

# Modèles d'interrogation sur les flux de données issues de capteurs

**Loïc Petit**

LIG Sigma - Orange Labs  
[Loic.Petit@imag.fr](mailto:Loic.Petit@imag.fr)

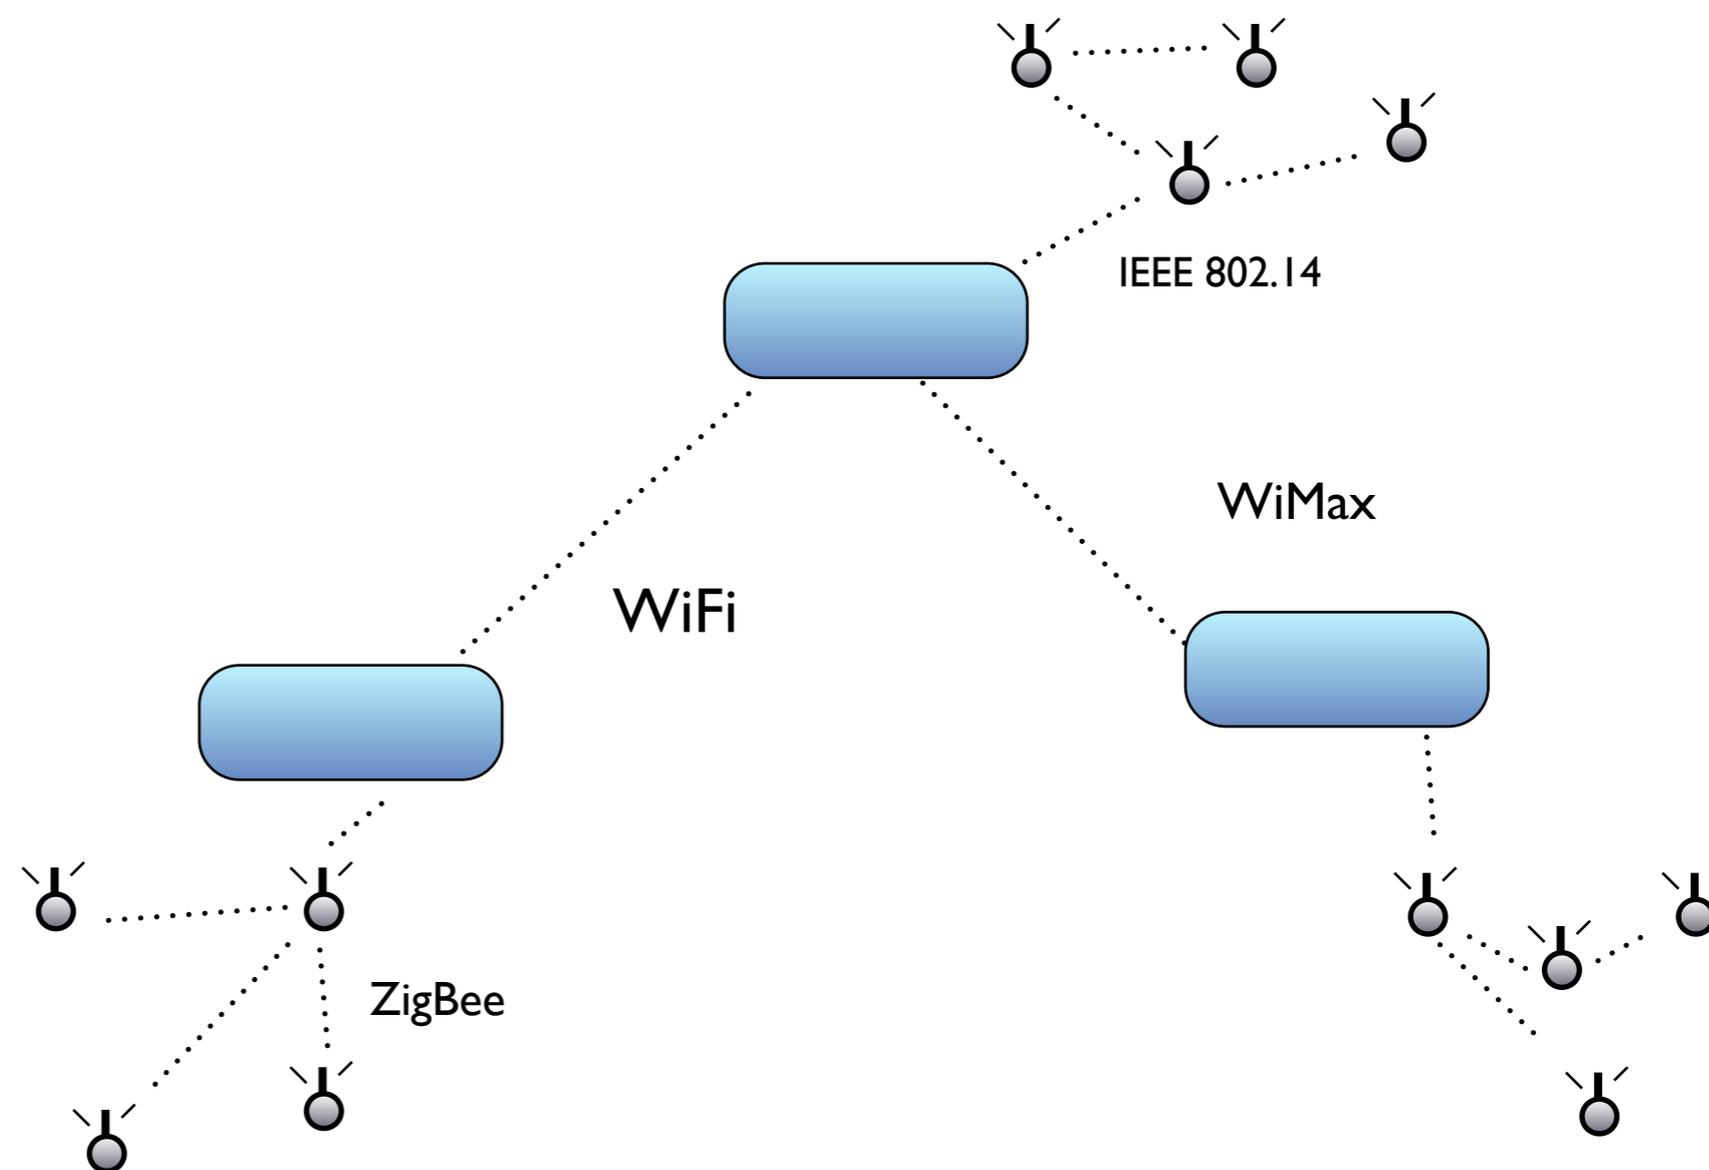


Orange Labs, Meylan  
MAPS/SHINE



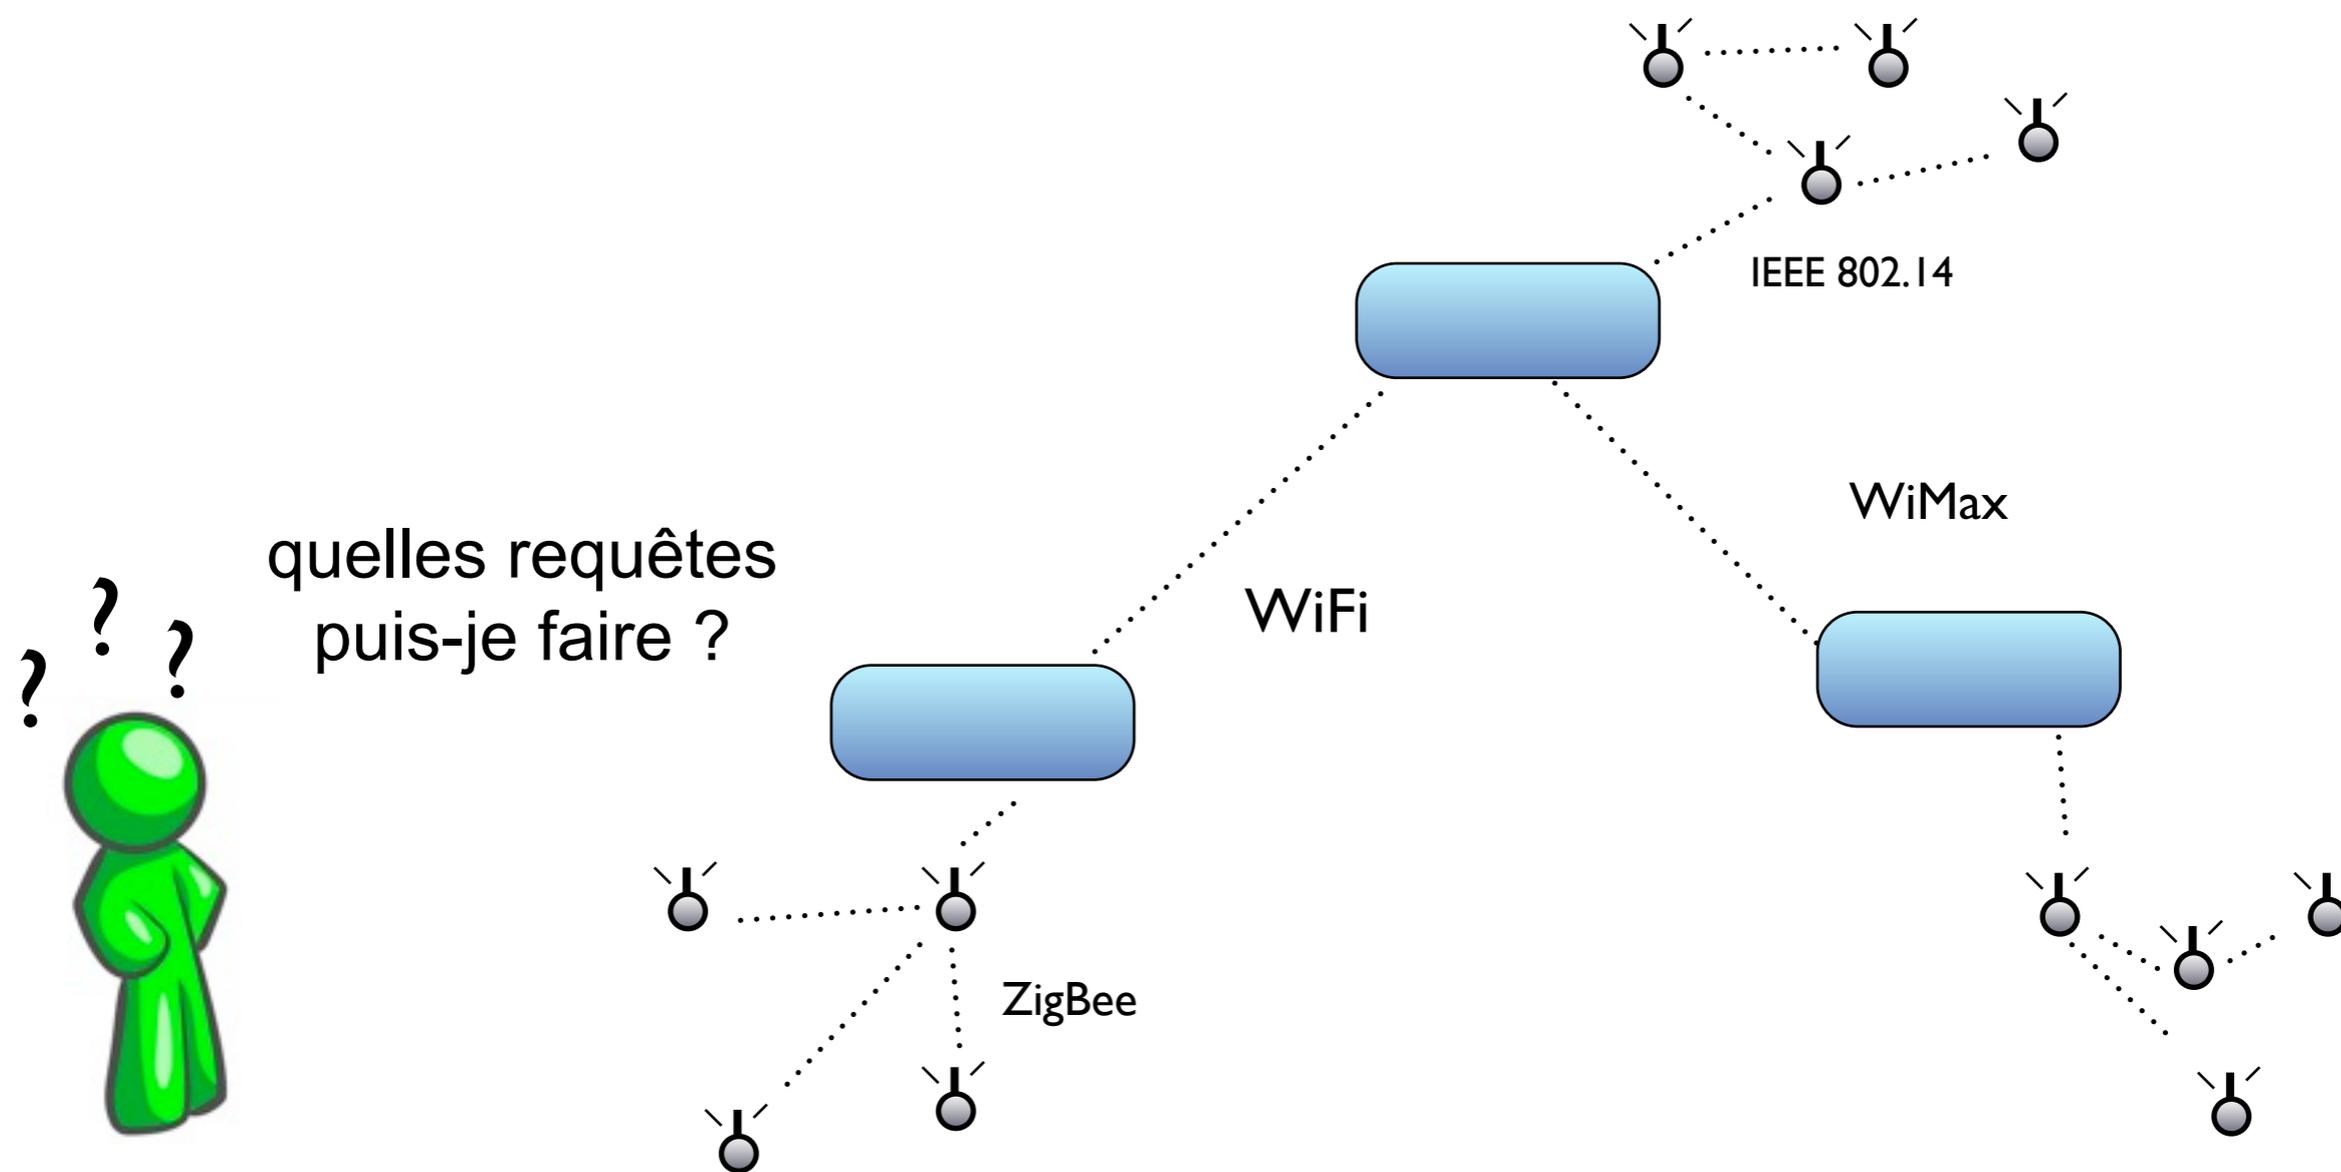
Système d'Information –  
inGénierie et Modélisation Adaptables

## Contexte : Les réseaux de capteurs



Domaines d'application : agriculture de précision, surveillance, domotique, géologie, chaînes de production, alertes environnementales, manutention datacenter...

