

# Datenschutz & UbiComp

RESEARCH GROUP FOR

*Distributed  
Systems*

Am Beispiel von Location Privacy  
Betreuer: Marc Langheinrich

**ETH**

Eidgenössische Technische Hochschule Zürich  
Swiss Federal Institute of Technology Zurich

Thierry Bücheler

# Inhalt

---

- Einführung: Location Based Services
- Gegenwärtige Probleme
- Privacy & Anonymity
- Lösungsvorschlag 1
- Lösungsvorschlag 2
- Was wird eigentlich gelöst?
- Fazit: Was ist zu tun?

# Location Based Services

---

- **Location Based Services (LBS)** sind Mehrwertdienste, die sich auf den aktuellen Standort des Users beziehen
- Optimalerweise wird der Standort **automatisch** erkannt
- **Positionsdaten** in Verbindung mit dem **personalisierten Benutzerprofil** des Nutzers erlauben ein massgeschneidertes Angebot

# LBS - freiwillig?

---

- Bei Active Badge/Bat kann ein User trivialerweise auf die **Herausgabe seiner Ortsinfo verzichten**, indem er sie einfach nicht nützt.

Dies ist aber **nicht möglich** bei grösseren Netzwerken wie z.B. GSM-Interfaces oder nationalen gesichtserkennenden Kameraprojekten.

# Anwendungsbeispiel



← subscribe

publish →

← LBS: Preis

↔



Middleware



Tankstellenzone

# Inhalt

---

- Einführung: Location Based Services
- Gegenwärtige Probleme
- Privacy & Anonymity
- Lösungsvorschlag 1
- Lösungsvorschlag 2
- Was wird eigentlich gelöst?
- Fazit: Was ist zu tun?

# Das Problem

---

- Zugang zu Information kontrollieren
- Aber nicht gesamten Zugang sperren
- Gegensätzliche Ziele

# Attacken

---

- Verschiedene Arten von Attacken:
  - **Locating/Lokalisierung:** Das Subjekt kann auf verschiedene Arten lokalisiert werden, z.B. aufdecken von LBS-Informationen oder Wireless-Signale triangulieren.
  - **Identification/Identifikation:** Der Real-world-Name oder z.B. die Adresse des Subjekts wird bekannt. Netzwerkadressen werden nicht als Identifikation des Subjekts bezeichnet, sondern als Pseudonyme, welche es ermöglichen können, ein Subjekt zu identifizieren.
- Lokalisierung und Identifikation sind z.T. verknüpft.



# Was will man also:

---

- Von Vorteilen des Ortstrackings profitieren
- Privacy gewährleisten/schützen
- Wahre Identität des Users geheim halten

# Inhalt

---

- Einführung: Location Based Services
- Gegenwärtige Probleme
- Privacy & Anonymity
- Lösungsvorschlag 1
- Lösungsvorschlag 2
- Was wird eigentlich gelöst?
- Fazit: Was ist zu tun?

# Privacy

---

- Die Universal Declaration of Human Rights (UNO, 1948) deklariert, dass jedermann ein Recht auf Privatsphäre (Privacy) zu Hause, in der Familie und in seiner Korrespondenz hat.

# Location Privacy

---

- Location Privacy ist eine **spezielle Art von** sogenannter **Information Privacy**, definiert als die Fähigkeit, andere daran zu hindern, den gegenwärtigen oder vergangenen Aufenthaltsort einer Person zu erfahren [1,3].

# Location Privacy

---

- Der Schutz der Privatsphäre wird als genügend erachtet, wenn die Verfolgung einer Person (Ortstracking) einen **vergleichbaren Aufwand benötigt wie traditionelle Überwachungsmaßnahmen** (Beschatten, Funksender an Auto haften etc.). [2]

# Policies

---

- Eine gegenwärtig schon eingesetzte Praxis ist es, dem User von LBS sogenannte **Privacy Policies** vorzulegen, welche den User über die Datenverwendung des Providers informieren und dem User als Entscheidungsbasis dienen, Informationen freizugeben.

# Anonymity

---

- Anonymität kann einen **hohen Grad an Privacy ermöglichen**, rettet Service-Nutzer davor, sich mit den Privacy Policies (Verträge) der Serviceprovider herumzuschlagen und reduziert die Anforderungen der Serviceprovider, private Information zu schützen [1,2].
- Anonymität wird daher als geeignetes Mittel empfunden, die Privatsphäre eines Nutzers ausreichend zu schützen.

