

# Export de NetFlows 9 sous Android et Localisation d'un utilisateur de smartphone à partir de ses flux réseaux

*5 septembre 2013*

Julien VAUBOURG  
Soutenance de stage 3<sup>e</sup> année

# Introduction

- ▶ Stage 3<sup>e</sup> année de TELECOM Nancy

- ▶ Stage 3<sup>e</sup> année de TELECOM Nancy
- ▶ 4 mois

- ▶ Stage 3<sup>e</sup> année de TELECOM Nancy
- ▶ 4 mois
- ▶ Orienté recherche

- ▶ Stage 3<sup>e</sup> année de TELECOM Nancy
- ▶ 4 mois
- ▶ Orienté recherche
- ▶ Partie ingénierie

- ▶ Stage Inria

- ▶ Stage Inria
- ▶ Établissement public de recherche



- ▶ Stage Inria
- ▶ Établissement public de recherche
- ▶ Sciences et technologies de l'information et de la communication

- ▶ Stage Inria
- ▶ Établissement public de recherche
- ▶ Sciences et technologies de l'information et de la communication
- ▶ LORIA : Unité Mixte de Recherche

- ▶ Stage Inria
- ▶ Établissement public de recherche
- ▶ Sciences et technologies de l'information et de la communication
- ▶ LORIA : Unité Mixte de Recherche
- ▶ Équipe Madynes (Abdelkader LAHMADI)

1. Développer un **exportateur NetFlow 9** modulaire pour Android
2. Travailler sur la **localisation d'un utilisateur de smartphone** à partir de ses flux réseaux

## 1. Android et NetFlow 9

1. Android et NetFlow 9
2. Exportateur de NetFlows

1. Android et NetFlow 9
2. Exportateur de NetFlows
3. Inférence de la localisation

1. Android et NetFlow 9
2. Exportateur de NetFlows
3. Inférence de la localisation
4. Résultats



# Android et NetFlows 9

- ▶ Système d'exploitation

- ▶ Système d'exploitation
- ▶ Smartphones et tablettes

- ▶ Système d'exploitation
- ▶ Smartphones et tablettes
- ▶ Distribution GNU/Linux

- ▶ Système d'exploitation
- ▶ Smartphones et tablettes
- ▶ Distribution GNU/Linux
- ▶ Libre (licence Apache)

- ▶ Système d'exploitation
- ▶ Smartphones et tablettes
- ▶ Distribution GNU/Linux
- ▶ Libre (licence Apache)
- ▶ Système mobile le plus populaire

- ▶ Synthétisation de flux **unidirectionnels**

- ▶ Synthétisation de flux **unidirectionnels**
- ▶ Paquets avec propriétés communes (IP et ports)



- ▶ Synthétisation de flux **unidirectionnels**
- ▶ Paquets avec propriétés communes (IP et ports)
- ▶ Version 9 : fonctionnement par **templates**

# Fonctionnement par templates

- ▶ Ajout dynamique de champs

# Fonctionnement par templates

- ▶ Ajout dynamique de champs
- ▶ Sémantique détachée du format


# Fonctionnement par templates

- ▶ Ajout dynamique de champs
- ▶ Sémantique détachée du format
- ▶ Optimisation des envois avec plusieurs templates

# Fonctionnement par templates

- ▶ Ajout dynamique de champs
- ▶ Sémantique détachée du format
- ▶ Optimisation des envois avec plusieurs templates
- ▶ Templates envoyés régulièrement mais pas systématiquement

# Format des NetFlows



## Exemple de paquet d'export

### Set de modèles

Modèle (1): src is IPv6; dst is IPv6; size is int

Modèle Record (2): src is IPv4; dst is IPv4; size is int

### Set de données (1)

NetFlow: src=fe80::1; dst=fe80::2; size=1337

NetFlow: src=fe80::2; dst=fe80::1; size=512

### Set de données (2)

NetFlow: src=192.88.99.1; dst=192.88.99.2; size=42

NetFlow: src=192.88.99.2; dst=192.88.99.1; size=53

— Envoie paquet d'export —→



# Exportateur de NetFlows

# Exportateur NetFlow pour Android

- ▶ **Inexistant** sur le marché



# Exportateur NetFlow pour Android

- ▶ **Inexistant** sur le marché
- ▶ **Nécessaire** pour l'analyse des flux réseau

# Exportateur NetFlow pour Android


- ▶ **Inexistant** sur le marché
- ▶ **Nécessaire** pour l'analyse des flux réseau
- ▶ **Scalabilité** et modularité

