ , and the fraction of agents with negative opinion ( $-1$ ) as  $p_-$  (where  $p_- = 1 - p_+$ ). Assuming that all agents can interact with each other, the update rule dictates that a “discussion group” of  $r$  agents are selected at each time point, and as a result of the discussion all selected agents take on the majority opinion within the group. The value of  $r$  is in each time step selected from a given distribution. If  $r$  is even there is a chance that either opinion is supported by  $r/2$  agents. In this case the usual solution is to introduce a bias in favor of one of the opinions.

Analyzing the model it can be shown that if  $p_+^0$  is defined as the initial fraction of agents with opinion  $+1$ , the opinion dynamic process is governed by a threshold  $p_c$  such that in the long run all agents will have opinion  $+1$  for  $p_+^0 > p_c$  and  $-1$  for  $p_+^0 < p_c$ . The exact value of this threshold depends on the size  $r$  of the discussion groups.

A number of modifications to the majority rule model have been suggested, such as [15]:

- multi-state opinions (in which the model becomes discrete instead of binary).
- each agent interacts with a variable number of neighbors.
- inflexible agents who does not change their opinions (i.e. the previously presented “zealots” ).
- accounting for the possibility that minority opinions in a discussion group can prevail.

### C.3.3 Sznajd model

The last discrete model we will describe is the Sznajd mode which also is a popularly used opinion dynamics model. The basic principle behind the Sznajd model is that it is easier for a pair of individuals to convince someone than it is for a single individual. The update rule of the original Sznajd model says that opinions should be updated in random sequential order and that a pair of neighboring agents  $i$  and  $i + 1$  determines the the opinions of their nearest neighbors  $i - 1$  and  $i + 2$  as follows:

- if  $x_i = x_{i+1} \rightarrow x_{i-1} = x_i = x_{i+1} = x_{i+2}$ ,
- if  $x_i \neq x_{i+1} \rightarrow x_{i-1} = x_{i+1}$  and  $x_{i+2} = x_i$ .

The second update rule (i.e. if  $x_i \neq x_{i+1}$ ) has been criticized for being unrealistic and is therefore often ignored so that neighbors of a pair of disagreeing agents maintain their previous opinion.

As for the other described models, various modifications or extensions have been proposed, including to [15]:

- allow different kinds of topologies (regular lattices, complete graphs, random graphs, etc.).
- change from random sequential updating to synchronous updating.

## C.4 Continuous models

While the models presented in Section C.3 have modeled opinions as a binary (or in the more general case a discrete) variable, there are in many cases also a need for continuous variables, allowing for smoother opinion changes. Rather than just having a pure yes/no decision or an extreme left and an extreme right opinion, it is in many situations necessary to let opinion variables take on values somewhere in between the extreme cases. This kind of distinguishing between extreme and moderate opinions is not possible with binary models. Continuous models assume a population of  $N$  agents where the opinions are represented by real numbers within an interval (typically  $[0, 1]$  or  $[-1, 1]$ ). The initial opinions are typically uniformly distributed so that all opinions are equally likely. The most common type of continuous opinion models are so called bounded confidence (BC) models, in which it is assumed that only people with reasonably similar opinions will be able to influence each other. This kind of threshold conditioning assumption creates non-linear continuous models which can be seen as more complex models than previously suggested continuous linear opinion models such as the ones suggested in [18] and [19]. The most common types of BC models are the models suggested by Hegselmann and Krause [20] (in the rest of this report referred to as the HK model) and Deffuant et al. (in the rest of this report referred to as the Deffuant model). In these models an individual can influence another individual (agent) whenever its opinion is inside the opinion segment of the other agent. More formally, the situation can be described using an uncertainty/tolerance  $\epsilon$ , such that an agent  $i$  with opinion  $x_i$  only interacts with an agent  $j$  if its opinion lies in the opinion segment  $s_j = [x_j - \epsilon, x_j + \epsilon]$ , i.e., if  $|x_i - x_j| \leq \epsilon$  (assuming that all agents have the same  $\epsilon$ ).

As we will see, the HK and Deffuant models are very similar and only differ in their communication regime.