# Wo Daten schützen?

---

- Daten sind schwieriger zu schützen, wenn sie einmal auf einem System gespeichert sind.
- Der Vorschlag von Gruteser et al. [3] erhöht die Privacy durch verteilte Anonymitätsmechanismen direkt im (Sensor-)Netz.



# Inhalt

---

- Einführung: Location Based Services
- Gegenwärtige Probleme
- Privacy & Anonymity
- Lösungsvorschlag 1
- Lösungsvorschlag 2
- Was wird eigentlich gelöst?
- Fazit: Was ist zu tun?

# Gruteser & co.

---

- Die Mechanismen in diesem Paper anonymisieren die Daten **direkt in einem Sensornetz**. Somit muss sich der Provider nicht um die Sicherheit kümmern.
- Ein Problem bei vielen vorgeschlagenen Privacy-Lösungen ist, dass die **Middleware von nicht vertrauenswürdigen Institutionen gesteuert** werden kann, was die Anonymität brechen kann.

# Gruteser & co.

---

- Gewisse Applikationen benötigen **aggregierte Statistiken** über die Popularität gewisser Orte (z.B. im Supermarkt), aber nicht unbedingt präzise Informationen über den genauen Standort einer einzelnen Person zu einem bestimmten Zeitpunkt.

—————→ „**Zählapplikationen**“

# Gruteser & co.

---

- Drei Voraussetzungen müssen bei diesem System gewährleistet sein:
  - Hierarchische Aggregation
  - Data Cloaking
  - Sichere Kommunikation


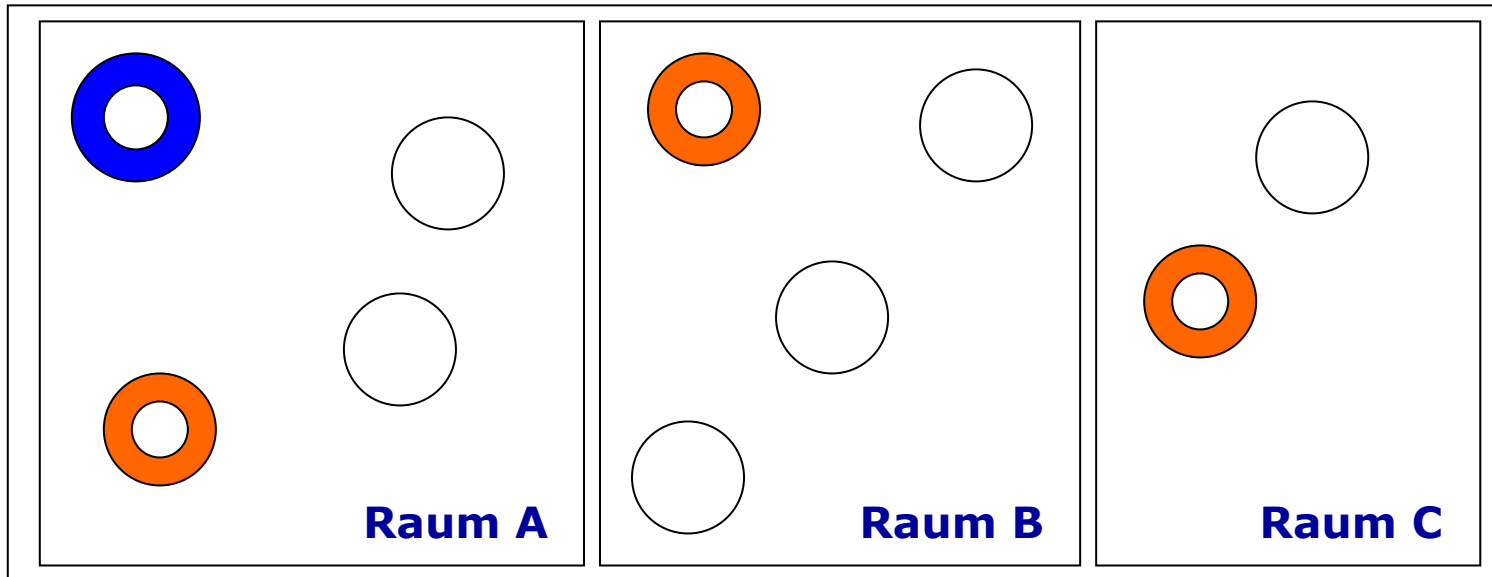
# Hierarchische Aggregation

---

- Das Netzwerk aus Sensorknoten wird hierarchisch gegliedert
- Auf jedem Hierarchielevel benötigt man einen **CL (co-ordination leader)**
- Die IDs der Knoten werden mit einem „**Präfixcode**“ bestückt, d.h. Knoten haben dieselbe **Stockwerk-/Raum-ID** codiert, die IDs an sich sind aber alle eindeutig (unique)