## Problème : Interroger les capteurs !



Domaines d'application : agriculture de précision, surveillance, domotique, géologie, chaînes de production, alertes environnementales, manutention datacenter...

## Les requêtes possibles

Les requêtes instantanées  
une question → une réponse

⊕ Quels capteurs sont dans la pièce 'A' en ce moment ?

Requête historique

⊕ Quelle température avait le capteur 42 à 20h hier soir ?



## Les requêtes possibles

Les requêtes continues

une question → un flux de réponses



## Les requêtes possibles

Les requêtes continues

une question → un flux de réponses



## Les requêtes possibles

Les requêtes continues

une question → un flux de réponses

✦ Flux des moyennes des températures sur 5 minutes du capteur 42 ?



## Les requêtes possibles

Les requêtes continues

une question → un flux de réponses

⊕ Flux des moyennes des températures sur 5 minutes du capteur 42 ?

⊕ Flux des moyennes des températures sur 5 minutes des capteurs de la salle 'A' ?



## Les requêtes possibles

Les requêtes continues  
une question → un flux de réponses



- ⊕ Flux des moyennes des températures sur 5 minutes du capteur 42 ?
- ⊕ Flux des moyennes des températures sur 5 minutes des capteurs de la salle 'A' ?
- ⊕ Flux des moyennes des températures sur 5 minutes des capteurs de la salle 'A' en ce moment ?

## Les requêtes possibles

Les requêtes continues  
une question → un flux de réponses



⊕ Flux des moyennes des températures sur 5 minutes du capteur 42 ?

### Requête par désignation

⊕ Flux des moyennes des températures sur 5 minutes des capteurs de la salle 'A' ?

⊕ Flux des moyennes des températures sur 5 minutes des capteurs de la salle 'A' en ce moment ?



## L'existant

- ⊕ Plusieurs systèmes de gestion de flux et/ou de gestion de capteurs existent !
  - ⊕ TAG/TinyDB[Berkeley] : Requêtes continues dans les réseaux de capteurs
  - ⊕ STREAM[Stanford] : Formalisation avancée de l'interrogation continue
  - ⊕ Aurora[Brown] : Nouvelle algèbre, procédés d'optimisations importants
  - ⊕ TelegraphCQ[Berkeley] : Intégration continue des flux dans Postgres
  - ⊕ SStreaMWare[LIG] : Désignation continue et instantanée
  - ⊕ GSN[EPFL] : Formation d'un internet de capteurs, historiques des flux
  - ⊕ HiFi[Berkeley] : Réécriture de requêtes par un schéma global
  - ⊕ SUMAC[UCD] : Stockage et interrogation d'historique grande échelle
  - ⊕ StoneDB[MIT] : Historique distribué sur les capteurs



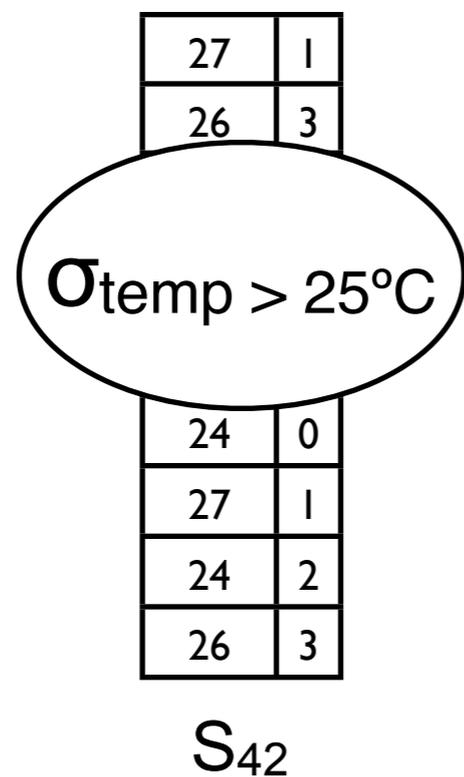
## Comment traiter les flux avec AStrAL ?



## L'arbre des requêtes

- ⊕ Toute requête continue s'appuie sur un arbre d'opérateurs
- ⊕ Exemple simple :

Le flux des mesures supérieures à 25°C du capteur 42



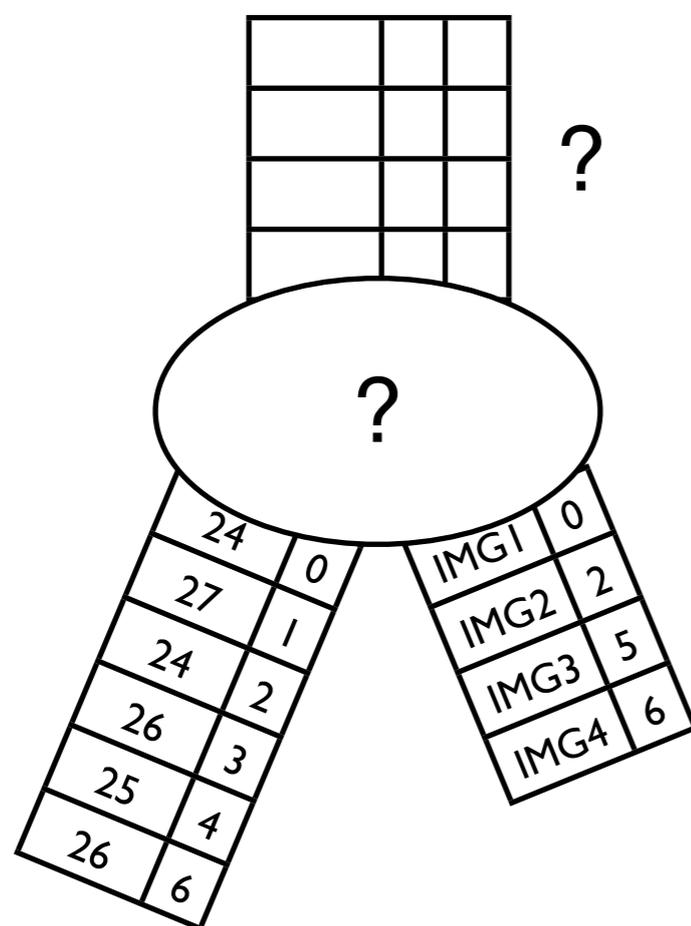
AStrAL  
 $\sigma_{temp > 25^\circ C}(S_{42})$