- ▶ Bibliothèque d'export **générique**

- ▶ Bibliothèque d'export **générique**
- ▶ **Implémentation stricte** de la RFC 3954 (NetFlow 9)

- ▶ Bibliothèque d'export **générique**
- ▶ **Implémentation stricte** de la RFC 3954 (NetFlow 9)
- ▶ **Interfaces claires** et souples

# Pilotes de communication



## Exemple de paquet d'export

### Set de modèles

Modèle (1): src is IPv6; dst is IPv6; size is int

Modèle Record (2): src is IPv4; dst is IPv4; size is int

### Set de données (1)

NetFlow: src=fe80::1; dst=fe80::2; size=1337

NetFlow: src=fe80::2; dst=fe80::1; size=512

### Set de données (2)

NetFlow: src=192.88.99.1; dst=192.88.99.2; size=42

NetFlow: src=192.88.99.2; dst=192.88.99.1; size=53

— Envoie paquet d'export —→



- ▶ Capturent les paquets du réseau

- ▶ Capturent les paquets du réseau
- ▶ **Bas niveau**



- ▶ Capturent les paquets du réseau
- ▶ **Bas niveau**
- ▶ Nécessite des privilèges

- ▶ Capturent les paquets du réseau
- ▶ **Bas niveau**
- ▶ Nécessite des privilèges
- ▶ **Code natif (C)**

- ▶ Capturent les paquets du réseau
- ▶ **Bas niveau**
- ▶ Nécessite des privilèges
- ▶ **Code natif (C)**
- ▶ Pilote **IPv4 et IPv6** fourni

- ▶ Exportateur de NetFlows pour Android

- ▶ Exportateur de NetFlows pour Android
- ▶ v1 par Madynes avec un exportateur externe en C

- ▶ Exportateur de NetFlows pour Android
- ▶ v1 par Madynes avec un exportateur externe en C
- ▶ Difficile à maintenir / faire évoluer

- ▶ Exportateur de NetFlows pour Android
- ▶ v1 par Madynes avec un exportateur externe en C
- ▶ Difficile à maintenir / faire évoluer
- ▶ **Implémentation de la bibliothèque**

- ▶ Pas de reprise de code



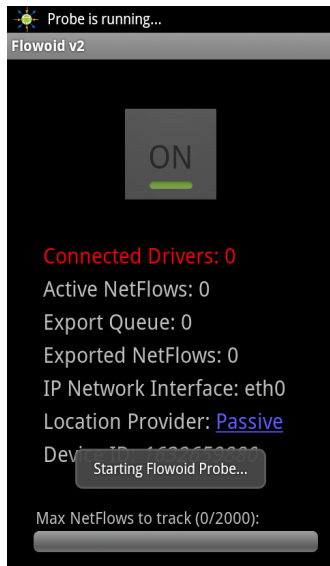
- ▶ Pas de reprise de code
- ▶ Cycle de vie de Android

- ▶ Pas de reprise de code
- ▶ Cycle de vie de Android
- ▶ Nom de l'interface réseau active

- ▶ Pas de reprise de code
- ▶ Cycle de vie de Android
- ▶ Nom de l'interface réseau active
- ▶ Application associée au flux

- ▶ Pas de reprise de code
- ▶ Cycle de vie de Android
- ▶ Nom de l'interface réseau active
- ▶ Application associée au flux
- ▶ Contraintes du collecteur

# Aperçu de Flowoid v2



# Aperçu de Flowoid v2



# Inférence de la localisation

« Inférence de la localisation d'un utilisateur de smartphone uniquement à partir de ses flux réseaux et sans données géotagguées »



« Inférence de la localisation d'un utilisateur de smartphone uniquement à partir de ses flux réseaux et sans données géotagguées »

► **Hypothèse 0 :**

1 type de lieu = 1 activité spécifique

« Inférence de la localisation d'un utilisateur de smartphone uniquement à partir de ses flux réseaux et sans données géotagguées »

► **Hypothèse 0 :**

1 type de lieu = 1 activité spécifique

► **Hypothèse 1 :**

1 séquence de NetFlows récurrente (*pattern*) = 1 type de lieu

« Inférence de la localisation d'un utilisateur de smartphone uniquement à partir de ses flux réseaux et sans données géotagguées »

► **Hypothèse 0 :**

1 type de lieu = 1 activité spécifique

► **Hypothèse 1 :**

1 séquence de NetFlows récurrente (*pattern*) = 1 type de lieu

► **Objectif :**

Trouver de quand à quand l'utilisateur était au lieu A, au lieu B, etc.