# Beispiel mit CLs in Räumen


## Stockwerk 1



**Stockwerk CL**



**Raum CL**



**Anderer Knoten**

# IDs

---

Floor ID	Sub-room ID		
<b>1010</b>	<b>1110</b>	<b>1011</b>	<b>0010</b>
	Room ID		Unique ID

# K-Anonymität

---

- Dieser Begriff stammt von Samarati und Sweeney:
- Daten sind **k-anonym**, wenn jeder Ortsevent (erfasstes Subjekt) aus dem Netzwerk un-unterscheidbar ist von mindestens  $k-1$  anderen Ortsevents (Subjekten).



# Data Cloaking

---

- Knoten setzen zwei Techniken ein um die Anonymität zu erhöhen:
  - Biete weniger örtliche Genauigkeit
  - Verwische die Anzahl gezählter Subjekte in der Zone

# Data Cloaking

---

- Das Sensornetz verwischt die Daten, sodass das **k-Anonymitäts-Kriterium erfüllt** wird. Im Idealfall wird nur minimal verwischt, damit die Daten ihre Brauchbarkeit für möglichst viele Applikationen behalten.
- Daten können auf zwei Arten gecloaked werden:
  - Cloake die ID (Ort des Sensors), liefere präzise Date
  - Cloake die Daten, liefere die präzise ID
- Zwischen diesen zwei Varianten wird eine ausgewählt, indem die Anzahl Subjekte mit einem festgesetzten **Anonymitätslevel k** verglichen wird. Übersteigt die Anzahl Subjekte  $k$ , werden die Daten gecloaked und die ID wird präzis geliefert (und umgekehrt).

# ID Cloaking

---

Floor ID		Sub-room ID	
<b>1010</b>	<b>1110</b>	<b>XXXX</b>	<b>XXXX</b>
Room ID		Unique ID	

Floor ID		Sub-room ID	
<b>1010</b>	<b>1110</b>	<b>1011</b>	<b>XXXX</b>
Room ID		Unique ID	

# Sichere Kommunikation

---

- Knoten sollen mit **verschlüsselten** und **authentifizierten** Datenpaketen kommunizieren
- Um Traffic Analysis zu verhindern, ist jeder Knoten verpflichtet, **mindestens ein Paket** pro Datensammlungsintervall zu versenden (auch wenn kein Event eintritt)

# Also:

---

- Lösungsvorschlag 1 ermöglicht v.a. eine „**Ortsunschärfe**“ (die Verwischung der Daten agiert sozusagen als Zückerchen, welches nicht vertieft wird)
- Lösungsvorschlag 1 schützt v.a. vor **Lokalisierungsattacken**
- Es ist aber schwierig, diese Technologie auf einzelne Individuen und deren Tracking anzuwenden

# Inhalt

---

- Einführung: Location Based Services
- Gegenwärtige Probleme
- Privacy & Anonymity
- Lösungsvorschlag 1
- Lösungsvorschlag 2
- Was wird eigentlich gelöst?
- Fazit: Was ist zu tun?


# Pseudonyme?

---

- Verschiedene Arten von LBS:
  - ID wichtig
  - ID unwichtig
  - Pseudonym genügt

# Statische Pseudonyme

---





# Beresford & Stajano

---

- Langfristige Pseudonyme sind nicht stark genug, IDs zu anonymisieren. Eine Lösung dieses Problems ist es, bei jeder Registrierung ein **ganzes Set von Pseudonymen** zu erhalten, und die Pseudonyme während des Trackings zu wechseln.

# Szenario

---

- Normalerweise will man nicht, dass LBS-Informationen für einen bestimmten Ort einer **Applikation an einem anderen Ort** bekannt werden.
- Somit können die Event-Callbacks **an Zonen gebunden** werden.
- Was aber, wenn diese Zonen hinter unserem Rücken **miteinander Informationen austauschen?**

# Beresford & Stajano

---

- Beresford und Stajano empfehlen ein „Privacy-protecting Framework“, welches auf **oft ändernden Pseudonymen** basiert, damit Benutzer nicht einfach verfolgt oder mit beliebigen Orten in Verbindung gebracht werden können.