## Et si nous voulons utiliser deux flux ?

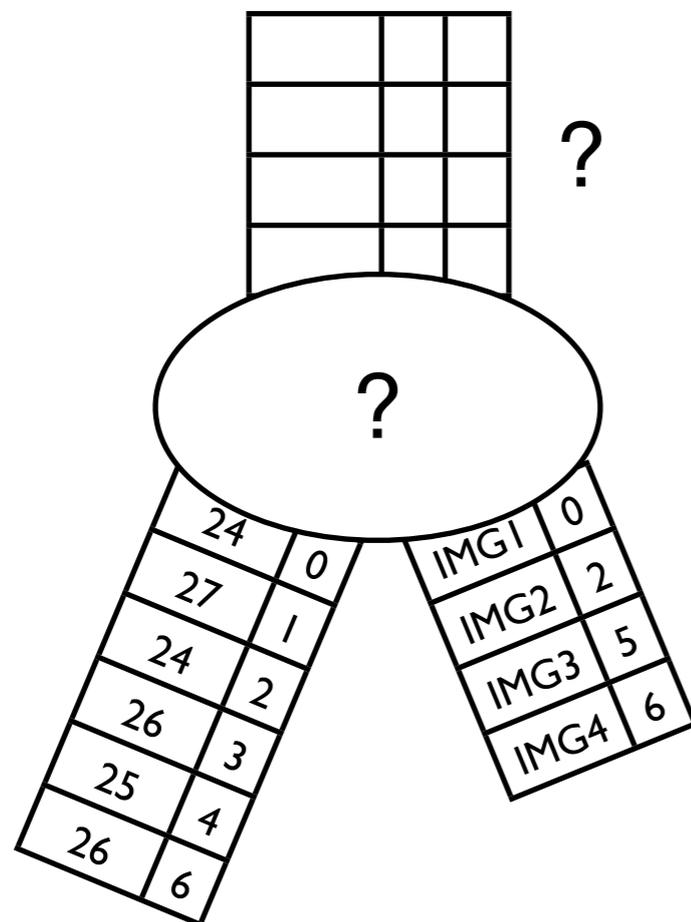
- Un flux, ça va... deux, bonjour les dégâts
- Exemple classique en surveillance :
  - Joindre à un flux de caméra, les températures d'un capteur





## Et si nous voulons utiliser deux flux ?

- Un flux, ça va... deux, bonjour les dégâts
- Exemple classique en surveillance :
  - Joindre à un flux de caméra, les températures d'un capteur

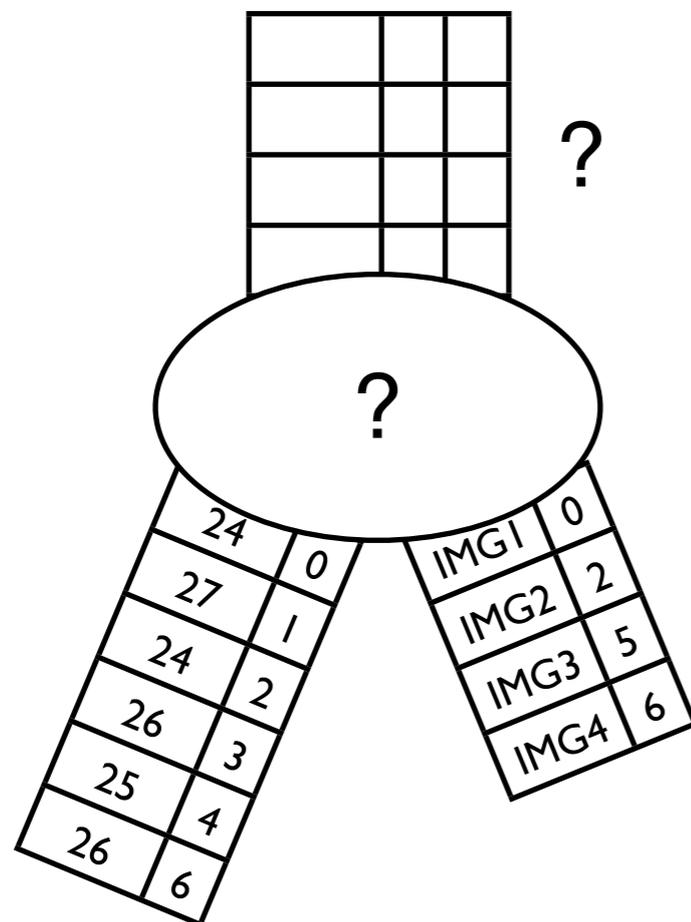


Égalité des timestamps ?  
 Autoriser une tolérance ?  
 Accorder une priorité ?

## Et si nous voulons utiliser deux flux ?



- Un flux, ça va... deux, bonjour les dégâts
- Exemple classique en surveillance :
  - Joindre à un flux de caméra, les températures d'un capteur



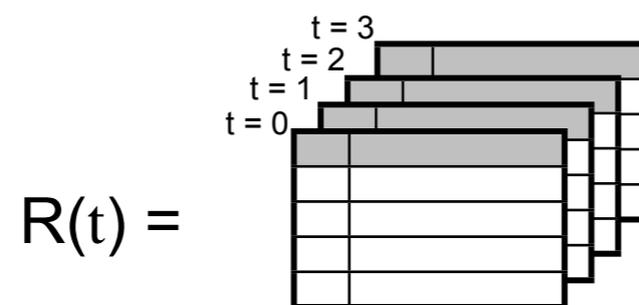
Égalité des timestamps ?  
 Autoriser une tolérance ?  
 Accorder une priorité ?

Diverses  
 sémantiques !

