

# FUSION STATISTIQUE DE DONNÉES D'ENQUÊTES

DERNIÈRES AVANCÉES POUR LES MESURES D'AUDIENCE

Lorie Dudoignon  
Lyon, 25 novembre 2018

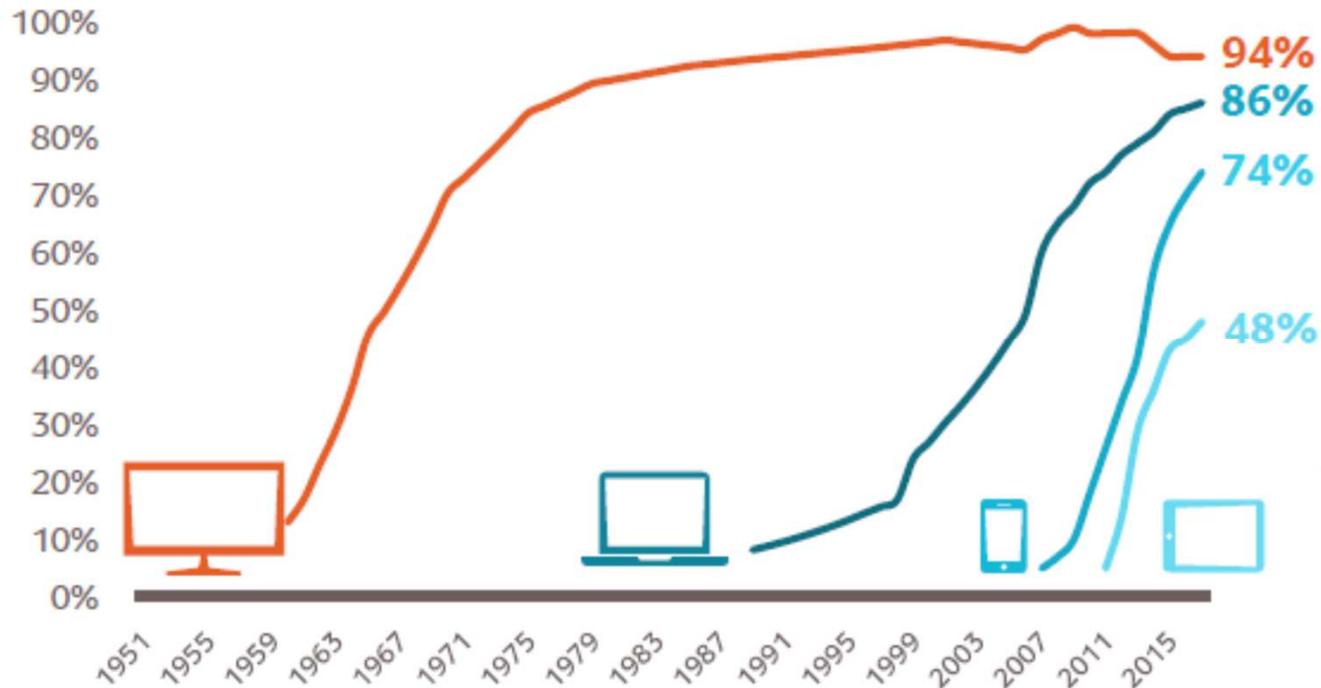


Mediametrie

- **Contexte**
- **Etats des lieux**
- **Internet Global 1<sup>ère</sup> Génération**
- **Internet Global 2<sup>ème</sup> Génération**



## Accélération de l'adoption de nouvelles technologies



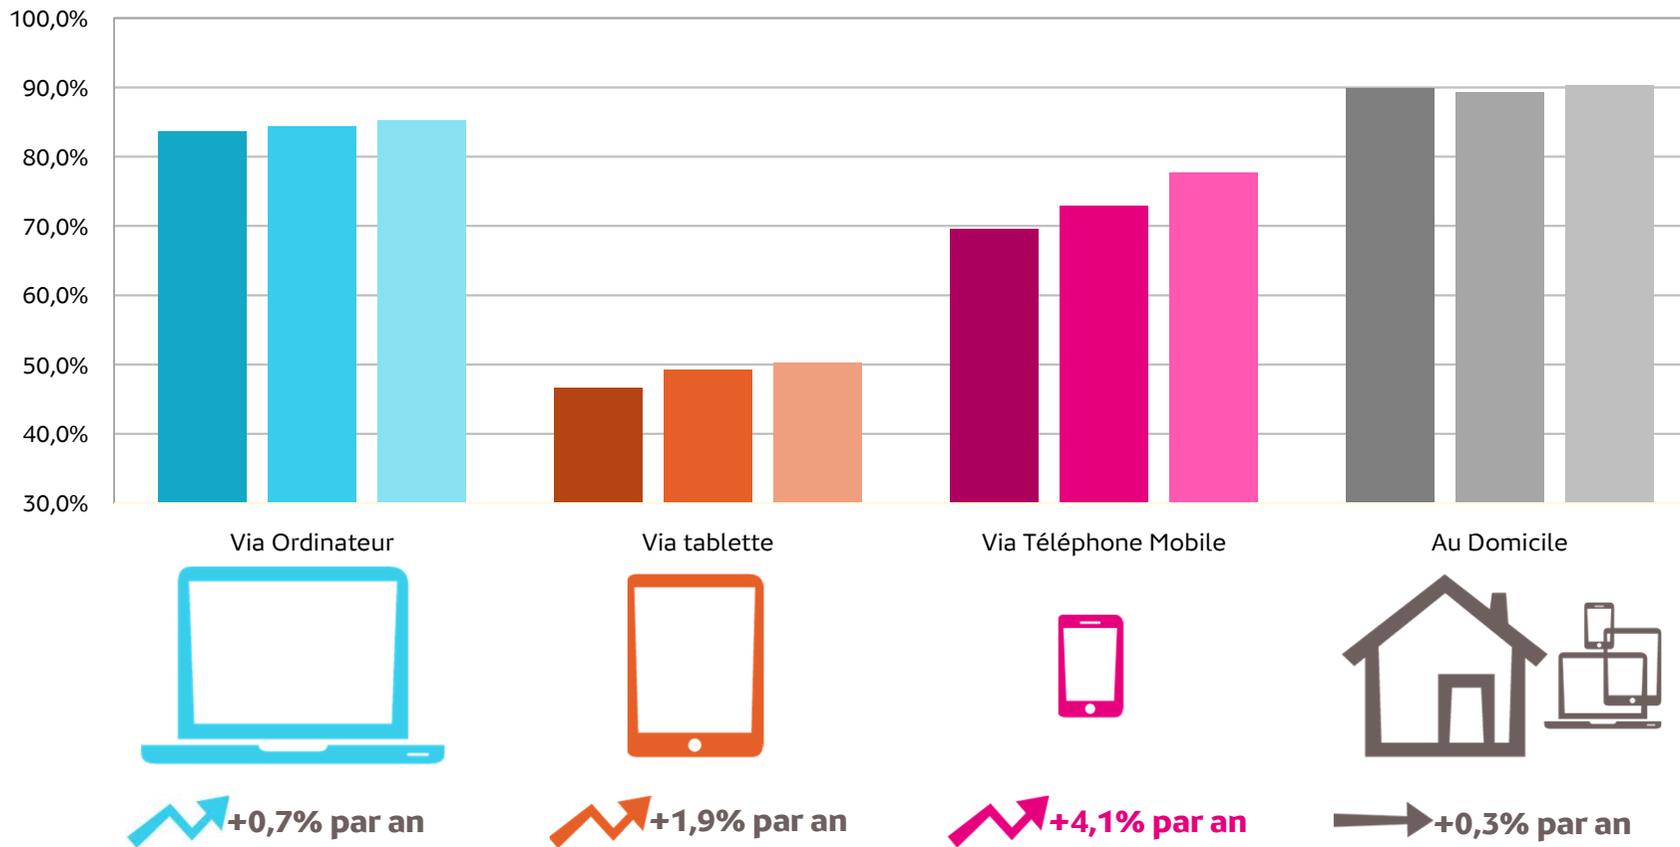
- En moins de 10 ans plus de 70% des foyers français possèdent au moins un smartphone
- Plus de 40 ans pour atteindre un tel niveau d'équipement pour la télévision

# Multiplication des accès Internet



## Accès Internet - Individus 11+

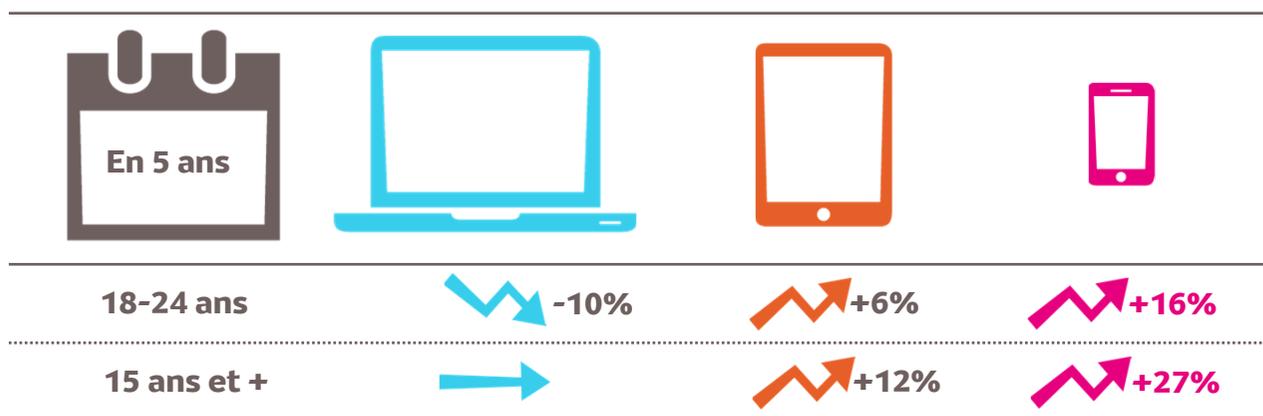
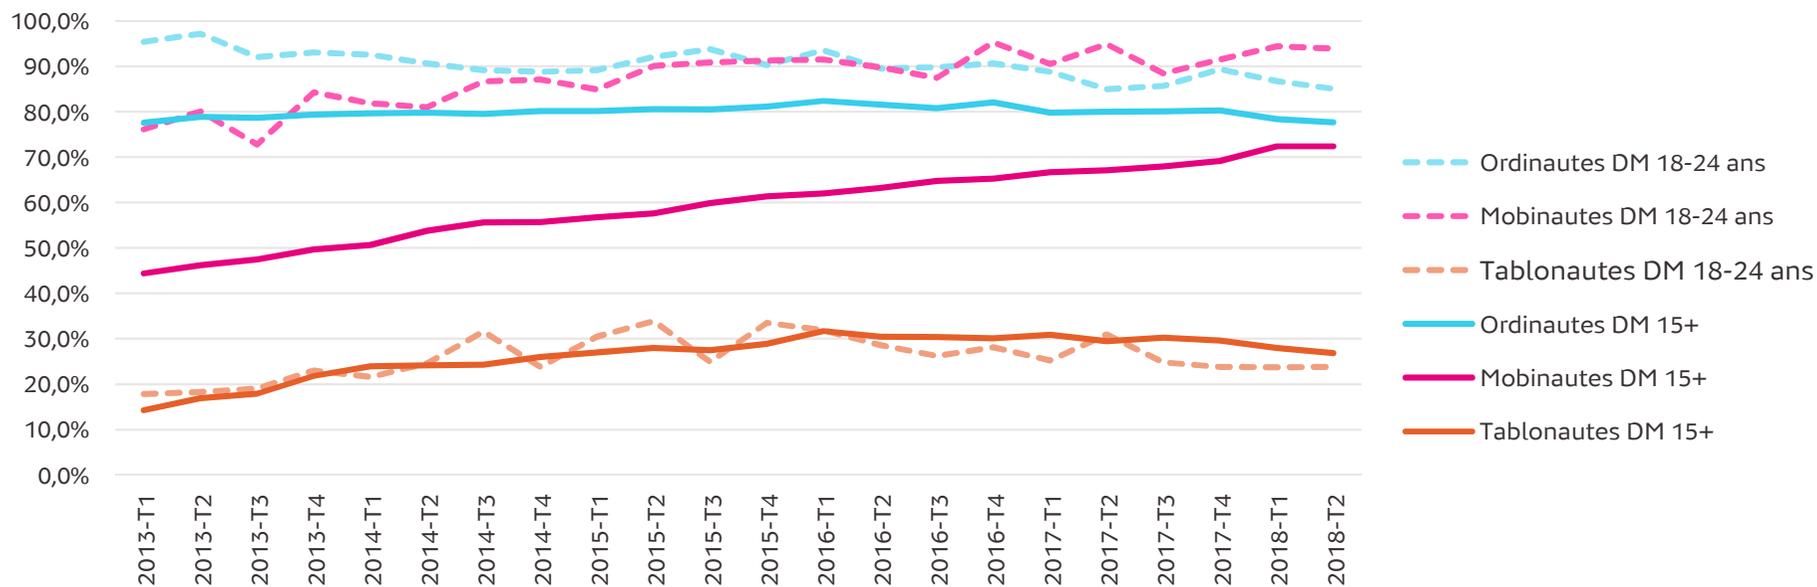
■ Janvier-Mars 2016 ■ Janvier-Mars 2017 ■ Janvier-Mars 2018