—————> TRIVIALE LÖSUNG

# Beresford & Stajano

---

- Wechselnde Pseudonyme sind aber auch problematisch, falls die räumliche und zeitliche Auflösung eines Systems gross genug ist
- Homes
- Footsteps

# Wie wird's gelöst?

---

- Um dieses Problem zu beheben, führen Beresford und Stajano die „**Mix Zones**“ ein.

# Mix Zones

---

- Mix zones gehen auf **Mix networks** und **Mix nodes** (von David Chaum) zurück.
- Store-And-Forward-Netzwerke
- n gleich lange verschlüsselte Pakete als Input
- Reihenfolge nach einer bestimmten Metrik (z.B. lexikografisch oder zufällig)

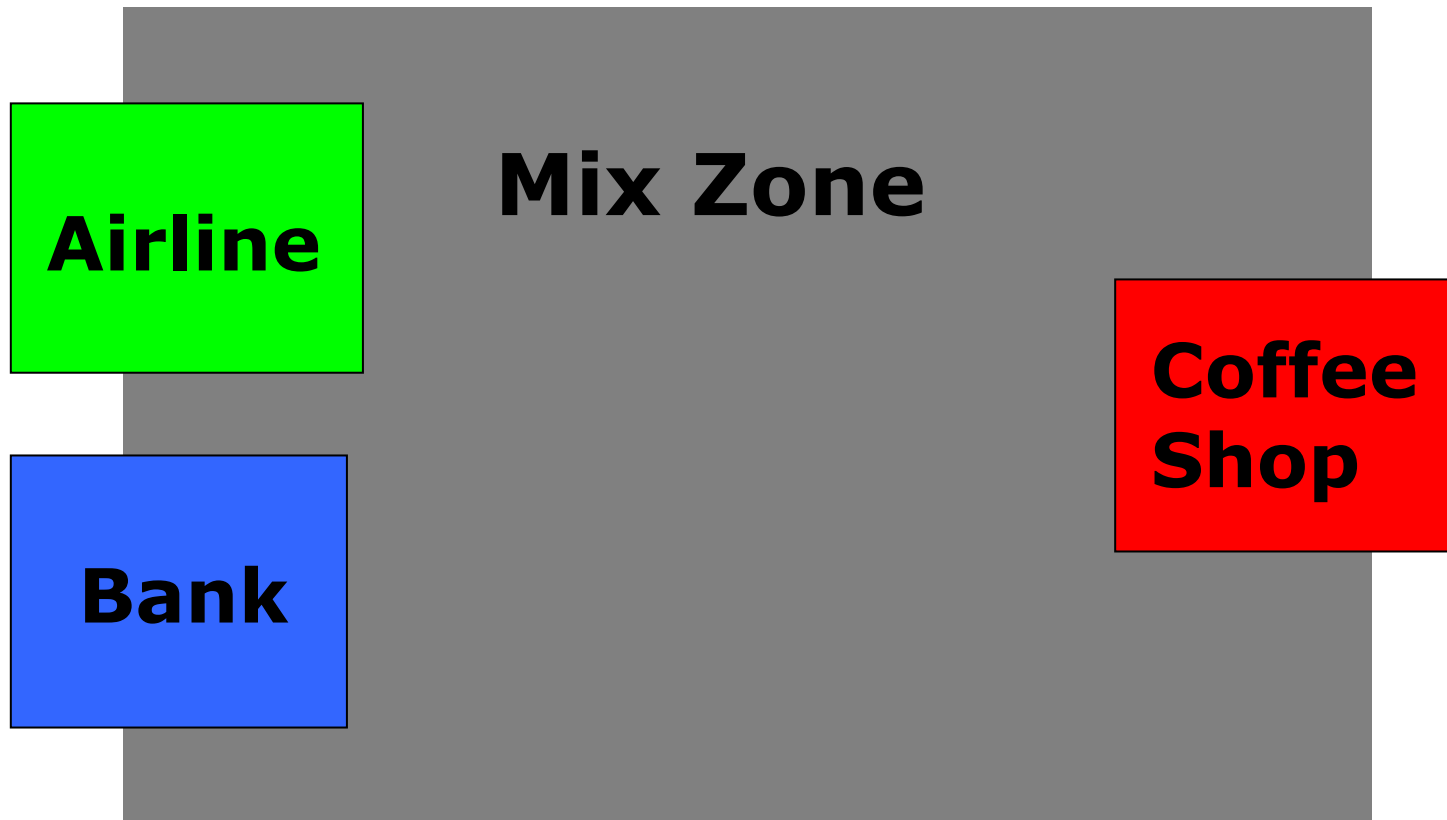
# Mix Zone

---

- Beresford und Stajano definieren die Mix Zone als eine **örtliche Region maximaler Grösse**, in welcher **kein User einen Event-Callback registriert** hat.
- Im Gegensatz dazu sind „**Application Zones**“ Orte, an denen mindestens ein User Event-Callbacks registriert hat.
- Mix Zones können a priori von der Middleware definiert oder laufend berechnet werden.