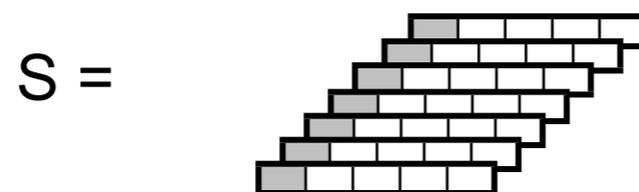


## Une solution : utiliser deux domaines de données

- Relation : Fonction du temps associant à un instant un ensemble de n-uplets

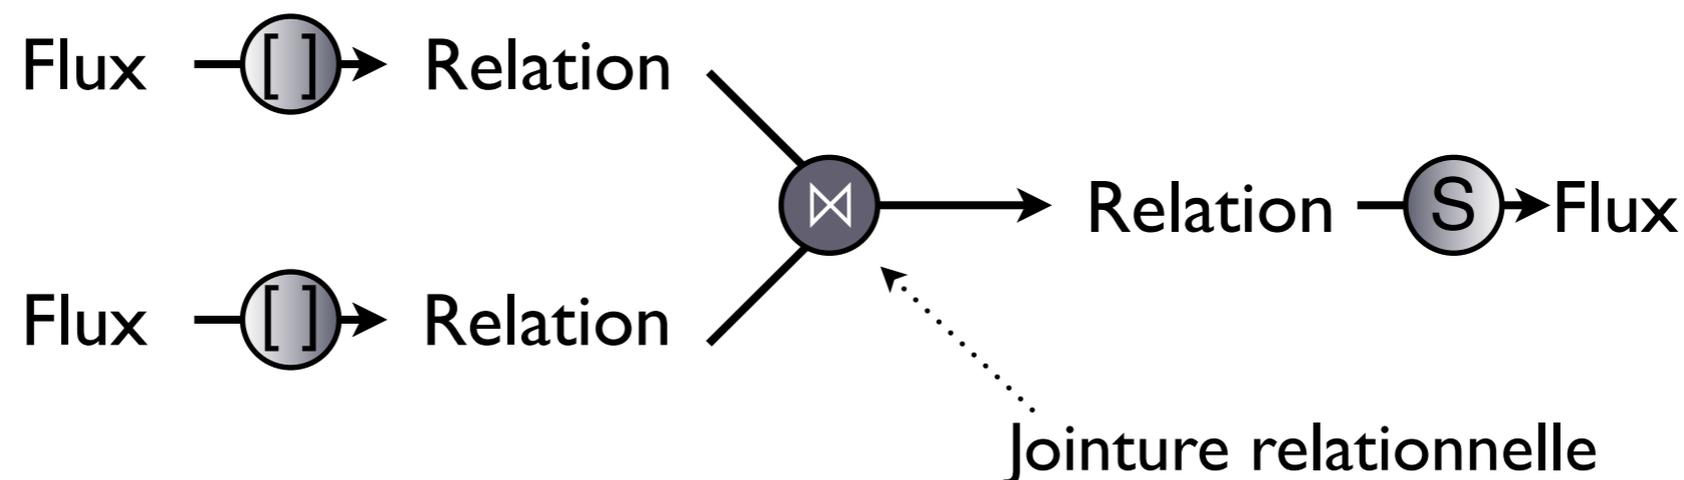


- Toute l'algèbre relationnelle est portable sur ce concept !
- Flux : Ensemble potentiellement infini de n-uplets qui contiennent un champ particulier *timestamp*



## Et concrètement ?

- ⊕ Opérateur de streaming : Relation  $\rightarrow$  Flux (par exemple : flux d'insertion)
- ⊕ Opérateur de fenêtrage : Flux  $\rightarrow$  Relation
- ⊕ Opération bien connue pour regrouper des n-uplets d'un flux suivant un critère et former une relation qui changera au cours du temps
- ⊕ Clarifie le sens des requêtes ! Une jointure entre flux ?

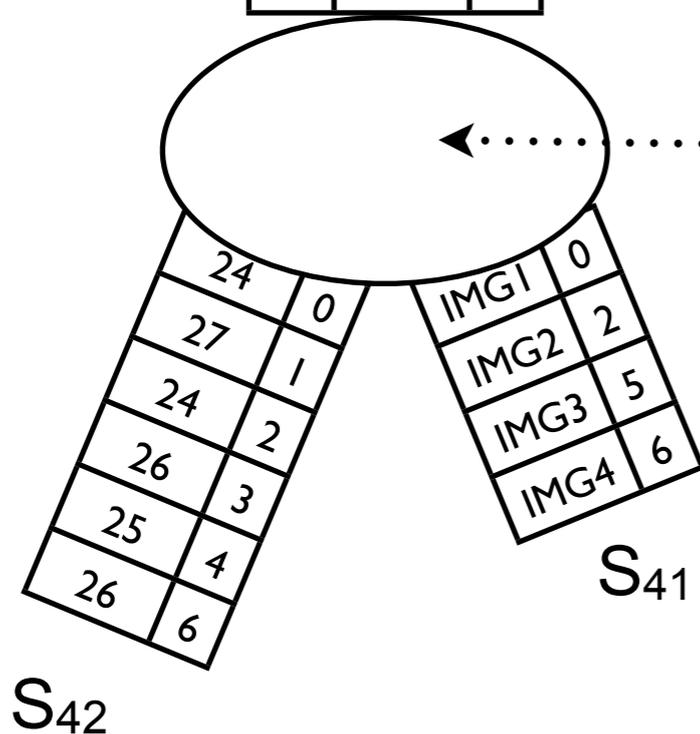


## Une jointure dans AStrAL

24	IMG1	0
27	IMG1	1
24	IMG2	2
26	IMG2	3
25	IMG2	4
25	IMG3	5
26	IMG4	6

$S[L]$  = Relation contenant à t la dernière donnée de S jusqu'à t

$R_S(R)$  = Envoie dans le flux résultant tout R à chaque fois que R change



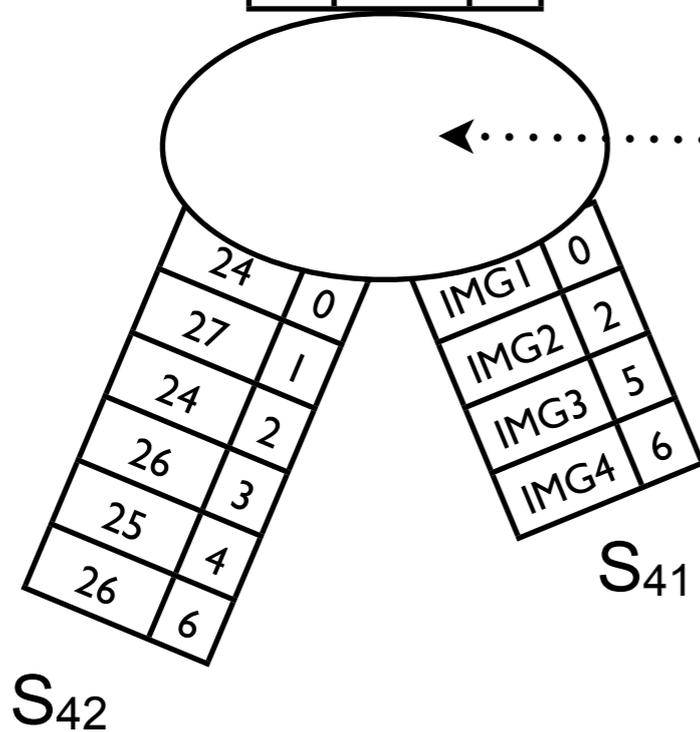
$$R_S^u((S_{42}[L]) \times (S_{41}[L]))$$

## Une jointure dans AStrAL

24	IMG1	0
27	IMG1	1
24	IMG2	2
26	IMG2	3
25	IMG2	4
25	IMG3	5
26	IMG4	6

$S[L]$  = Relation contenant à t la dernière donnée de S jusqu'à t

$R_S(R)$  = Envoie dans le flux résultant tout R à chaque fois que R change



$$R_S^u((S_{42}[L]) \times (S_{41}[L]))$$

Sémantique non ambiguë !



## Et la désignation dans tout ça ?



Flux des moyennes des températures sur 5 minutes des capteurs de la salle 'A'?