# Multiplication des accès Internet



## Internautes Dernier Mois



## Les mesures d'audiences Internet



Mesure Ordinateur



Mesure Mobile



Mesure Tablette



## Les mesures d'audiences Internet



### Mesure Ordinateur



Panel  
18.000 individus

- Panel Mediametrie//Netratings
- Mesure 2+ :
  - Grappage foyer
  - Meter Netsight de Nielsen + Déclaration

## Les mesures d'audiences Internet



### Mesure Mobile



Panel  
10.000 individus

- Panel Mediametrie
  - Naissance en 2010 : Logs opérateurs
  - 2016 : Meter Reality Mine
- Mesure 11+
  - Individu

## Les mesures d'audiences Internet



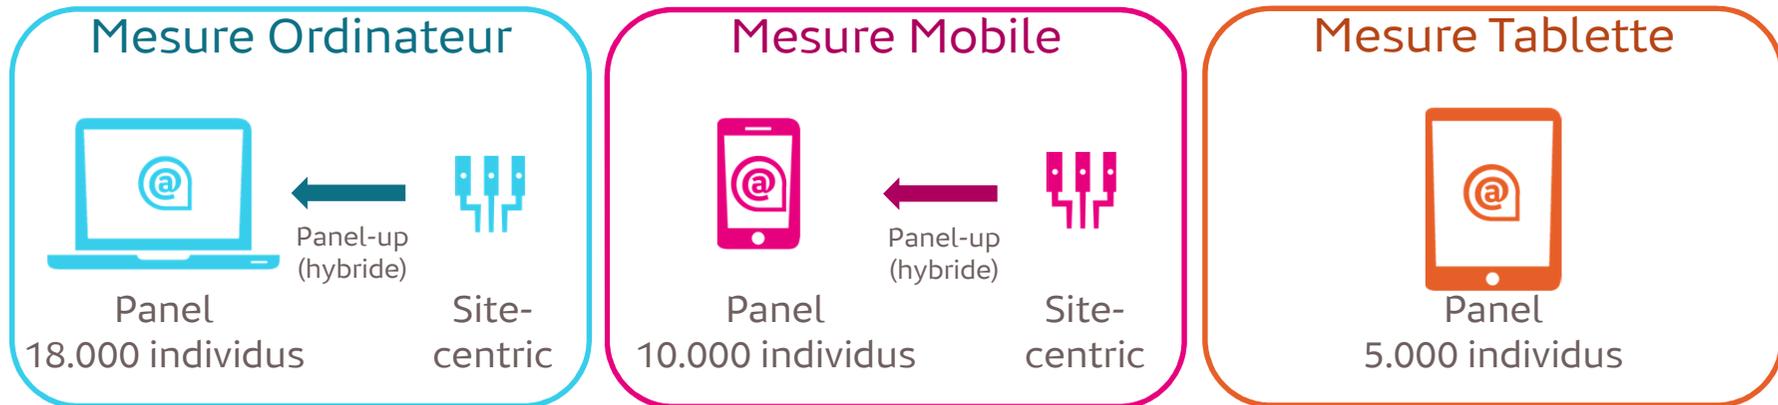
### Mesure Tablette



Panel  
5.000 individus

- Panel Mediametrie
  - Naissance en 2012 
  - 2014 
- Mesure 2+
  - Grappage foyer
  - Mesure Proxy + Appli de déclaration

## Les mesures d'audiences Internet

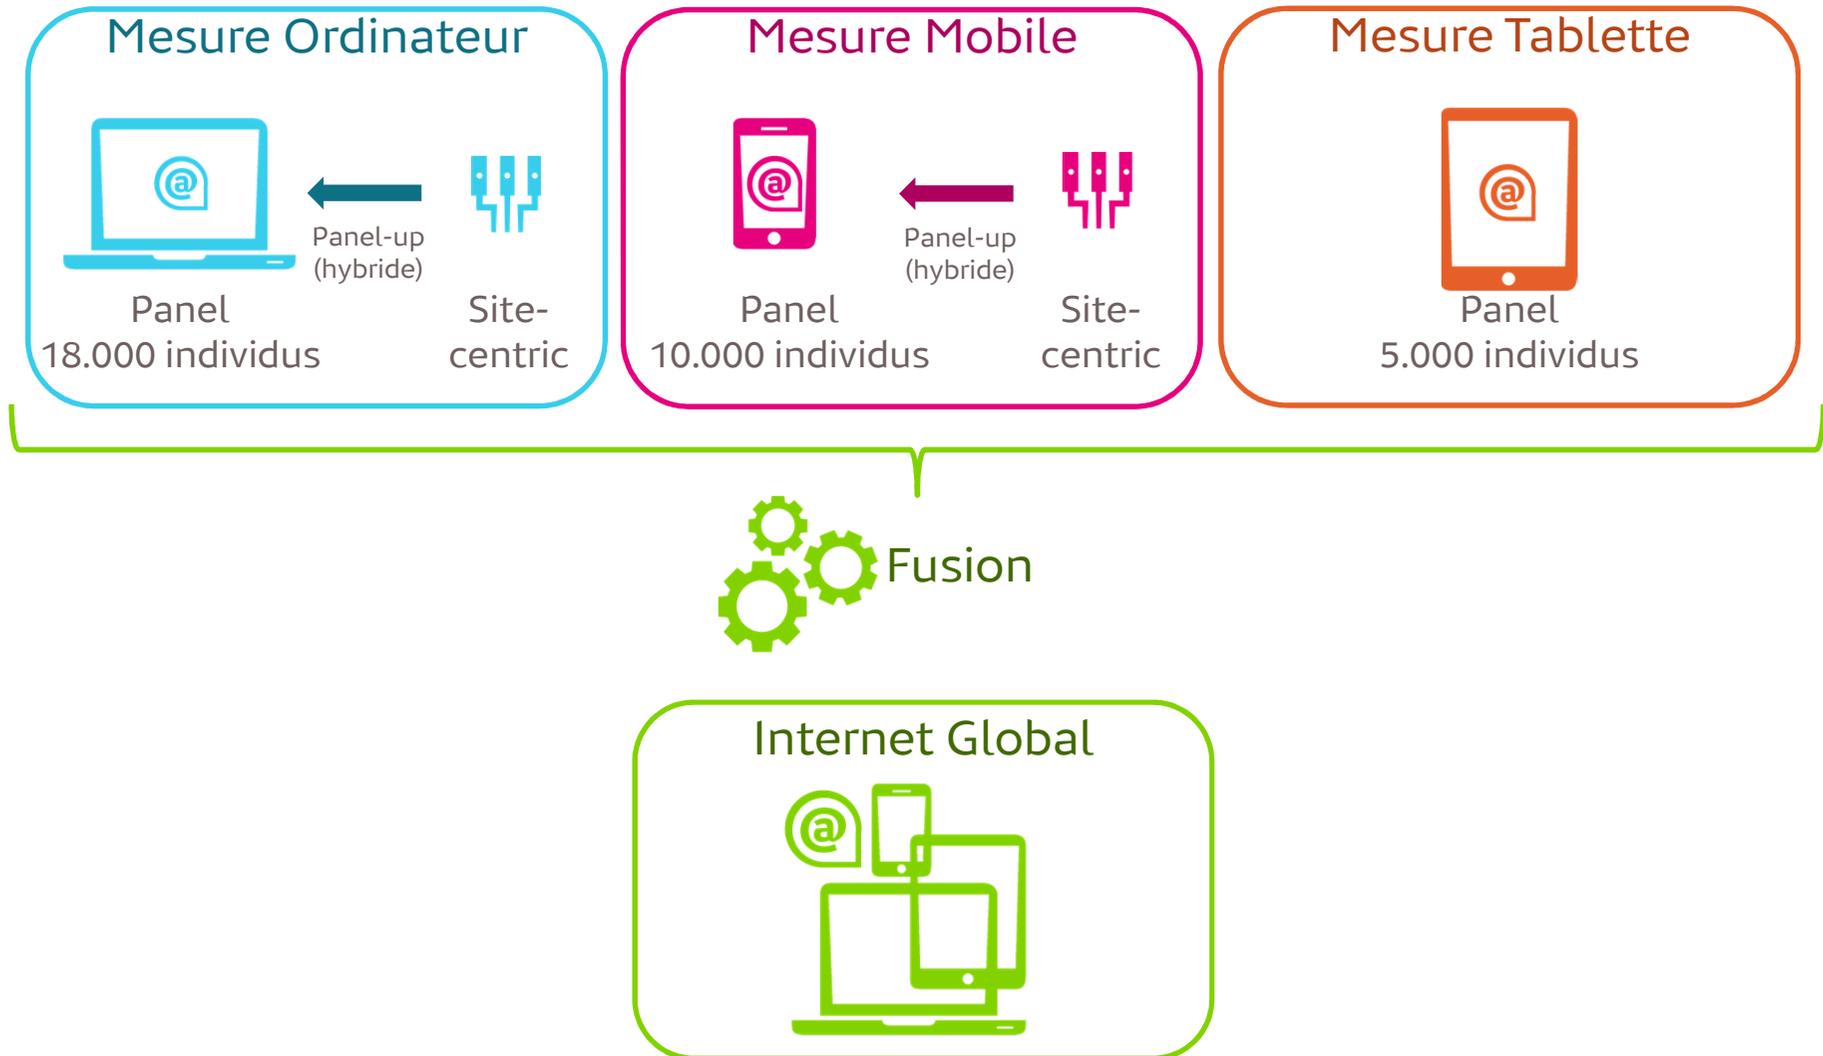


- Site-Centric
  - Marqueur Site / Appli
  - → Nombre de visites
- Hybridation Panel-up
  - Site-Centric = Information auxiliaire
  - Calage du nombre de visites

**Références:**

Dudoignon, L. & Zydorczak, L. *Enquête et données exhaustives : un nouveau défi pour les mesures d'audience*, Colloque Francophone sur les Sondages, Rennes, 2012.