# Modell

---





# Das Mixen

---

- Weil Applikationen **keinerlei Ortsinformationen** erhalten, während User in einer Mix Zone sind, werden Identitäten „gemixt“.
- Ein User ändert sein Pseudonym in einer Mix Zone und ein böser Beobachter kann keine Verbindung zwischen „eingehenden“ und „ausgehenden“ Usern herstellen.

# K-Anonymität beim Mixen

---

- Die k-Anonymität wird erreicht, sobald **k** **Subjekte zur gleichen Zeit in einer Mix Zone** sind (oder die Mix Zone dementsprechend vergrössert wird)
- Ein User kann dann entscheiden, dass der **Anonymitätslevel k** ihm **genügend Privatsphäre** bietet.

# Aber: Geografie

---

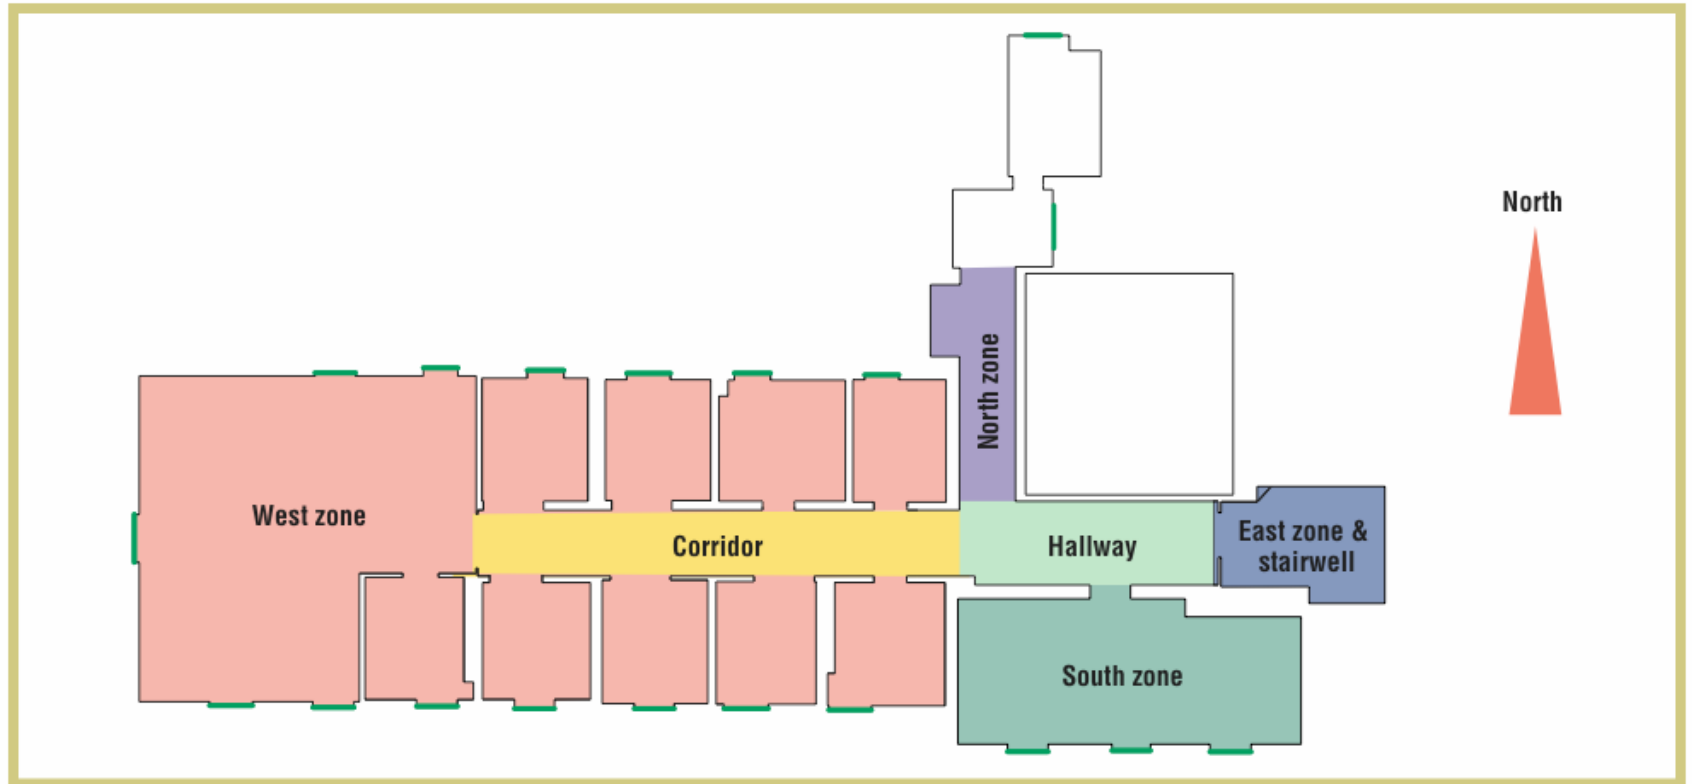
- Es besteht eine **starke Korrelation** zwischen Eintritts- und Austrittspunkt in einer Mix Zone.
- Die k-Anonymität in einer Mix Zone ist nur ein gutes Mass, wenn **alle Subjekte** für einen bösen Beobachter **gleich interessant** sind. In diesem Fall haben wir die maximale Entropie (gemäss Shannon).