## Une désignation algébrique

- L'opérateur de désignation a le comportement suivant :  
À partir d'une relation  $Q$  contenant des identifiants et d'un flux fragmenté  $S$ 
  - Fournir le flux concernant ces identifiants, ce flux sera noté

$$\lambda_S(Q) = \bigcup_{i \in Q.id} S_i$$



## Une désignation algébrique

- L'opérateur de désignation a le comportement suivant :  
À partir d'une relation  $Q$  contenant des identifiants et d'un flux fragmenté  $S$ 
  - Fournir le flux concernant ces identifiants, ce flux sera noté

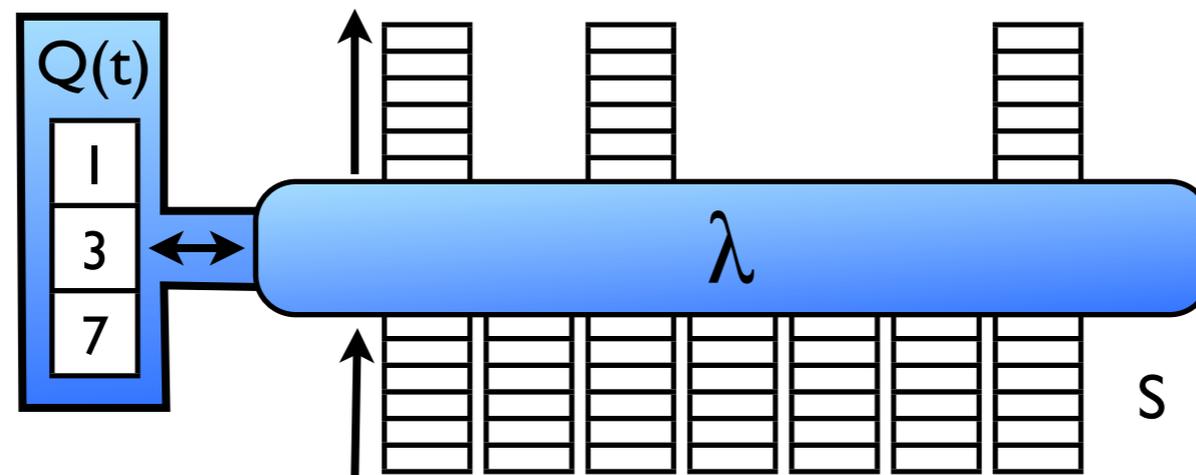
$$\lambda_S(Q) = \bigcup_{i \in Q.id} S_i$$



## Une désignation algébrique

- L'opérateur de désignation a le comportement suivant :  
 À partir d'une relation  $Q$  contenant des identifiants et d'un flux fragmenté  $S$ 
  - Fournir le flux concernant ces identifiants, ce flux sera noté

$$\lambda_S(Q) = \bigcup_{i \in Q.id} S_i$$



## Une désignation algébrique

- L'opérateur de désignation a le comportement suivant :  
À partir d'une relation  $Q$  contenant des identifiants et d'un flux fragmenté  $S$ 
  - Fournir le flux concernant ces identifiants, ce flux sera noté

$$\lambda_S(Q) = \bigcup_{i \in Q.id} S_i$$

- Nous définissons aussi l'équivalent relationnel  $C_S$  d'un flux  $S$  comme la relation contenant les dernières valeurs passés dans le flux pour chaque  $id$ .

$$C_S = \bigcup_i (S_i[L])$$

- Avec ces deux définitions, nous pouvons faire des requêtes très complexes facilement





## Exemples de requêtes

- Nous considérons que l'on a un flux fragmenté  $S$  :

Rappel :  $s \in S_i \Leftrightarrow s = \langle i, d_{p1}, \dots, d_{pk}, m, \tau \rangle$

- $i$  son identifiant
  - Chaque  $d_{pk}$  étant une méta-donnée où  $pk \in \{\text{type, location, unit...}\}$
  - $m$  étant une mesure
- Flux des capteurs situés dans la pièce A

$$\lambda_S(\sigma_{\text{room}=A} C_S)$$

- Flux des moyennes sur 5 minutes des capteurs de la salle 'A' ?

$$R_S^u(G_{\text{avg}(m)}(\lambda_S(\sigma_{\text{room}=A} C_S))[5\text{min}])$$

- Flux des moyennes sur 5 minutes des capteurs de la salle 'A' en ce moment ?

$$R_S^u(G_{\text{avg}(m)}(\lambda_S(\sigma_{\text{room}=A} C_S^{t_0}))[5\text{min}])$$



## Exemples de requêtes

- Nous considérons que l'on a un flux fragmenté  $S$  :

Rappel :  $s \in S_i \Leftrightarrow s = \langle i, d_{p1}, \dots, d_{pk}, m, \tau \rangle$

- $i$  son identifiant
- Chaque  $d_{pk}$  étant une méta-donnée où  $pk \in \{\text{type, location, unit...}\}$
- $m$  étant une mesure

- Flux des capteurs situés dans la pièce A

$$\lambda_S(\sigma_{\text{room}=A} C_S)$$

- Flux des moyennes sur 5 minutes des capteurs de la salle 'A' ?

$$R_S^u(G_{\text{avg}(m)}(\lambda_S(\sigma_{\text{room}=A} C_S)) [5\text{min}])$$

- Flux des moyennes sur 5 minutes des capteurs de la salle 'A' en ce moment ?

$$R_S^u(G_{\text{avg}(m)}(\lambda_S(\sigma_{\text{room}=A} C_S^{t_0})) [5\text{min}])$$



## Exemples de requêtes

- Nous considérons que l'on a un flux fragmenté  $S$  :

Rappel :  $s \in S_i \Leftrightarrow s = \langle i, d_{p1}, \dots, d_{pk}, m, \tau \rangle$

- $i$  son identifiant
- Chaque  $d_{pk}$  étant une méta-donnée où  $pk \in \{\text{type, location, unit...}\}$
- $m$  étant une mesure

- Flux des capteurs situés dans la pièce A

$$\lambda_S(\sigma_{\text{room}=A} C_S)$$

- Flux des moyennes sur 5 minutes des capteurs de la salle 'A' ?

$$R_S^u(G_{\text{avg}(m)}(\lambda_S(\sigma_{\text{room}=A} C_S)) [5\text{min}])$$

- Flux des moyennes sur 5 minutes des capteurs de la salle 'A' en ce moment ?

$$R_S^u(G_{\text{avg}(m)}(\lambda_S(\sigma_{\text{room}=A} C_S^{t_0})) [5\text{min}])$$



## Exemples de requêtes

- Nous considérons que l'on a un flux fragmenté  $S$  :

Rappel :  $s \in S_i \Leftrightarrow s = \langle i, d_{p1}, \dots, d_{pk}, m, \tau \rangle$

- $i$  son identifiant
- Chaque  $d_{pk}$  étant une méta-donnée où  $pk \in \{\text{type, location, unit...}\}$
- $m$  étant une mesure

- Flux des capteurs situés dans la pièce A

$$\lambda_S(\sigma_{\text{room}=A} C_S)$$

- Flux des moyennes sur 5 minutes des capteurs de la salle 'A' ?

$$R_S^u(G_{\text{avg}(m)}(\lambda_S(\sigma_{\text{room}=A} C_S)) [5\text{min}])$$

- Flux des moyennes sur 5 minutes des capteurs de la salle 'A' en ce moment ?

$$R_S^u(G_{\text{avg}(m)}(\lambda_S(\sigma_{\text{room}=A} C_S^{t_0})) [5\text{min}])$$



## Un peu d'historiques ?



## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots \}$$

## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots \}$$

## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots \}$$

## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

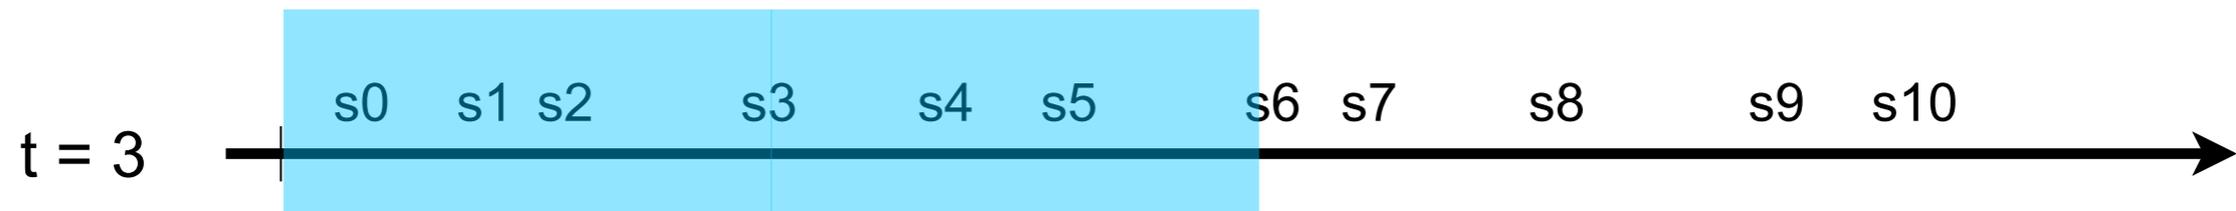
$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots \}$$

## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

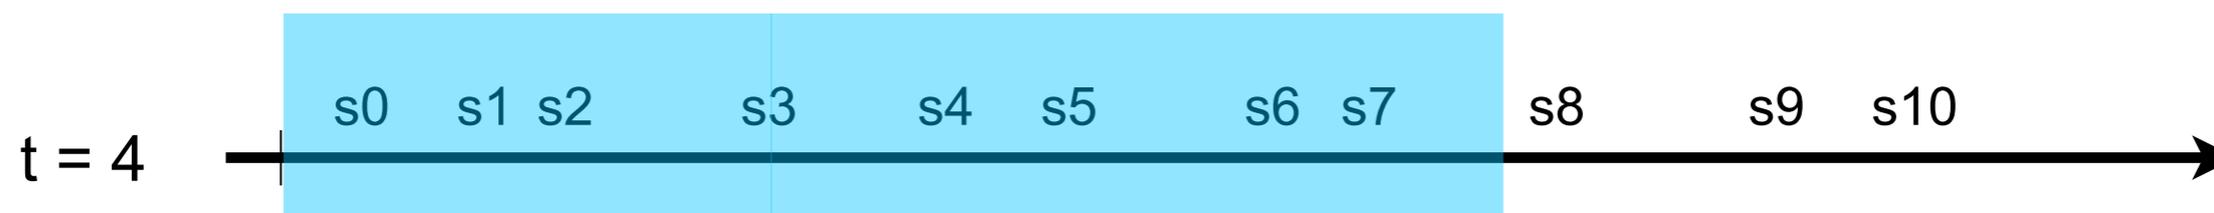
$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots\}$$

## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

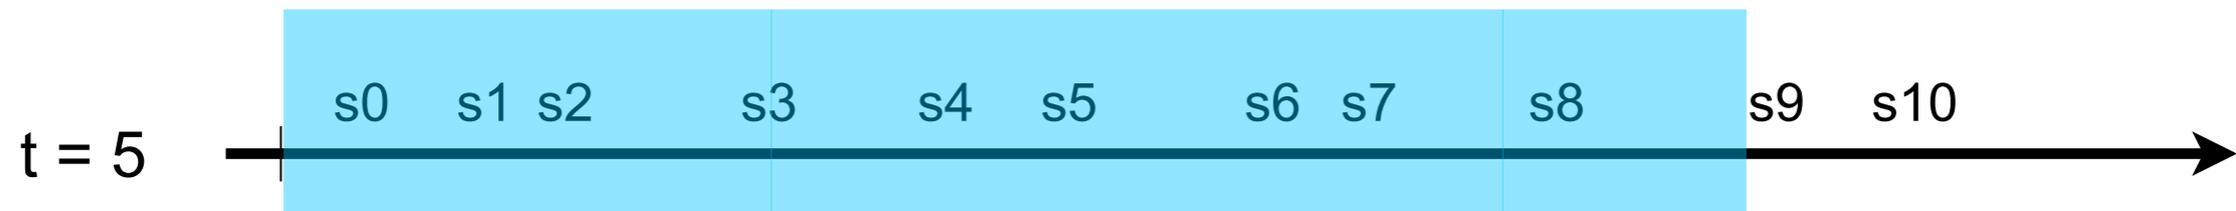
$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots \}$$

## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

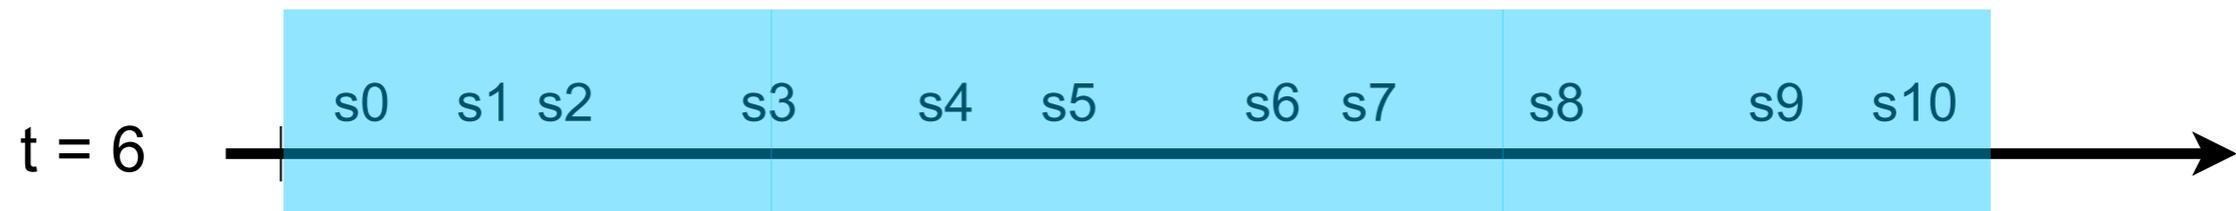
$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots\}$$

## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

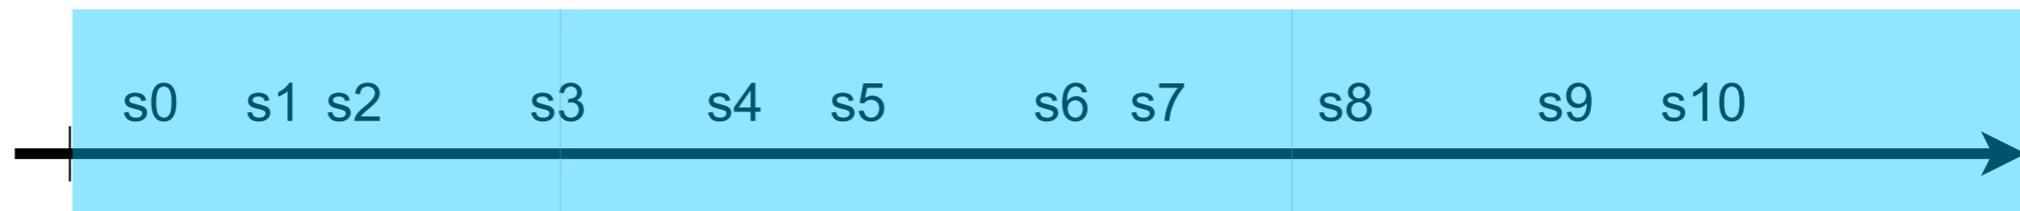
$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots\}$$

## Qu'est-ce que c'est ?

- ⊕  $S[\infty]$  : Séquence de fenêtres cumulative, garde l'ensemble des données



- ⊕ Historique d'une requête  $Q_0$  démarré à  $t_0$  :

$$(Q_0[\infty], t_0)$$

- ⊕ Historique d'un système : Ensembles d'historiques de requêtes

$$P = \{(Q_0[\infty], t_0), (Q_1[\infty], t_1), \dots \}$$

## Qu'en faire ?

- ⊕ Utiliser l'historique comme une source pour évaluer d'autres requêtes
- ⊕ Nous devons pouvoir traverser le temps et garder les mêmes sémantiques
  - ⊕ Notion de «transposabilité» d'une requête
  - ⊕ Exemples :

$\sigma_{\text{temp} > 25^{\circ}\text{C}}(S_{42})$  est transposable de  $t_0$  à  $t_1$  si  $t_0 < t_1$

$S_{42}[5\text{min}]$  est transposable de  $t_0$  à  $t_1$  si  $t_0 < t_1$  et  $t_1 \equiv t_0[5\text{min}]$

- ⊕ Conséquence : nous savons manipuler l'historique comme le présent, nous pouvons faire des requêtes combinant les deux !