## 1. État de l'art

# Organisation du travail

1. État de l'art
2. Pertinence des informations à disposition

# Organisation du travail

1. État de l'art
2. Pertinence des informations à disposition
  - ▶ Adresses IP de destination


1. État de l'art
2. Pertinence des informations à disposition
  - ▶ Adresses IP de destination
3. Construction d'un modèle

1. État de l'art
2. Pertinence des informations à disposition
  - ▶ Adresses IP de destination
3. Construction d'un modèle
4. Expérimentations




1. État de l'art
2. Pertinence des informations à disposition
  - ▶ Adresses IP de destination
3. Construction d'un modèle
4. Expérimentations
5. Conclusions

# Recherche des patterns




élaguage

Itération n°1



élaguage

Itération n°2



élaguage

Iteration n°3

# Regroupement des patterns

## 1. **Nombre cohérent** de patterns

# Regroupement des patterns

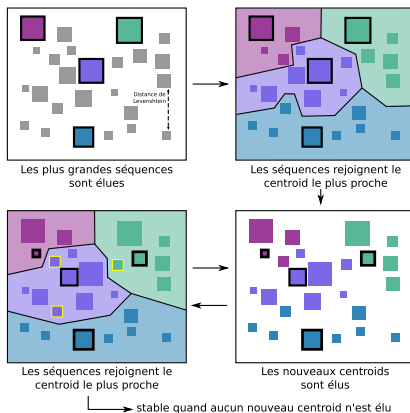
1. **Nombre cohérent** de patterns
2. K-means avec un **nombre imposé**

# Regroupement des patterns


1. **Nombre cohérent** de patterns
2. K-means avec un **nombre imposé**
3. Domicile, Déplacements, Travail, Loisirs

# Regroupement des patterns

1. **Nombre cohérent** de patterns
2. K-means avec un **nombre imposé**
3. Domicile, Déplacements, Travail, Loisirs



# Application des patterns



**Séquence recherchée :** c d e f

**Taille de la séquence :** 4

**Distance max. :** 1

# Résultats



Périodes témoins :

- ▶ **Coordonnées géographiques**

Périodes témoins :

- ▶ **Coordonnées géographiques**
- ▶ Nom des **applications associées**

Périodes témoins :

- ▶ **Coordonnées géographiques**
- ▶ Nom des **applications associées**
- ▶ **Fusion à la main** des flux et lieux similaires

Périodes témoins :

- ▶ **Coordonnées géographiques**
- ▶ Nom des **applications associées**
- ▶ **Fusion à la main** des flux et lieux similaires
- ▶ **Classification** des types lieux et réduction à 4 différents

Périodes témoins :

- ▶ **Coordonnées géographiques**
- ▶ Nom des **applications associées**
- ▶ **Fusion à la main** des flux et lieux similaires
- ▶ **Classification** des types lieux et réduction à 4 différents
- ▶ **Interrogation de l'utilisateur**

Périodes témoins :

- ▶ **Coordonnées géographiques**
- ▶ Nom des **applications associées**
- ▶ **Fusion à la main** des flux et lieux similaires
- ▶ **Classification** des types lieux et réduction à 4 différents
- ▶ **Interrogation de l'utilisateur**

Expérimentation :

Périodes témoins :

- ▶ **Coordonnées géographiques**
- ▶ Nom des **applications associées**
- ▶ **Fusion à la main** des flux et lieux similaires
- ▶ **Classification** des types lieux et réduction à 4 différents
- ▶ **Interrogation de l'utilisateur**

Expérimentation :

- ▶ Découverte des **patterns**

Périodes témoins :

- ▶ **Coordonnées géographiques**
- ▶ Nom des **applications associées**
- ▶ **Fusion à la main** des flux et lieux similaires
- ▶ **Classification** des types lieux et réduction à 4 différents
- ▶ **Interrogation de l'utilisateur**

Expérimentation :

- ▶ Découverte des **patterns**
- ▶ Détection des **périodes**



Périodes témoins :

- ▶ **Coordonnées géographiques**
- ▶ Nom des **applications associées**
- ▶ **Fusion à la main** des flux et lieux similaires
- ▶ **Classification** des types lieux et réduction à 4 différents
- ▶ **Interrogation de l'utilisateur**

Expérimentation :