# Internet Global



## Approche simple du type donneur - receveur



Base receveuse

Individus	Variables A	Variables B	Variables C
1			
i			?
N			

Base donneuse

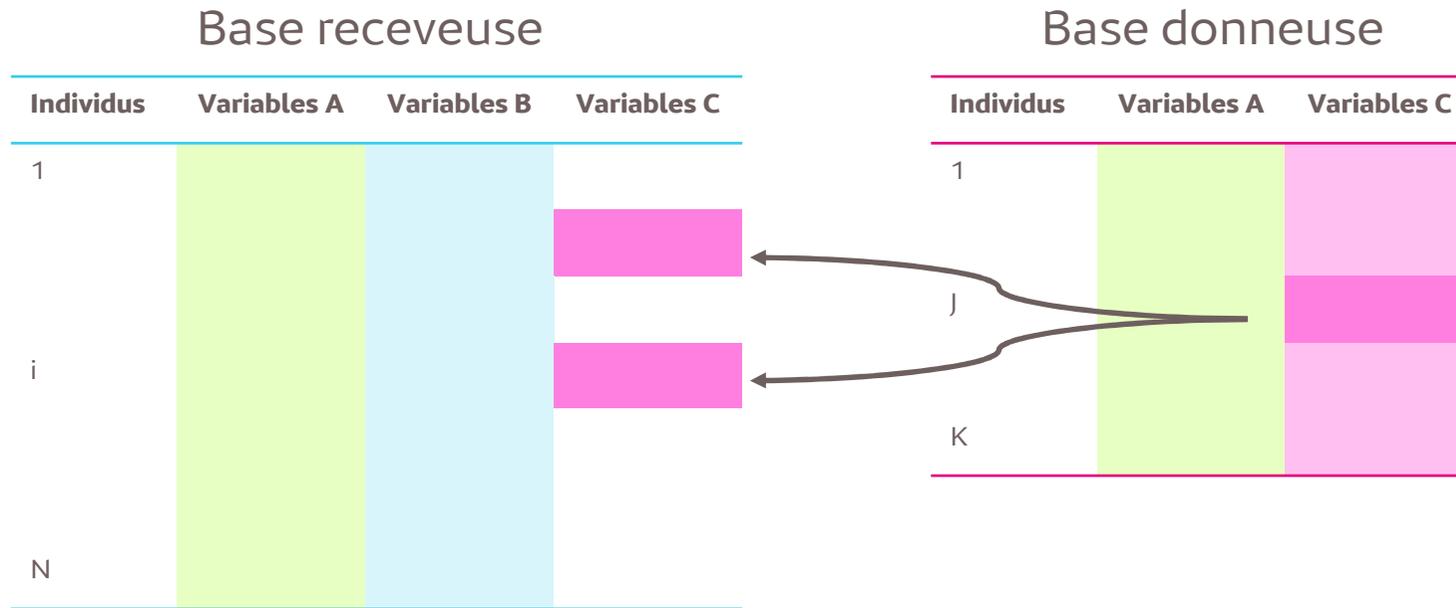
Individus	Variables A	Variables C
1		
J		
K		

- Les variables A sont renseignées dans les 2 bases. → **Variables de pont**
- Les variables B sont spécifiques à la base receveuse.
- Les variables C sont spécifiques à la base donneuse. → **Variables à transférer**

### Références :

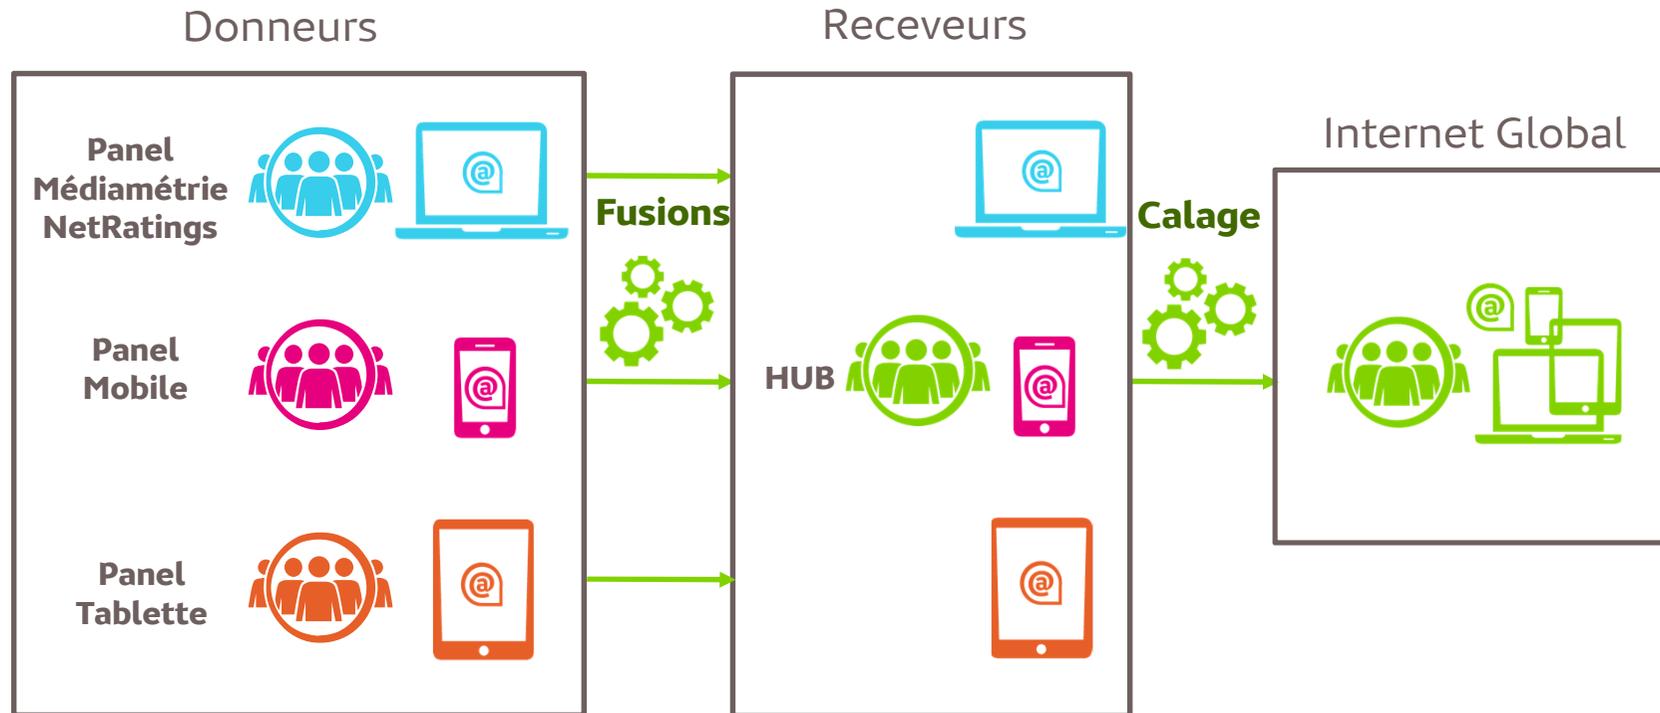
Fisher, N. (2004), *Fusion statistique de fichiers de données*, Thèse de doctorat, Montpellier

## Approche simple du type donneur - receveur



- Pour chaque individu  $i$  receveur :
  - Trouver un donneur  $j$  qui lui « ressemble »
  - Transférer les données de  $j$  à  $i$  (pour les variables C).
- Pour déterminer si deux individus se ressemblent, toutes les variables communes A peuvent être utilisées
- Un même donneur peut être utilisé pour plusieurs receveurs.

## 3 fusions + 1 hub



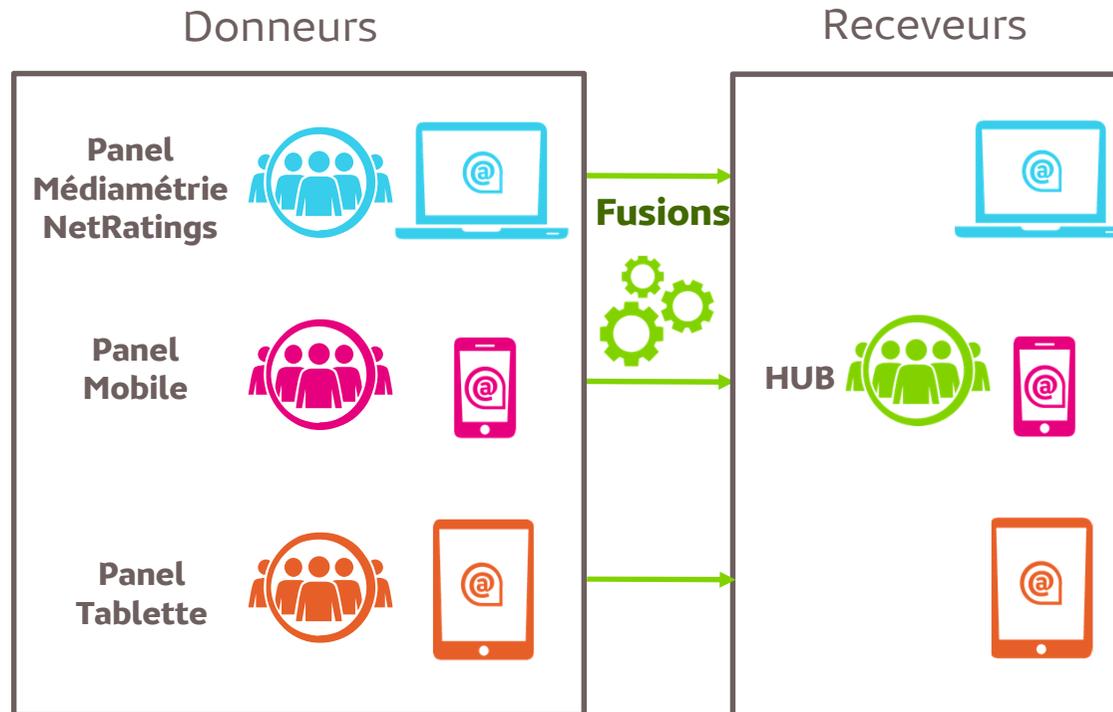
- HUB

- 10.000 interviews / an
- Questionnaire d'Habitude d'Ecoute auto-administré
  - Habitudes par écran au global
  - Habitudes par écran x sites





## 3 fusions + 1 hub

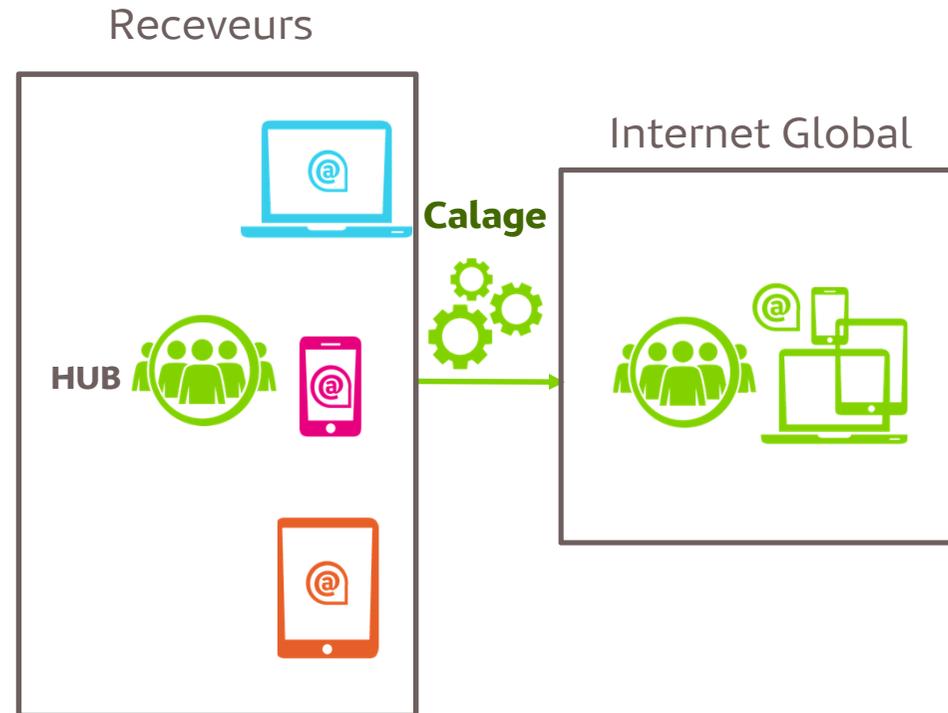


### Fusions



- Approche Donneur → Receveur
  - Contrainte sur le nombre de répliation d'un même donneur
- « Distance scorée » sur les habitudes d'écoute
  - $\text{Score}(\text{Visiteur}, \text{Visiteur}) > \text{Score}(\text{Non visiteur}, \text{Non visiteur})$