## Qu'en faire ?

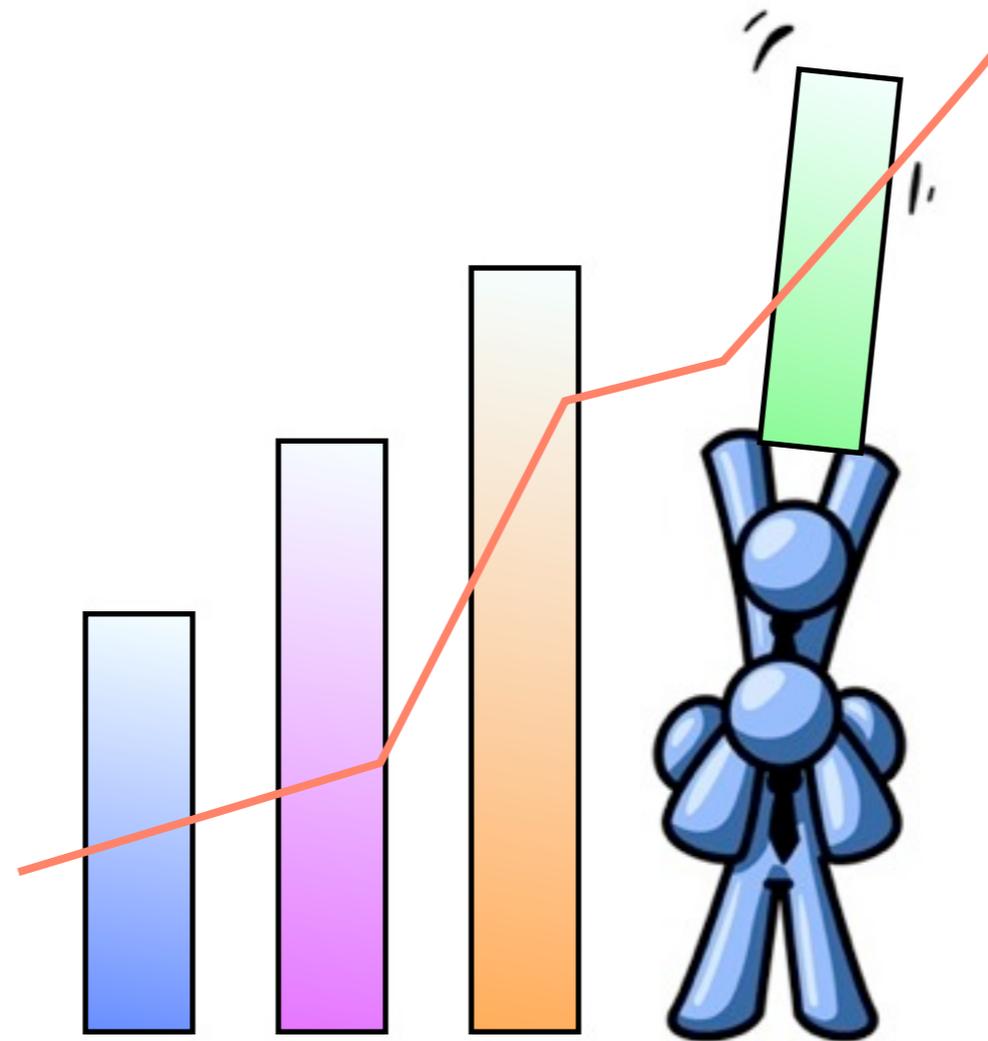
- ⊕ Utiliser l'historique comme une source pour évaluer d'autres requêtes
- ⊕ Nous devons pouvoir traverser le temps et garder les mêmes sémantiques
  - ⊕ Notion de «transposabilité» d'une requête
  - ⊕ Exemples :

$\sigma_{\text{temp} > 25^{\circ}\text{C}}(S_{42})$  est transposable de  $t_0$  à  $t_1$  si  $t_0 < t_1$

$S_{42}[5\text{min}]$  est transposable de  $t_0$  à  $t_1$  si  $t_0 < t_1$  et  $t_1 \equiv t_0[5\text{min}]$

- ⊕ Conséquence : nous savons manipuler l'historique comme le présent, nous pouvons faire des requêtes combinant les deux !

# Conséquences pratiques ? Clarté, Optimisations et Performances !





## Optimisation algébrique

- ⊕ Formalisation propre basée sur les mathématiques
- ⊕ Nous induisons des propositions sur des équivalences de requêtes
  - ⊕ Peut-on trouver la meilleure requête équivalente ?
  - ⊕ Pour l'instant encore à établir mais nous avons quelques résultats !
- ⊕ Partage de plan généralisable
  - ⊕ Dans un système grande échelle : plusieurs requêtes continues
  - ⊕ Économie de processus en partageant des sous-requêtes
  - ⊕ Requiert équivalence de requêtes à travers le temps
  - ⊕ Solution partielle : analyse de l'historique et de la transposabilité

## Validation



- ⊕ Comparaison avec les systèmes actuels dans les d
- ⊕ Écriture des opérateurs d'AStrAL dans les autres systèmes
  - ⊕ Aucune couverture totale n'est atteinte
  - ⊕ Détails sur <http://tls.wydd.free.fr/comparatif>
- ⊕ Formalisation des requêtes de trois systèmes avec AStrAL
  - ⊕ SStreaMWare (désignation), SUMAC (historique), FastBit/TelegraphCQ (couplage historique-continu)
  - ⊕ Permet de mieux comprendre ces systèmes
- ⊕ *Proof of Concept* : Création d'un prototype d'évaluation de requête (distribuée).

# Conclusion



- ⊕ Une algèbre pour l'écriture des requêtes mentionnées sur flux
  - ⊕ Permet d'avoir une sémantique précise sur les requêtes
- ⊕ Une formalisation de l'historique
  - ⊕ Permet des réécritures de requêtes sur des données persistantes
- ⊕ L'ouverture de procédés d'optimisation peu exploités
  - ⊕ Optimisation algébrique sur les flux
  - ⊕ Partage de sous-requêtes

## Perspectives

- ⊕ Critère exact d'équivalence de requêtes
- ⊕ Mise en œuvre d'un système de réécriture sur l'historique
- ⊕ Déploiement de l'historique en distribué
- ⊕ Optimisation algébrique et répartition distribuée des opérateurs
- ⊕ Etudes des requêtes approximatives



**Nous avons des propositions,  
mais il reste énormément de travail !**

**Merci de votre attention !**



**Questions ?**