### C.4.1 The Deffuant model

In the Deffuant model, we can model our population of agents as a graph in which the  $N$  nodes represent the agents, and where there is an edge between

two nodes  $i$  and  $j$  if their corresponding agents can interact directly with each other. Each agent  $i$  is associated with an opinion  $x_i(t)$ , where  $(t)$  denotes a time step, so that the vector  $\vec{x}(t) = (x_1(t), \dots, x_n(t))$  represents the population's opinion profile at time  $t$ . At each time step  $t$ , there is an encounter between a randomly selected agent and one of its neighbors. Now, if  $i$  and  $j$  is the pair of interacting agents, the update rule specifies that if the opinion differences between the two is too large, nothing will happen. If the opinions instead are similar enough, the opinions of the interacting agents will get closer to each other by a relative amount  $\mu$ . Mathematically speaking, this can be formalized as:

$$x_i(t+1) = \begin{cases} x_i(t) + \mu[x_j(t) - x_i(t)], & \text{if } |x_i - x_j| \leq \epsilon \\ x_i(t), & \text{otherwise} \end{cases}$$

and

$$x_j(t+1) = \begin{cases} x_j(t) + \mu[x_i(t) - x_j(t)], & \text{if } |x_i - x_j| \leq \epsilon \\ x_j(t), & \text{otherwise.} \end{cases}$$

Except for the threshold parameter  $\epsilon$  (sometimes interpreted as the agents' uncertainty) which is common for all the BC models, there is also the convergence parameter  $\mu \in [0, 1]$  which is specific for the Deffuant model. The value of this parameter decides how much the agents' opinions should get closer to each other (this parameter is in [21] described as a measure of the persuasibility or open-mindedness of an agent). This value is most often chosen to be set to 0.5, meaning that the agents' opinions will converge in the middle. Small values of  $\mu$  correspond to "stubborn" agents who are hard to influence, while large values of  $\mu$  imply a will to compromise [21].

The Deffuant model and its pairwise interactions is according to [15] suitable for describing the opinion dynamics of large populations where people meet in small groups.

Like the other BC models, the Deffuant model is not analytically solvable. Most insights on the resulting dynamics are therefore derived through numerical/agent-based simulations. Such simulations have shown that in general, the number of (and the size of) opinion clusters (i.e., sets of agents holding the same/very similar opinions) depend on the threshold  $\epsilon$ , while the parameter  $\mu$  in general only affects the convergence time. More specifically, the number of clusters in the final stable configuration is often approximated using the value  $\text{Integer}(w/(2\epsilon))$ , where  $w$  is the width of the initial opinion distribution, i.e.,  $w$  typically equals 1 since the interval  $[0, 1]$  is used most often. Hence, for large uncertainty consensus is obtained in the population, whereas low uncertainties do not lead to consensus [22]. For small value of  $\mu$ , this parameter can also has an impact on the final cluster configuration [21, 22].

A number of modifications, extensions and special cases of the Deffuant model have been proposed in the literature. This includes to:

- let agents have individual values of  $\epsilon$  of  $\mu$  (representing that agents can be more or less uncertain and more or less open-minded).

- introduce external periodic perturbations simulating the affect of propaganda.
- test the impact of various types of social networks.

#### C.4.2 The Hegselmann-Krause (HK) model

The HK model is very similar to the Deffuant model. While an agent in a pairwise fashion is interacting with one neighbor in each step in the Deffuant model, it is in the HK model interacting with all neighbors at once. With respect to an opinion profile  $\vec{x} = (x_1, \dots, x_n)$ , an agent is confident only in the agents belonging to his confidence set  $I(i, x)$ , where  $I(i, x) = \{1 \leq j \leq n \mid |x_i - x_j| \leq \epsilon\}$ . This confidence set also includes the agent itself, i.e.  $i$ . Now, the agent's opinion in the time period  $t + 1$  is given by the arithmetic mean of the opinions of the agents in the confidence set  $I(i, x)$  for the time period  $t$ . More formally, if  $I$  represents  $I(i, x(t))$ , we have that:

$$x_i(t+1) = \frac{1}{|I|} \sum_{j \in I} x_j(t).$$

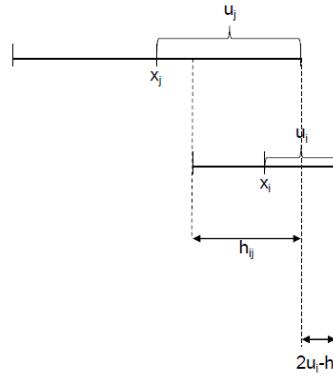
Compared to the Deffuant model, the HK model is more computationally demanding since it takes an average of all its compatible neighbors (which can be quite many) rather than just interacting with a single neighbor. This is in [15] listed as a likely reason for why the HK model has not been as well studied as Deffuant's model. The update rule stating that an agent who is confident in the opinions of a selected group of other agents forms an average opinion by taking an arithmetic mean is in [23] generalized to take into account also other kinds of means, such as the geometric and harmonic means. The HK model's updating rule is according to [15] intended to describe formal group meetings in which there is interactions among many people at the same time.