## 3 fusions + 1 hub



### Calage

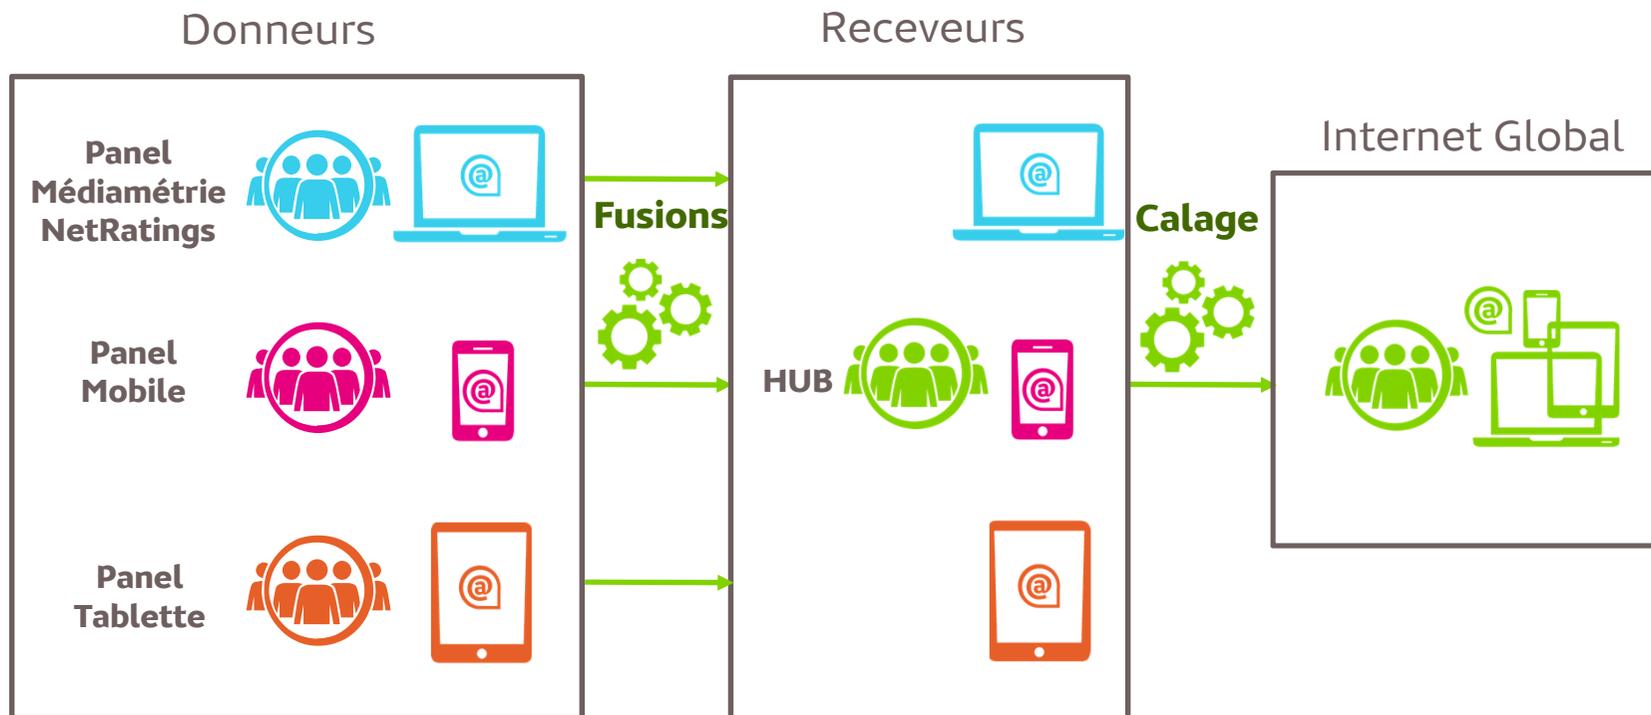


- Redressement Ridge
  - Tolérance sur les marges issues des enquêtes donneuses

### Références:

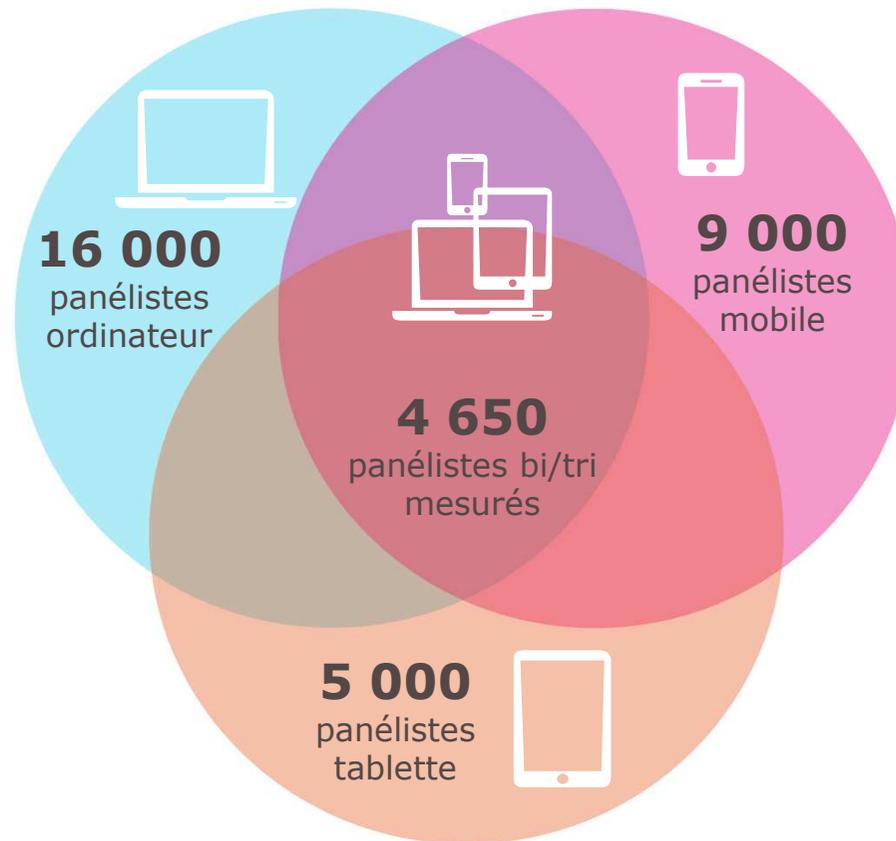
Beaumont, J.-F. and Bocci, C. (2008), Another look at ridge calibration, *Metron-International Journal of Statistics*, LXVI, 5–20.

### 3 fusions + 1 hub



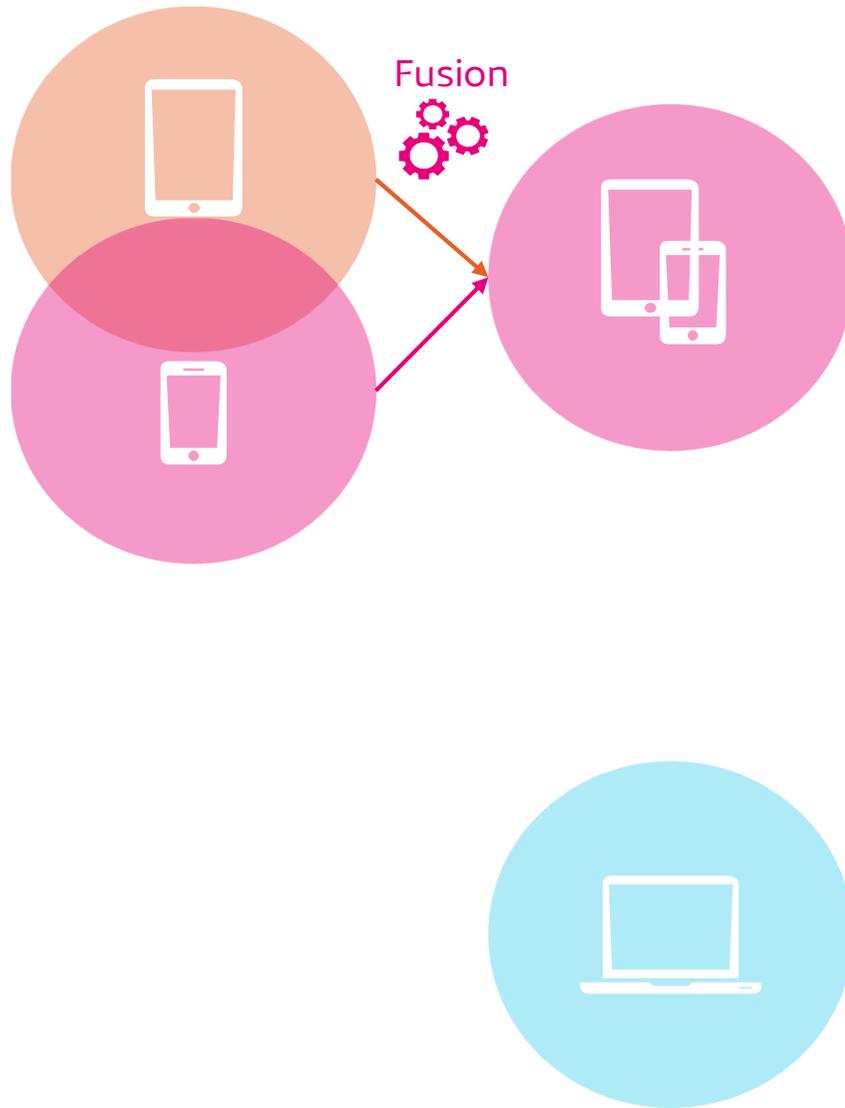
- **Résultats par écran ≠ Etude de référence**
- **HUB mis à jour 2 fois par an**