# Theorie

---

- Beresford & Stajano haben in ihrem Feldversuch jeweils die **vorhergende Zone (p)** und die **nachfolgende Zone (s)** geloggt und eine Bewegungsmatrix erstellt.

# Die AT&T Labs



# Bewegungsmatrix

	East	North	South	West	Mix zone
Mix zone	96	47	66	101	814
West	125	13	17	1	43
South	29	55	7	22	30
North	39	6	64	39	66
East	24	47	74	176	162

# Ein bisschen Mathe

---

**P(vorher=p, nachher=s) =**

$$\frac{M(p,s)}{\sum_{i,j} M(i,j)}$$

# Bedingte W'keit

---

**$P(\text{nachher}=s \mid \text{vorher}=p) =$**

$$\frac{M(p,s)}{\sum_j M(p,j)}$$



# Entropie

---

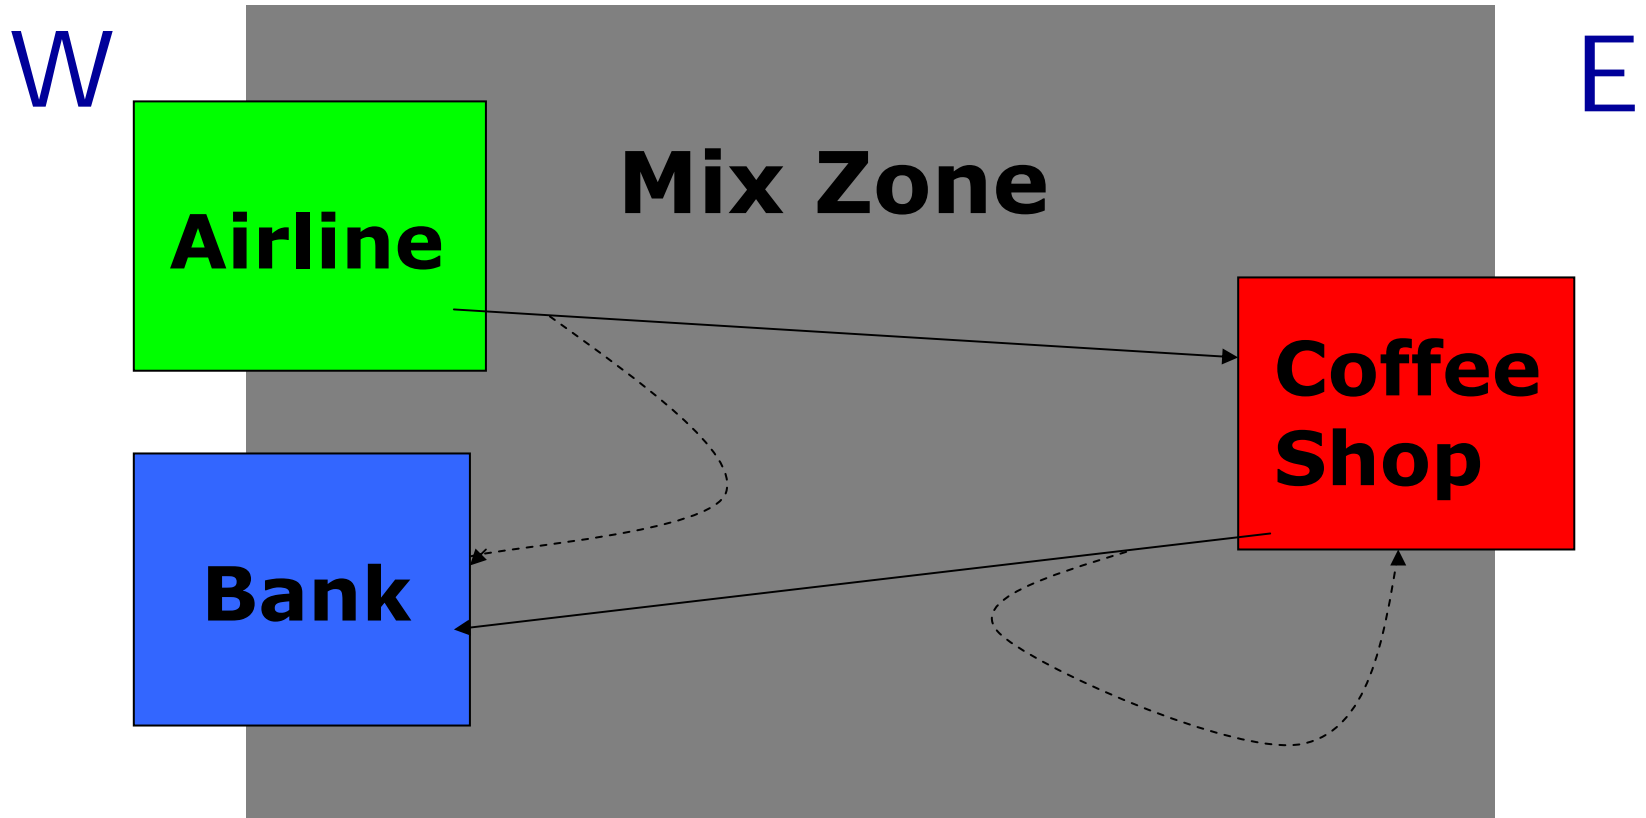
$$H = - \sum_i p_i * \log p_i$$

# Wieso Informationstheorie?

---

- Nehmen wir an, ein böser Beobachter verfügt über die **historischen Daten** der Bewegung (die Matrix).
- Ein Beispiel demonstriert, dass die **Anonymität geringer** ist, als die k-Anonymität suggeriert:
- Wir vergleichen die Wahrscheinlichkeit, dass zwei Subjekte von **Ost nach West** (bzw. umgekehrt) gehen, mit der Wahrscheinlichkeit, dass sie einen „**U-Turn**“ machen.

# Modell



# Vergleich (Herleitung)

---

- Wahrscheinlichkeit beobachtet:

EEWW ∨ EWWE ∨ WEEW ∨ WWEE

- Wahrscheinlichkeit U-Turn:

EEWW ∨ WWEE

# Numerische Lösung

---

- Die Wahrscheinlichkeiten werden z.B. so errechnet:

$$p(EWWE) = p(EW) * p(WE)$$

Die Wahrscheinlichkeiten stammen aus der Matrix (mit den obigen Formeln):

$$\mathbf{p(\text{beobachtet}) = 0.414}$$

$$\mathbf{p(\text{uturn}) = 0.0005}$$

# Bedingte W'keit

---

- Wir wollen wissen, wie gross die Wahrscheinlichkeit ist, dass beide Subjekte einen uturn gemacht haben:

$$p(\text{uturn} | \text{beobachtet}) =$$

$$\frac{p(\text{uturn} \wedge \text{beobachtet})}{p(\text{beobachtet})} = 0.001$$

# Entropie ist genauer!

---

- Der Informationsgehalt des Resultats ist also nicht 1 Bit, wie wenn die Wege gleichwahrscheinlich wären, sondern viel kleiner.
- Die Entropie beträgt in diesem Fall 0.012 Bits.