- ▶ Découverte des **patterns**
- ▶ Détection des **périodes**
- ▶ **Comparaison** avec les périodes témoins

- ▶ Périodes témoins peu fiables

- ▶ Périodes témoins peu fiables
- ▶ Sollicitation forte de l'utilisateur


- ▶ Périodes témoins peu fiables
- ▶ Sollicitation forte de l'utilisateur
- ▶ Immiscion dans sa **vie privée**

- ▶ Changements supposés de lieu à des heures étranges

- ▶ Changements supposés de lieu à des heures étranges
- ▶ Patterns pollués par des IP récurrentes


- ▶ Changements supposés de lieu à des heures étranges
- ▶ Patterns pollués par des IP récurrentes
- ▶ Bruit de fond (routines) trop important

# Distinction des routines





# Distinction des routines



# Distinction des routines

- ▶ 59% courriels (vérification régulière)

# Distinction des routines

- ▶ 59% courriels (vérification régulière)
- ▶ 25% Facebook (synchronisation)

# Distinction des routines

- ▶ 59% courriels (vérification régulière)
- ▶ 25% Facebook (synchronisation)
- ▶ 9% Yahoo (météo)

# Distinction des routines

- ▶ 59% courriels (vérification régulière)
- ▶ 25% Facebook (synchronisation)
- ▶ 9% Yahoo (météo)
- ▶ 7% Google (cadre de travail Android)

# Distinction des routines

- ▶ 59% courriels (vérification régulière)
- ▶ 25% Facebook (synchronisation)
- ▶ 9% Yahoo (météo)
- ▶ 7% Google (cadre de travail Android)

Potentiellement 100% de routines

**Un résultat peut en cacher  
un autre**

- ▶ Il n'y a pas plus régulier qu'une machine




- ▶ Il n'y a pas plus régulier qu'une machine
- ▶ Modèle condamné à **détecter les routines**

- ▶ Il n'y a pas plus régulier qu'une machine
- ▶ Modèle condamné à **détecter les routines**
- ▶ Reprise du jeu de données

- ▶ Il n'y a pas plus régulier qu'une machine
- ▶ Modèle condamné à **détecter les routines**
- ▶ Reprise du jeu de données
- ▶ Différenciation des flux détectés par les modèles

# Résultats inattendus



# Conclusion

- ▶ **Exportateur de NetFlows pour Android** fonctionnel

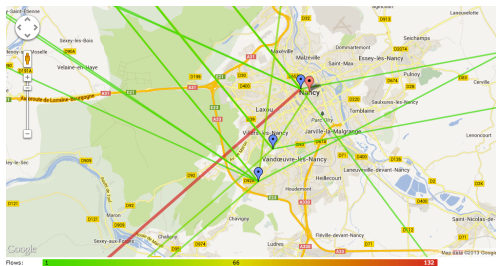
- ▶ **Exportateur de NetFlows pour Android** fonctionnel
- ▶ **Modulaire et scalable**

- ▶ **Exportateur de NetFlows pour Android** fonctionnel
- ▶ **Modulaire et scalable**
- ▶ Entièrement **libre**



- ▶ **Exportateur de NetFlows pour Android** fonctionnel
- ▶ **Modulaire et scalable**
- ▶ Entièrement **libre**
- ▶ Bibliothèque disponible pour **encourager la diversité**

# Ingénierie



- ▶ **Première expérience** très instructive

- ▶ **Première expérience** très instructive
- ▶ Écriture d'un **papier de recherche**

- ▶ **Première expérience** très instructive
- ▶ Écriture d'un **papier de recherche**
- ▶ **Résultats inattendus mais prometteurs**

- ▶ **Première expérience** très instructive
- ▶ Écriture d'un **papier de recherche**
- ▶ **Résultats inattendus mais prometteurs**
- ▶ Et plus intéressants en terme de recherche

- ▶ **Confirmer** les résultats (expérience)

- ▶ **Confirmer** les résultats (expérience)
- ▶ **Affiner** le modèle en vue des nouveaux objectifs



- ▶ **Confirmer** les résultats (expérience)
- ▶ **Affiner** le modèle en vue des nouveaux objectifs
- ▶ **Adapter** le papier de recherche

- ▶ **Confirmer** les résultats (expérience)
- ▶ **Affiner** le modèle en vue des nouveaux objectifs
- ▶ **Adapter** le papier de recherche

Doctorat dans l'équipe MAIA  
(en collaboration avec EDF R&D et Madynes)

# Questions