## Une panélisation « à la carte »

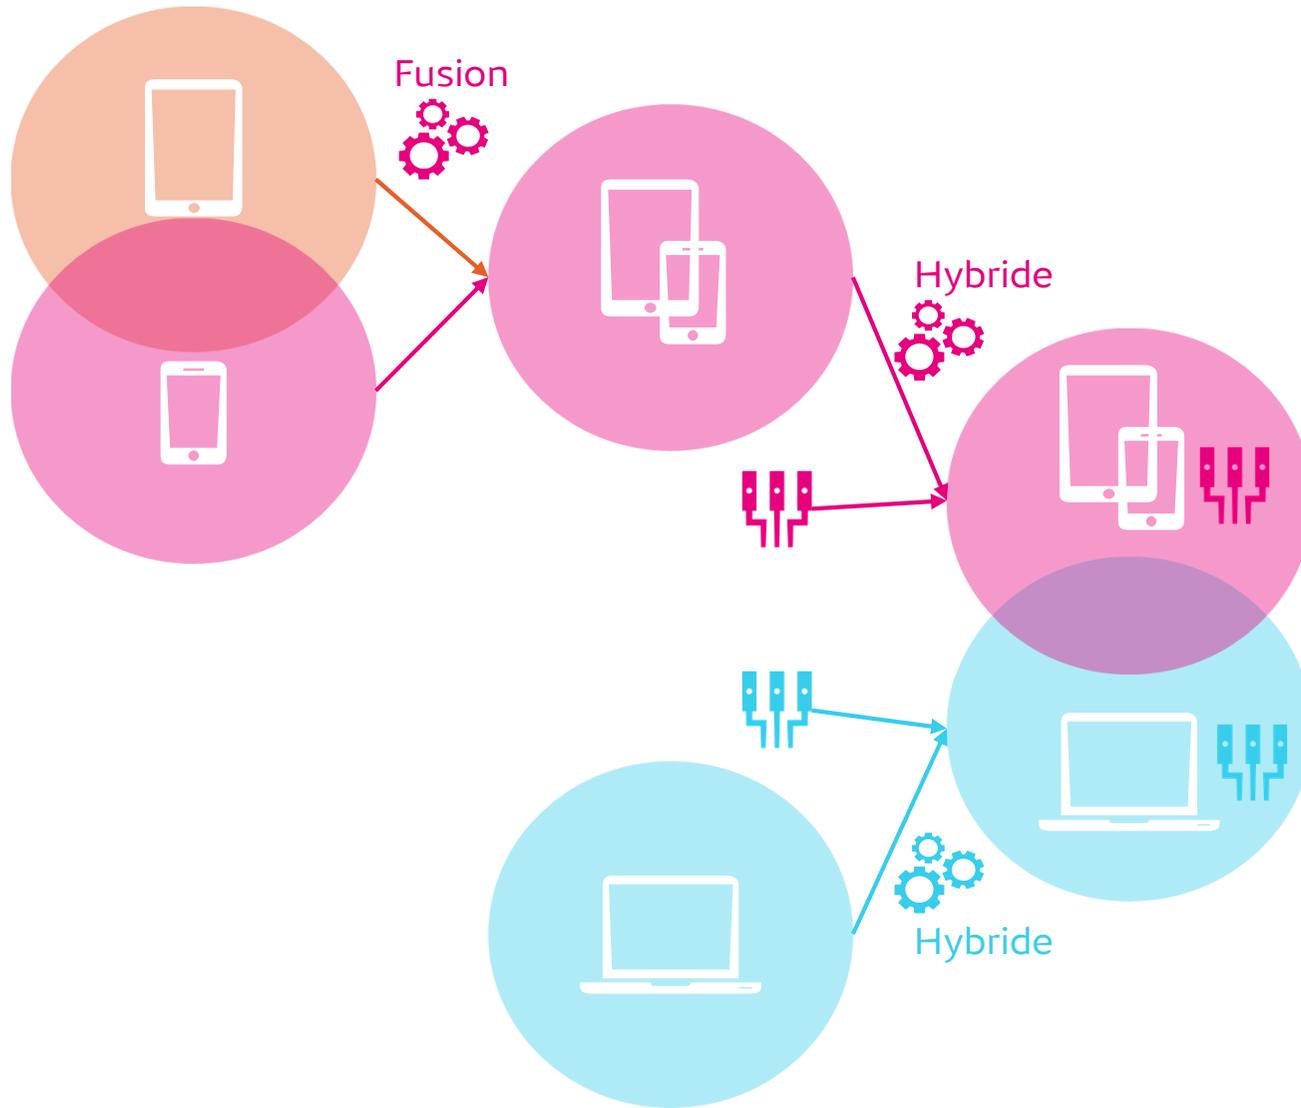


**Objectifs fin 2018**

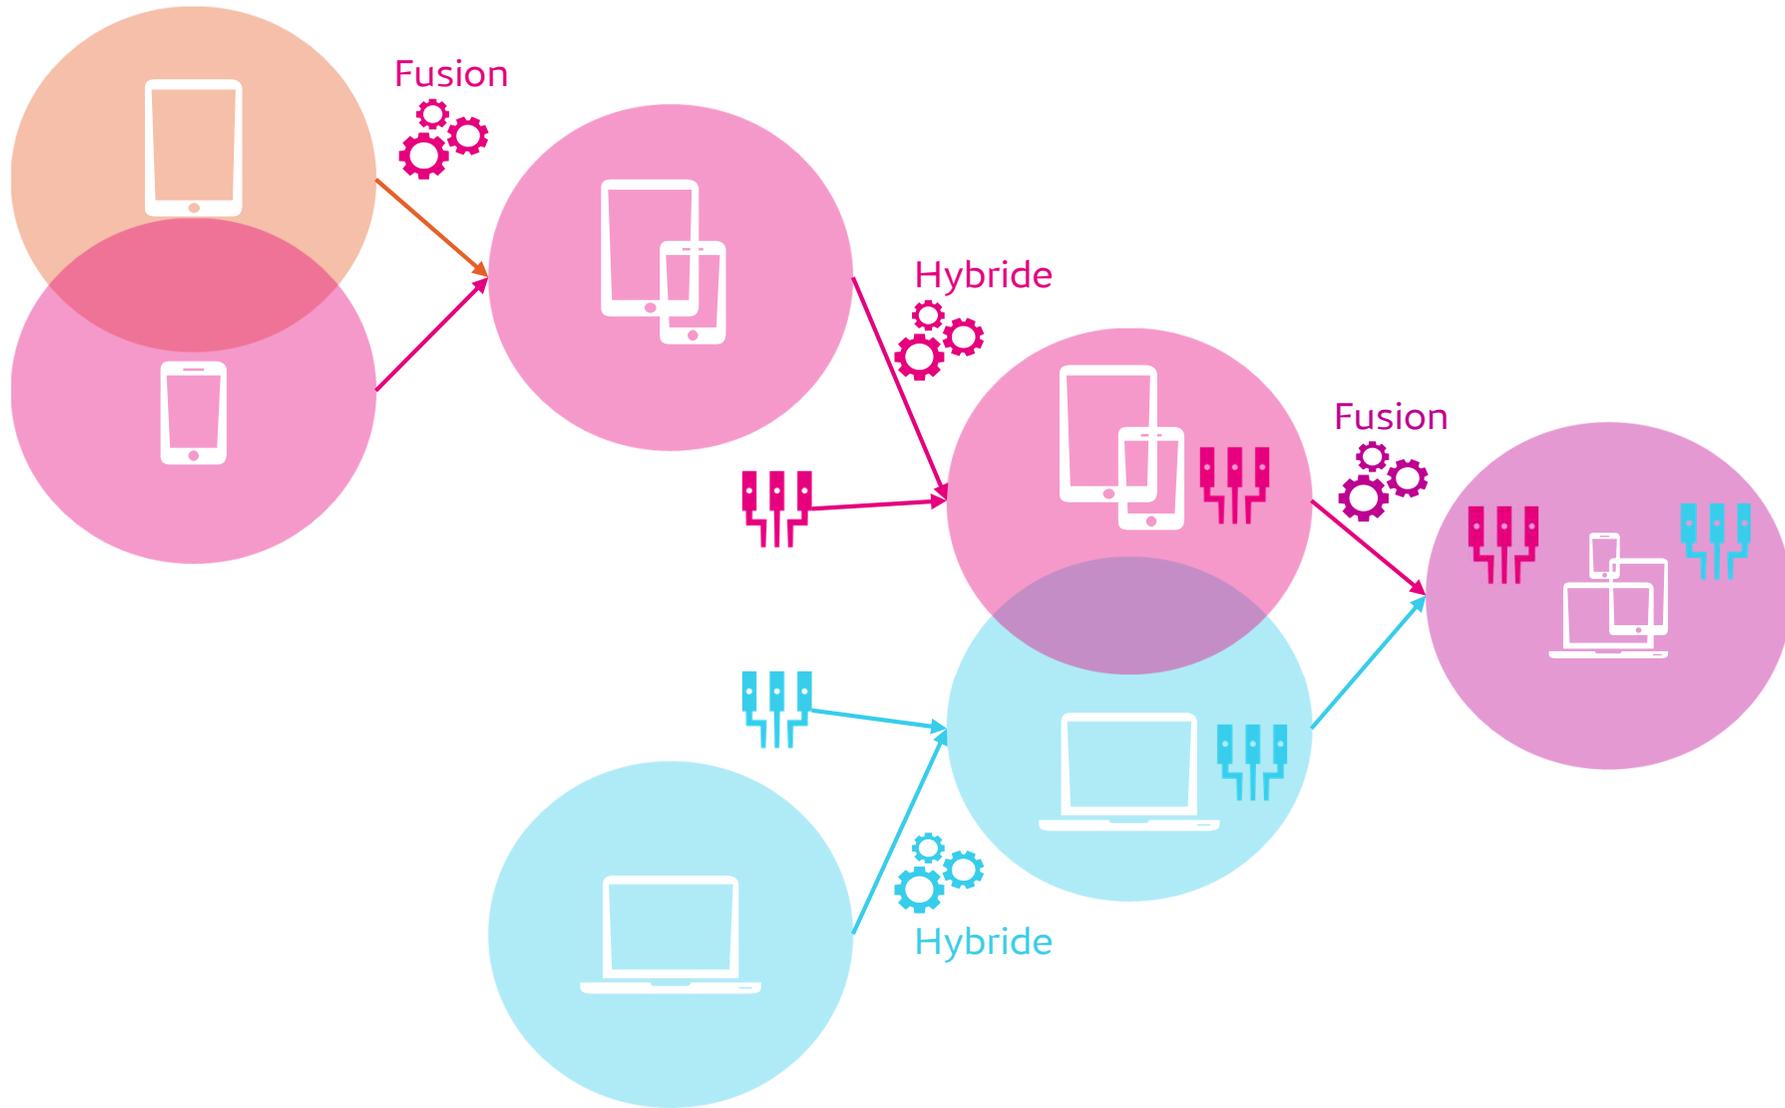
## Mise en œuvre



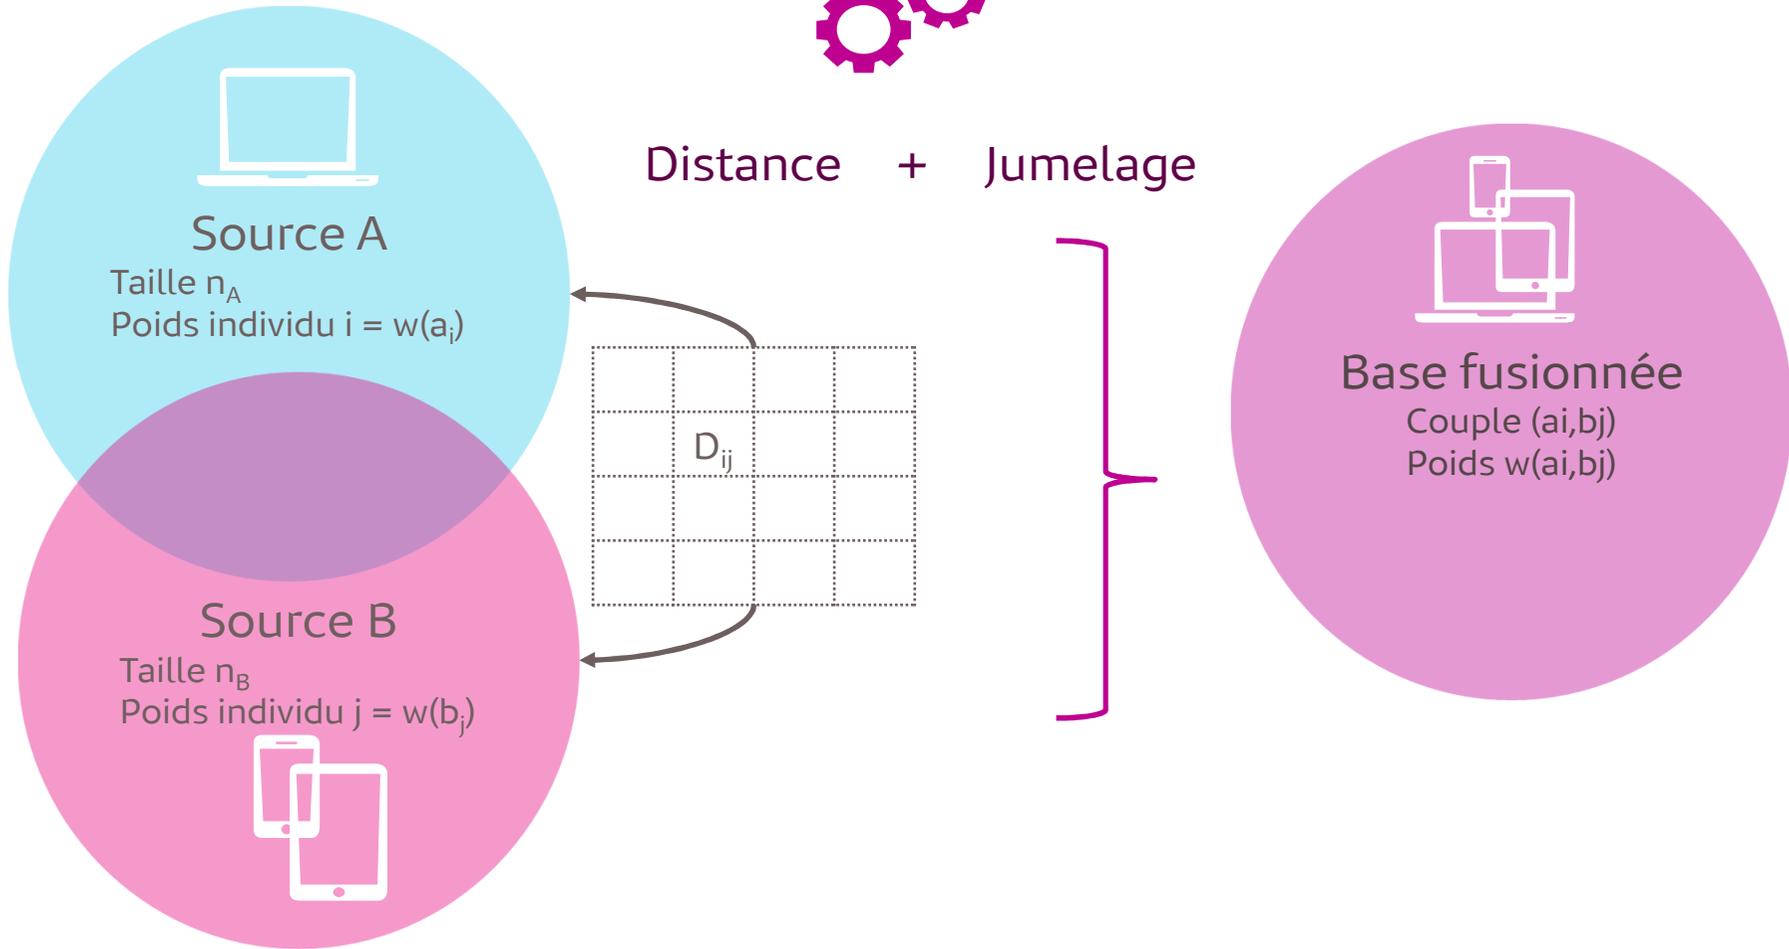
# Mise en œuvre



# Mise en œuvre



# Fusion = Distance + Jumelage





## Jumelage sous contraintes

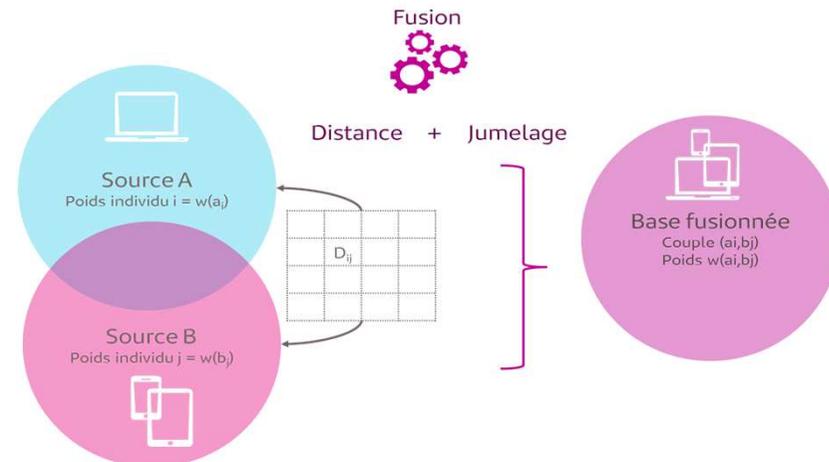
### Objectifs :

- Conserver les résultats des 2 sources
- Conserver le « bénéfice » de l'hybridation  
→ **Conserver les poids**

- Minimiser le coût du jumelage
  - $Z = \sum_{i=1}^{n_A} \sum_{j=1}^{n_B} D_{ij} \times w(a_i, b_j)$
- Sous les contraintes de conservation des poids

- $\sum_{i=1}^{n_A} w(a_i, b_j) = w(b_j)$

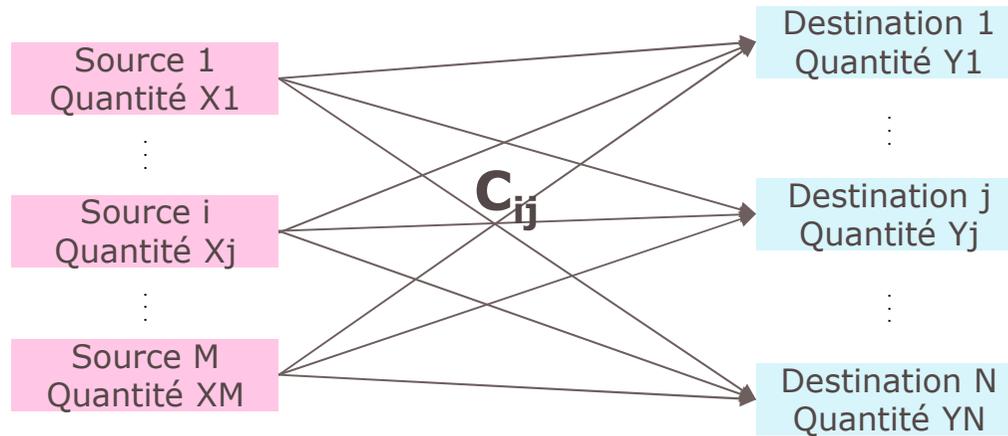
- $\sum_{j=1}^{n_B} w(a_i, b_j) = w(a_i)$



## Jumelage sous contraintes



### Un problème de transport !



Hypothèse :  
Offre = Demande

- Minimiser le coût du transport
  - $Z = \sum_{i=1}^{n_A} \sum_{j=1}^{n_B} C_{ij} \times w(a_i, b_j)$
- Sous les contraintes Offres et Demandes
  - $\sum_{i=1}^{n_A} w(a_i, b_j) = w(b_j)$
  - $\sum_{j=1}^{n_B} w(a_i, b_j) = w(a_i)$

→ Nombre de couple  $\leq N + M - 1$

#### Références:

Mansi, S.G. (2011), A Study on Transportation Problem, Transshipment Problem, Assignment Problem and Supply Chain, Thèse de doctorat, Rajkot

## Jumelage sous contraintes



### Un problème de transport !

- Exemple d'algorithme « simple » : Least Cost Method

Coûts	Source 1	Source 2	Source 3	Demande
Destination 1	6	4	1	50
Destination 2	3	8	7	40
Destination 3	4	5	2	60
Offre	50	65	35	

Solution	Source 1	Source 2	Source 3	Reste
Destination 1				50
Destination 2				40
Destination 3				60
Reste	50	65	35	

## Jumelage sous contraintes



### Un problème de transport !

- Exemple d'algorithme « simple » : Least Cost Method

Coûts	Source 1	Source 2	Source 3	Demande
Destination 1	6	4	1	50
Destination 2	3	8	7	40
Destination 3	4	5	2	60
Offre	50	65	35	

Solution	Source 1	Source 2	Source 3	Reste
Destination 1			35	15
Destination 2				40
Destination 3				60
Reste	50	65	0	

## Jumelage sous contraintes



### Un problème de transport !

- Exemple d'algorithme « simple » : Least Cost Method

Coûts	Source 1	Source 2	Source 3	Demande