# Also:

---

- Lösungsvorschlag 2 ermöglicht v.a. eine „**ID-Unschärfe**“ (mit Hilfe der Pseudonymisierung)
- Lösungsvorschlag 2 schützt v.a. vor **Identifikationsattacken**
- Lösungsvorschlag 2 hat gezeigt, dass Pseudonymisieren nicht so einfach ist, wie es scheint und darum einige Anforderungen an die Sicherheit gestellt



# Inhalt

---

- Einführung: Location Based Services
- Gegenwärtige Probleme
- Privacy & Anonymity
- Lösungsvorschlag 1
- Lösungsvorschlag 2
- Was wird eigentlich gelöst?
- Fazit: Was ist zu tun?

# Was wird eigentlich gelöst?

---

- Gruteser und Grunwald
  - Dieser Approach stärkt Privacy-Schutz im Vergleich zu Lösungen auf dem DB-Level weil er das Sammeln von Privacy-sensitiven Daten verhindert
  - Bei „Bulk“-Applikationen (und allgemeiner Applikationen, die eine Ortsunschärfe erlauben) kann der Ort eines Einzelevents (-Subjekts) verschleiert werden.
  - Man kann eine gewisse (unscharfe) Awareness schaffen, die bei Bedarf (z.B. Emergency) geschärft werden kann (die Sensoren sind ja präzis verteilt)

# Was wird eigentlich gelöst?

---

- Beresford und Stajano
  - Dieser Approach ermöglicht es einem Individuum, das Tracking zu verhindern
  - Es wird ein Mass für Pseudonym-Switching hergestellt und gezeigt, dass die k-Anonymität einer Mix-Zone nicht als Qualitätsmass genügt
  - Es ist möglich, pseudonymisierte Services zu nutzen, solange man ab und zu mixt.
- Wer ist besser?
  - Ortsunschärfe-Apps vs. ID-Unschärfe-Apps: verschiedene Anwendungen

# Was geht (nicht)?

---

- Apps wie „Wo ist X?“ oder „Ich möchte ein Taxi an meine Adresse“ gehen nicht.
  - Hier darf weder der Ort noch die ID verschleiert werden.

# Inhalt

---

- Einführung: Location Based Services
- Gegenwärtige Probleme
- Privacy & Anonymity
- Lösungsvorschlag 1
- Lösungsvorschlag 2
- Was wird eigentlich gelöst?
- Fazit: Was ist zu tun?

# Fazit

---

- Für viele LBS ergibt die **Verwischung von Ortsinformationen wenig Sinn**. In diesem Fall ist es angebracht, an der Verwischung der Identität zu forschen, um den User anonym zu halten.
- Für verschiedene LBS-Arten müssen **verschiedene Privacy-Modelle** verwendet werden.

# Fazit 2

---

- Ein sinnvolles Ziel ist die **Datensparsamkeit** (data minimization). Man will nur so viele Daten verbreiten wie wirklich benötigt werden.
- Lösung 2 geht davon aus, dass das häufige Pseudonym-Wechseln keine Applikationen verunmöglicht. Stimmt das? Wie werden die Pseudonyme mit den wahren IDs gelinkt? Ist das nötig? Gibt's dann doch wieder Policies/Contracts?

# Fazit 3

---

- Benötigt wird ein **formales, wenn möglich probabilistisches Modell für Lokationsanonymität**, welches einen kontinuierlichen Datenstrom liefert. Dies würde eine bessere Evaluation ermöglichen.



# Letztes Fazit

---

- Ein besseres Verständnis über die **Anforderungen an die Genauigkeit** von Lokationsdaten für **verschiedene Klassen von Applikationen** würde eine Analyse des Anonymitätslevels für LBS- und Sensornetz-Applikationen erleichtern.

# Fragen?

---

## Kommentare?

## Diskussion?

# Literatur

---

- [1] Alastair R. Beresford & Frank Stajano: *Location Privacy in Pervasive Computing*, Security & Privacy Magazine, 2003
- [2] Gruteser & Grunwald: *Anonymous Usage of LBS through Spatial and Temporal cloaking*, 2003
- [3] Gruteser, Schelle, Jain, Han, Grunwald: *Privacy-Aware Location Sensor Networks*, Proceedings of HotOS IX, 2003
- [4] Gruteser, Grunwald: *A Methodological Assessment of Location Privacy Risks in Wireless Hotspot Networks*, 2003
- [5] Pfitzmann & Köhntopp: *Anonymity, Unobservability, and Pseudonymity - A Proposal for Terminology*, Draft v0.14, 2003