Due to the averaging mechanism, there is in the HK model no need for a convergence parameter as in the Deffuant model. Instead, only the uncertainty parameter  $\epsilon$  has to be modeled.

#### C.4.3 The relative agreement (RA) model

The relative agreement model (RA) model proposed in [24] can be seen as an extension of a BC model. As for BC models, agents with radically different opinions will not influence each other in the RA model, but in addition to this it also captures the ideas that some agents may be more uncertain than others (more susceptible to social influence) and that certain agents are more influential than the uncertain ones. However, the main property of the RA model is that an agent's influence on another agent is varying linearly with the relative agreement (i.e., the overlap) between their opinion segments. Hence, the differences between RA and the standard BC models is that the RA model allows for [24]:

- a non-symmetric influence, where the influence varies as the inverse of the influencing agent's uncertainty.
- agents influencing other agents uncertainty in addition to their opinions.
- a continuous variation of the influence corresponding to the distance between the two agents' opinions.



Figur C.1: Illustration of the metrics of interest when calculating how much agent  $j$  is influenced by agent  $i$  (adapted from [24]).

As in the Deffuant model, the population consists of  $N$  agents which interacts using pairwise interactions. Each agent  $i$  is characterized by an opinion variable  $x_i$  and an uncertainty  $u_i$ . The update rule of the RA model makes use of the relative agreement, which can be calculated as follows. First, we define the opinion segments of agents  $i$  and  $j$  as:

$$s_i = [x_i - u_i, x_i + u_i]$$

and

$$s_j = [x_j - u_j, x_j + u_j]$$

(where the uncertainty variable  $u$  corresponds to  $\epsilon$  in the standard BC models). Using these opinion segments, we can calculate the (non-symmetric) overlap  $h_{ij}$  of agent  $i$  with agent  $j$  as:

$$h_{ij} = \min(x_i + u_i, x_j + u_j) - \max(x_i - u_i, x_j - u_j).$$

Now, the agreement can be calculated as the overlap minus the width of the non-overlap, i.e.:

$$h_{ij} - (2u_i - h_{ij}) = 2(h_{ij} - u_i).$$

Finally, the relative agreement can be calculated as the agreement divided by the length of segment  $s_i$ , i.e.:

$$\frac{2(h_{ij} - u_i)}{2u_i} = \frac{h_{ij}}{u_i} - 1$$

This value of the relative agreement is used in the update rule, saying that:

$$x_j(t+1) = \begin{cases} x_j(t) + \mu(\frac{h_{ij}}{u_i} - 1)(x_i(t) - x_j(t)), & \text{if } h_{ij} > u_i \\ x_i(t), & \text{otherwise} \end{cases}$$

and

$$u_j(t+1) = \begin{cases} u_j(t) + \mu(\frac{h_{ij}}{u_i} - 1)(u_i(t) - u_j(t)), & \text{if } h_{ij} > u_i \\ x_i(t), & \text{otherwise.} \end{cases}$$

Note that this is very similar to the standard BC dynamics, except for the multiplication with the relative agreement. To better explain the metrics of interest for calculations of the relative agreement, Figure C.1 illustrates some of the metrics defined above. The constraint that  $h_{ij}$  has to be larger than  $u_i$  for an update to take place corresponds to the idea that the opinion segment of an agent has to intersect with the actual opinion of the other agent if an interaction should take place.

Experiments in [24] show that the RA models general behavior is similar to the standard BC models. The number of clusters obtained in simulations where an initial uniform distribution of opinions of width  $w$  and a constant initial uncertainty  $u$  is used for the whole population is shown to be close to  $w/(2u)$ , somewhat different from the Deffuant model in which the the number of clusters can be approximated by the integer part of  $w/(2u)$  as explained in Section C.4.1 (note that  $\epsilon$  and  $u$  can be used interchangeably).

## C.5 Other aspects to take into consideration

### C.5.1 The impact of the social structure

Most of the work that has been done on opinion dynamics assume simple structures in which agents are located regularly in space (in lattices) or that each agent can be interacting with all other agents (fully connected networks). The study of the effect of more complex social networks is according to [15] currently a hot topic. Examples of more complex networks are the random graph [25] and the small-world network model introduced in [26]. Examples of the effect of social network structure are given in Section C.5.2. Of extra interest here is the phenomenon of evolving networks, since many real networks are generated dynamically rather than statically. An example of such a type of network is the scale-free networks generated by the Barabasi-Albert model [27]. The effect of scale-free networks that have been generated dynamically but does not change during the simulations has been tested in existing literature,

but to the best of our knowledge, no one has studied the effect of dynamic networks that change as the simulation runs. This is an aspect that can be tested by implementing opinion dynamic models into POPSIM.