Destination 1	6	4	1	15
Destination 2	3	8	7	40
Destination 3	4	5	2	60
Offre	50	65	0	

Solution	Source 1	Source 2	Source 3	Reste
Destination 1			35	15
Destination 2	40			0
Destination 3				60
Reste	10	65	0	

## Jumelage sous contraintes



### Un problème de transport !

- Exemple d'algorithme « simple » : Least Cost Method

Coûts	Source 1	Source 2	Source 3	Demande
Destination 1	6	4	1	15
Destination 2	3	8	7	0
Destination 3	4	5	2	60
Offre	10	65	0	

Solution	Source 1	Source 2	Source 3	Reste
Destination 1		15	35	0
Destination 2	40			0
Destination 3				60
Reste	10	50	0	

## Jumelage sous contraintes



### Un problème de transport !

- Exemple d'algorithme « simple » : Least Cost Method

Coûts	Source 1	Source 2	Source 3	Demande
Destination 1	6	4	1	0
Destination 2	3	8	7	0
Destination 3	4	5	2	60
Offre	10	50	0	

Solution	Source 1	Source 2	Source 3	Reste
Destination 1		15	35	0
Destination 2	40			0
Destination 3	10			50
Reste	0	50	0	

## Jumelage sous contraintes



### Un problème de transport !

- Exemple d'algorithme « simple » : Least Cost Method

Coûts	Source 1	Source 2	Source 3	Demande
Destination 1	6	4	1	0
Destination 2	3	8	7	0
Destination 3	4	5	2	50
Offre	0	50	0	

Solution	Source 1	Source 2	Source 3	Reste
Destination 1		15	35	0
Destination 2	40			0
Destination 3	10	50		0
Reste	0	0	0	

## Jumelage sous contraintes



### Un problème de transport !

- MODI (MODified DIstribution method)
  - Une solution initiale non optimale qui respecte les contraintes
  - Pour chaque couple non utilisé
    - Gain potentiel sur le coût total
    - Gain le plus important → Poids max
    - Baisse du poids des autres couples pour équilibrer

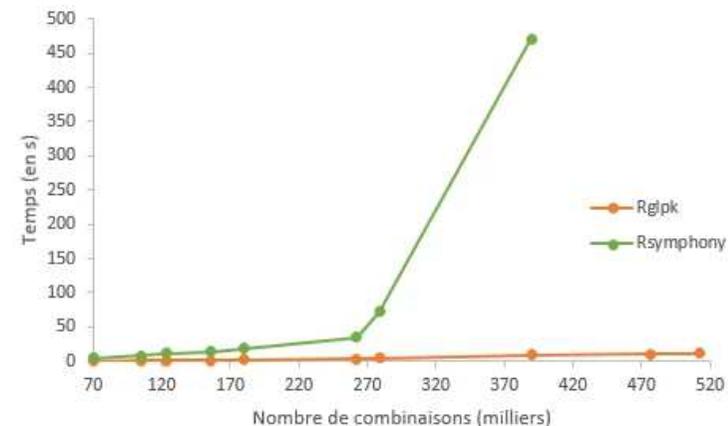
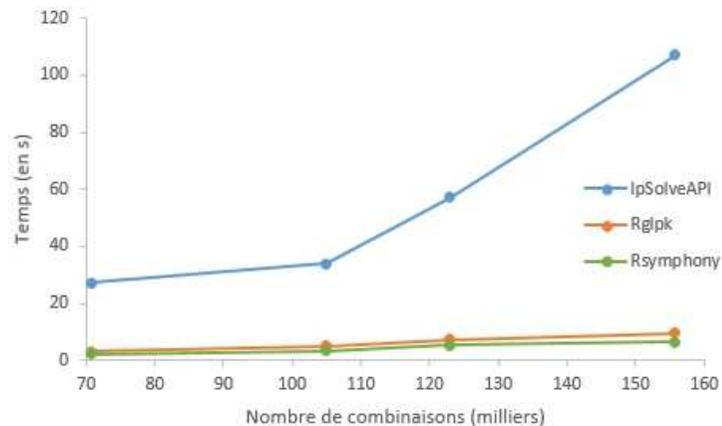


## Jumelage sous contraintes



### Un problème de transport !

- Optimisation linéaire R
  - Contrainte du problème de transport = solutions entières
  - Suppression de cette contrainte → Gain important dans les temps de calcul
  - 3 packages testés : IpSolveAPI, **Rglpk**, Rsymphony

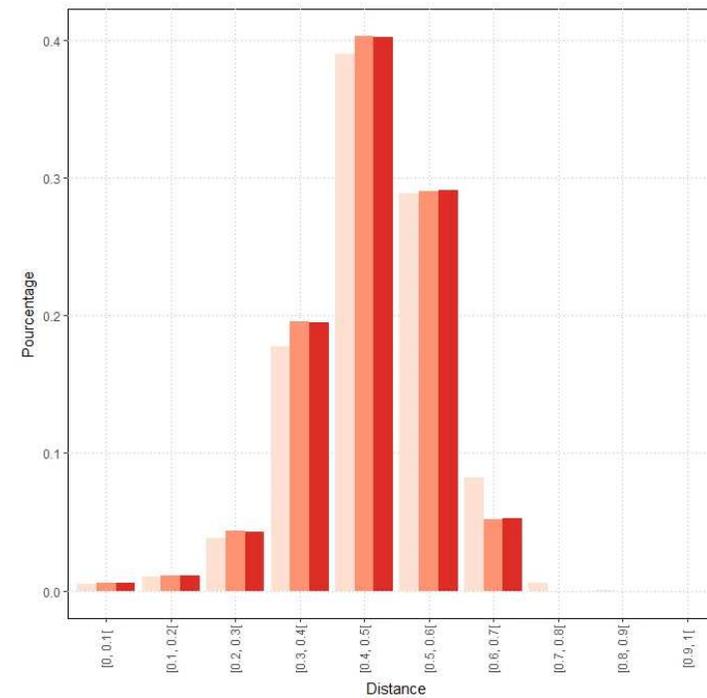
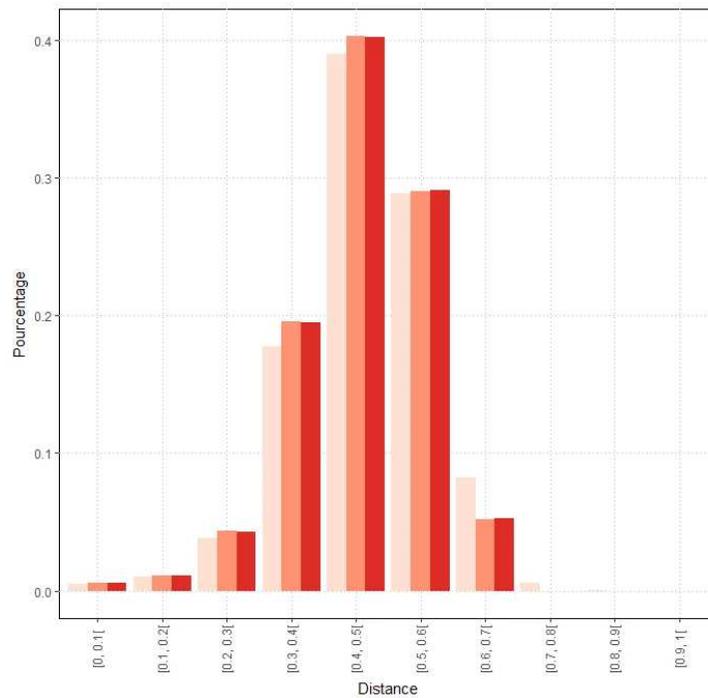
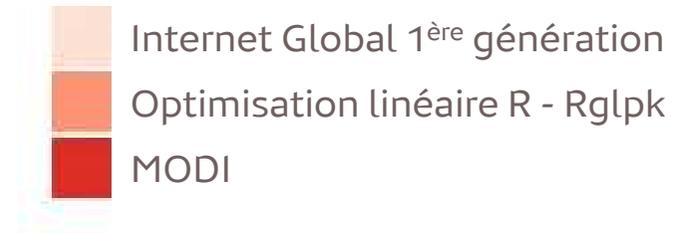


## Jumelage sous contraintes



### Comparaisons des solutions

- Distribution des distances



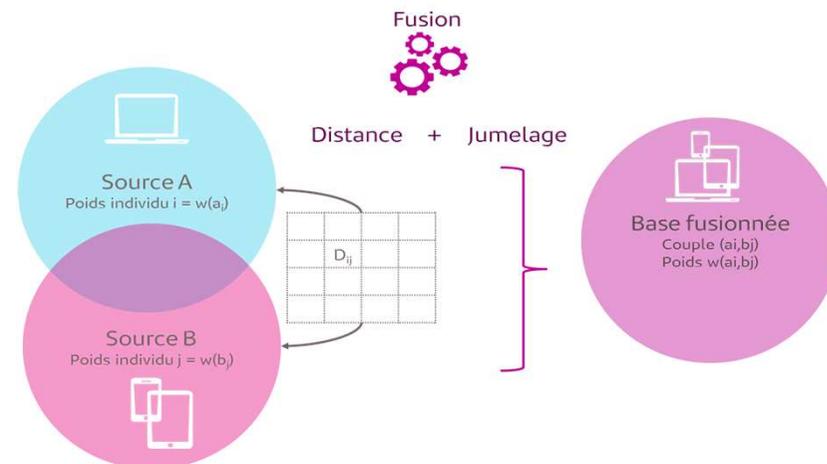
## Distance



### Objectifs :

- Utiliser la partie du panel pour laquelle la mesure est complète

- Transformation procustèenne
  - Rapprocher le + possible 2 nuages
  - En conservant les relations entre les points
- Sur la base des communs
  - Transformations optimales
  - Translation, homothétie, rotation, symétrie



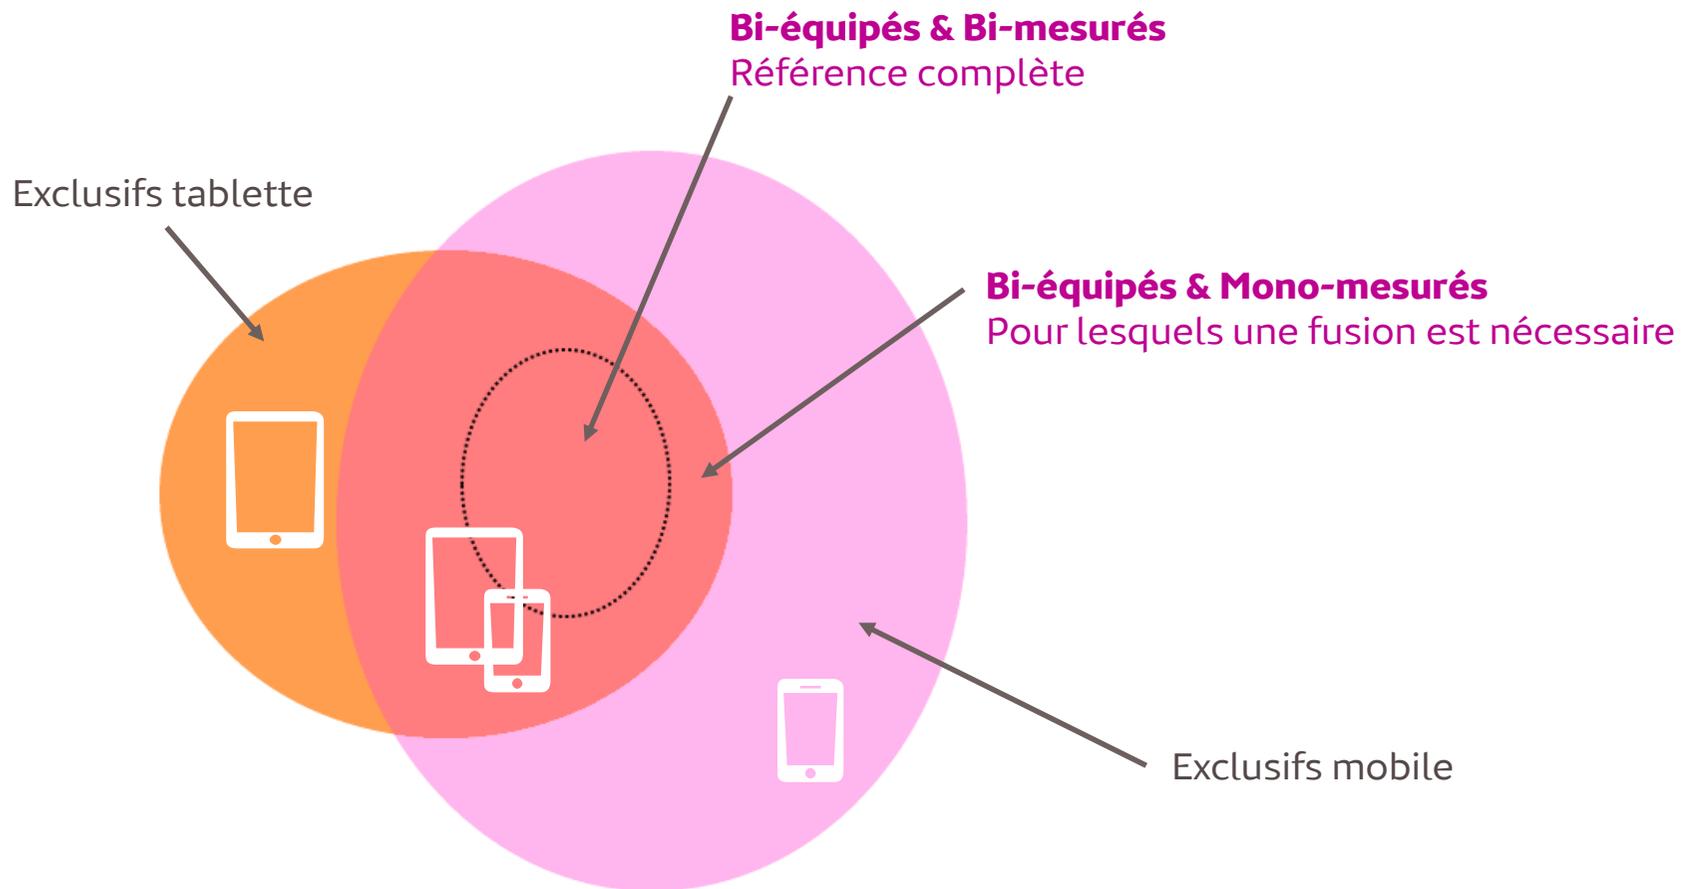
### Références:

Borg I., Groenen P., *Modern Multidimensional Scaling, Theory and Applications*, 2005.



## Distance

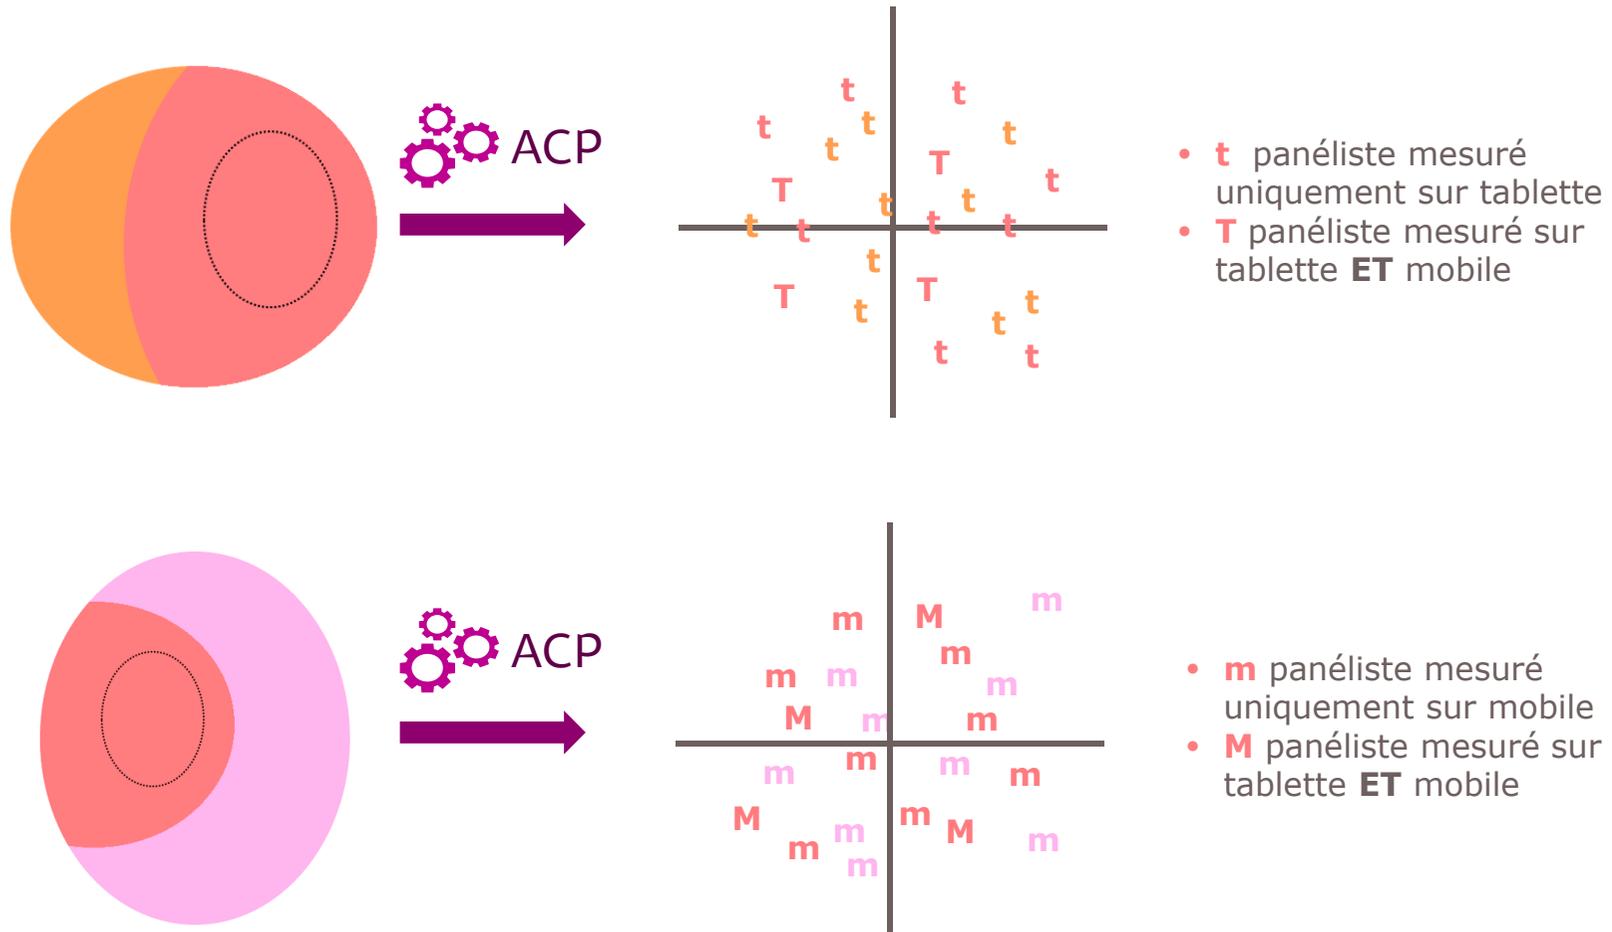
### Illustration sur le panel Mobile - Tablette