### C.5.2 The influence of extremists

As mentioned in [13], there are many cases where an initially small minority of “extremists” succeed with spreading their opinion to a majority of the population. One tragic example which often is used is the spread of extreme opinion in e.g. Germany during the 1930’s, but interestingly enough, also ideas that today are mainstream, e.g. womens’ right to vote, has at some point in time been seen as being extreme. Another example mentioned in [24] is the spread of religious ideas. When studying the impact of extremists on opinion dynamics, extremists should not necessarily be interpreted as having the wrong ideas, but rather as having marginal opinions far away from the “middle”.

The influence of extremists on opinion dynamics has been studied in a number of papers. All of these make use of continuous models since extremist opinions as we define it here cannot be modeled in binary models. In [24], the introduction of extremists in a fully connected network is tested for the RA model. Extremists are modeled by introducing agents at the extremes of the opinion distribution with very low uncertainty (and high persuasion) compared to the other agents. The authors justify this by arguing that people with extreme opinions tend to be more convinced than people with moderate opinions. Their results show that for a low general uncertainty, the influence of extremists was limited to agents who initially got similar opinions as the extremists. In this case the majority of the population ended up in “central convergence”. However, for high general uncertainty the results were different. In those cases the extremist opinions tended to prevail, leading to bi-polarization or convergence to a single extreme. This work is in [17] extended to test the influence of the social network. It is shown that when having a RA model with extremists in a small-world social network topology, opinions converge to a single extreme only in cases where the average number of connections for each individual is extremely high. These experiments have been replicated in [13], and are in the same paper extended to also test the effect on convergence behavior when changing the small-world topology to a network in which there are positively skewed degree distributions (more similar to scale-free networks than to small-world networks). In their experiments, it is found that such a positively skewed network topology results in single extremism convergence under a wider range of conditions than the small-world network. Moreover, the effects of having extremists placed on hubs in such networks are also demonstrated. As is shown in their experiments, the importance of social position is very important. When placing “positive” extremists with one view at central hubs, the whole population converge to the positive extreme although there are twice as many “negative” extremists in the network (having a complete opposite view). Finally, the patterns of extremism propagation is also tested in [28], in which

the behavior of a RA model, a Deffuant model and two other continuous opinion models are compared for three types of social structures: a fully connected network, a random network, and a lattice. The robustness of the results are also tested by at each time step introducing a probability of random variations to the agents' opinions, where the strength of the random variation is regulated by an agent's level of uncertainty. The main results show that the RA model yield double extreme convergence for high initial uncertainty of the non-extremists when there are high proportions of extremists, for any type of network and any value of  $\mu$ . For the cases where the initial uncertainty of the non-extremists is high and there are small proportions of extremists, single extreme convergence is a likely final state for the RA model. The introduction of noise does not seem to have a significant impact on the results.

The modeling of extremists can potentially be an interesting aspect to test in POPSIM.

### C.5.3 Connections to the “real world”

In [16] it is highlighted that nearly all opinion dynamic studies use random and uniformly distributed initial opinion profiles. To connect the agents' opinions to specific information about “the real world out there” is in [24] listed as an important objective for future work. We share this view and would like to stress the importance of using opinion profiles that in some sense are better connected to the real world (the scenario one would like to simulate).

Another thing which is common to nearly all traditional opinion dynamic models is that the final state of the system after an interaction among agents is well-defined, i.e., they make use of deterministic update rules. However, many recent models are according to [15] starting to focus on the importance of non-determinism, i.e., randomness, in the opinion dynamics process. As they observe, our individual opinions as well as other peoples' influence on our opinion may vary in a way that is very hard to fully predict. Therefore, it can be of interest to introduce an amount of randomness in the models. An example of a model that incorporate such randomness is presented in [29]. That model uses the simple majority rule, but additionally also introduce external modulation affecting all the agents for modeling the role of period fashion, and random noise for modeling individual uncertainty. Another model in which outside perturbation of the opinion dynamics is modeled explicitly is presented in [30]. They extend the Deffuant model to investigate how propaganda can affect the dynamics of a group's opinion. This is implemented as a periodic perturbation that interacts instantaneously with all the agents in the population. Their results imply that in order to attain a maximum efficiency of propaganda as modeled in their model, the optimal range of the propaganda period depends on the open-mindedness ( $\mu$ ) of the agents. The idea to not let the agents' final state be determined by their initial opinion profiles and their random interactions only is something that we would like to incorporate in our simulations. For this reason, we would like to let the agents behavior be affected by external

stimuli, such as propaganda (tv, media, psysops, etc.) and to other external events taking place in the simulation (the placement of road blocks, soldiers behaving badly against civilians, etc.