## Distance

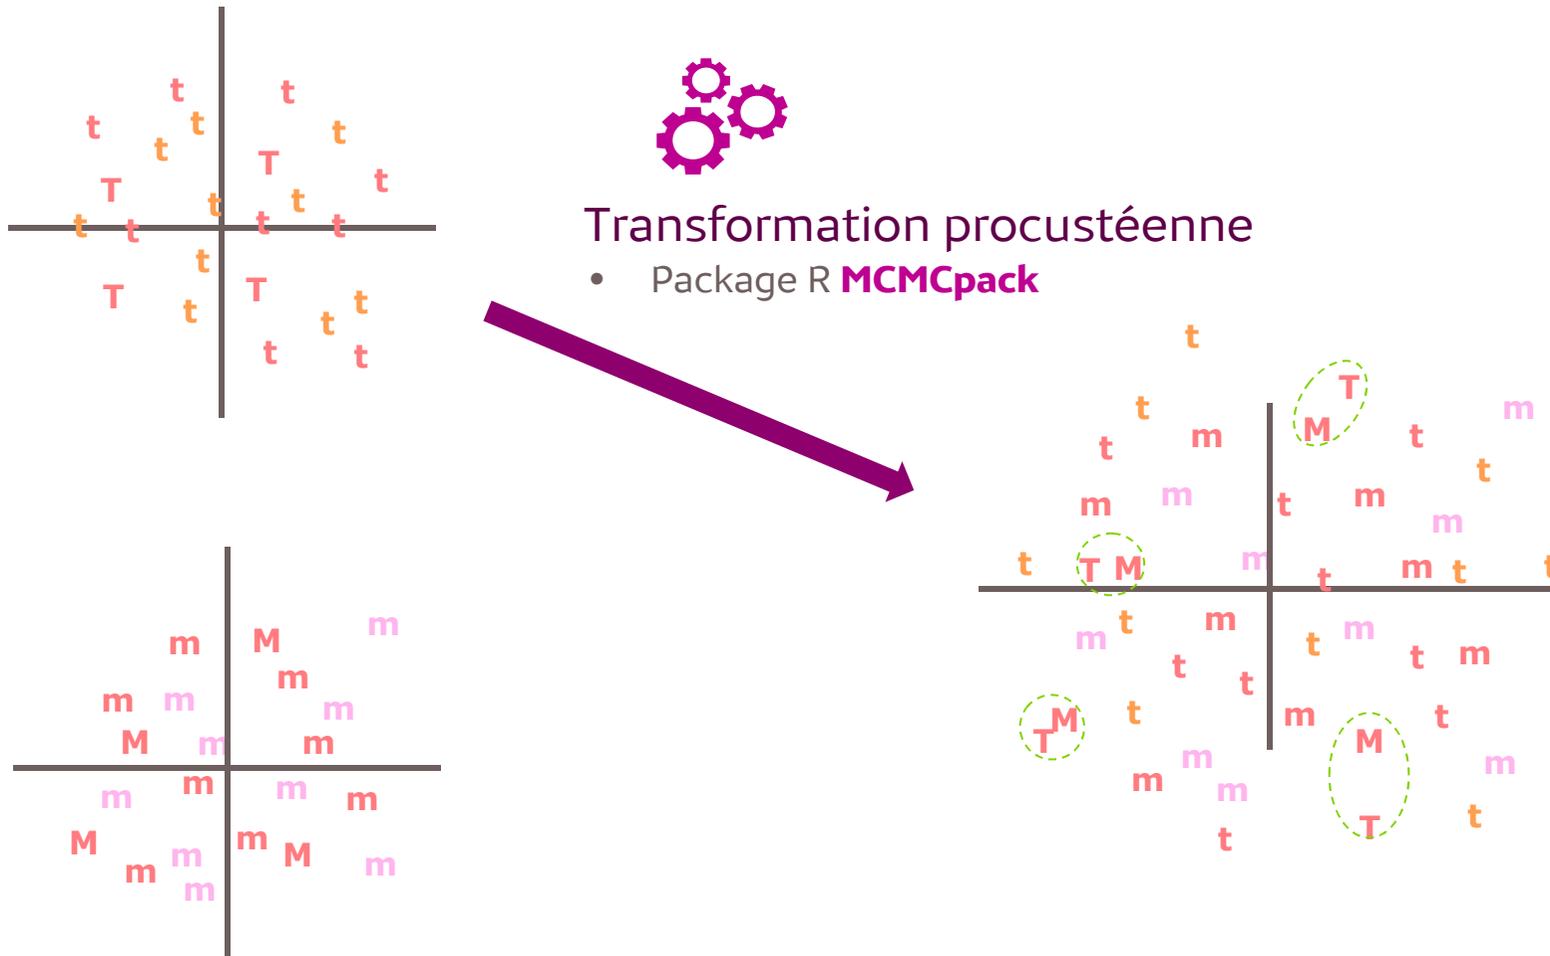
### Illustration sur le panel Mobile - Tablette





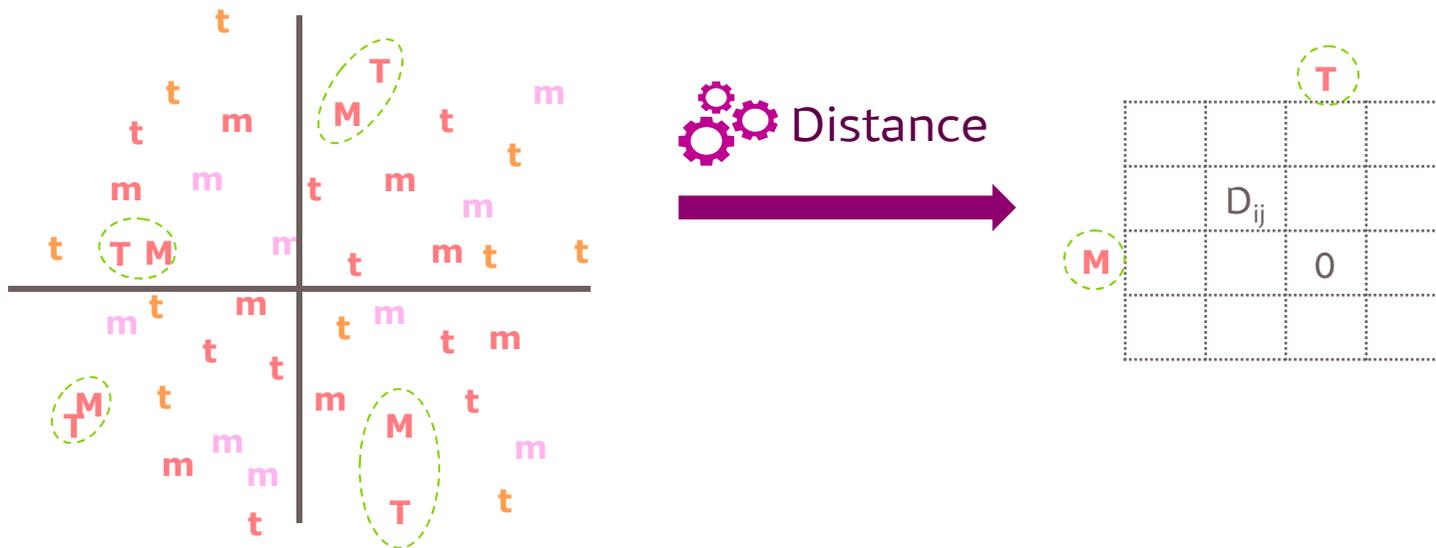
## Distance

### Illustration sur le panel Mobile - Tablette



## Distance

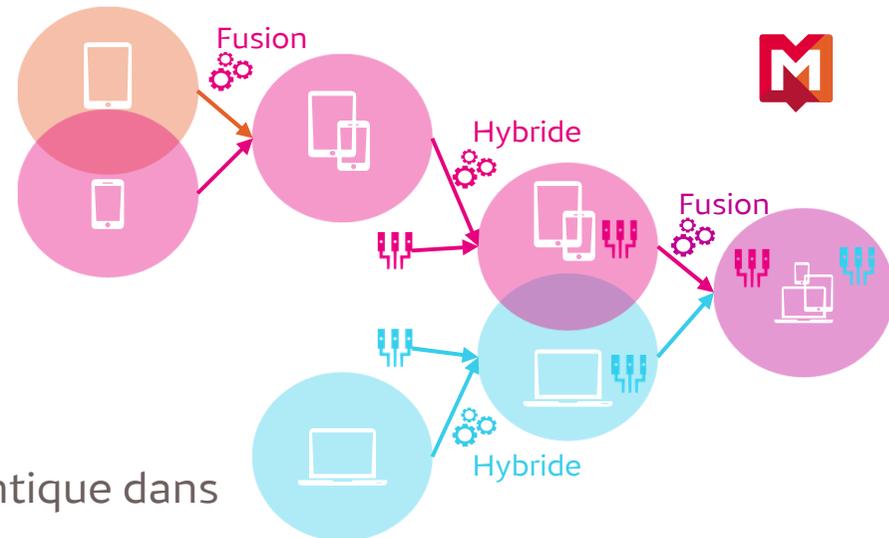
### Illustration sur le panel Mobile - Tablette



## Quelques détails pratiques

### Stratification

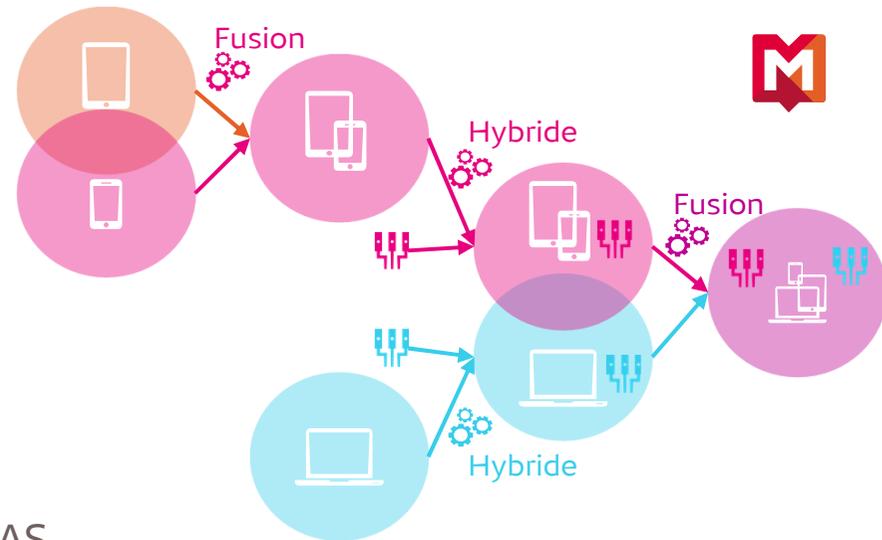
- Le poids d'une même strate doit être identique dans les 2 sources avant fusion
- En particulier sur l'équipement :
  - Le poids des bi-équipés ordinateur-mobile doit être le même au sein du panel ordinateur et du panel mobilité
- Pour les étapes de fusion, le traitement des strates peut être parallélisé



## Quelques détails pratiques

### R sur le serveur SAS

- Utilisation de package R pour les fusions
- Chaînes de traitement historiques sous SAS
- Exécution du code R via la PROC IML de SAS





**Merci pour votre attention**

