

# Approche par bornes stochastiques et histogrammes pour l'analyse de performance des réseaux <sup>1</sup>

Farah AIT SALAHT <sup>1</sup>

Sous la direction de : H. Castel, J.M. Fourneau et N. Pekergin

<sup>1</sup>PRiSM, Univ. Versailles St Quentin, UMR CNRS 8144, Versailles France



10ème Atelier en Evaluation de Performances,  
11-13 juin 2014



Projet Digiteo : MARINA & Projet MARMOTE



# Sommaire

Motivation

Description du modèle de file d'attente

Notre méthodologie

Exemples à partir de traces réelles

Conclusion

# Sommaire

## Motivation

Description du modèle de file d'attente

Notre méthodologie

Exemples à partir de traces réelles

Conclusion

# Motivation

- Analyser les performances d'un réseau sous des trafics généraux issus de traces réelles

# Motivation

- Analyser les performances d'un réseau sous des trafics généraux issus de traces réelles
  - **Problème :**
    - Chaînes de Markov à espace d'état très grand
    - Solution exacte est très difficile voir impossible
    - Calcul numérique rapide impossible (complexité)

# Motivation

- Analyser les performances d'un réseau sous des trafics généraux issus de traces réelles
  - **Problème :**
    - Chaînes de Markov à espace d'état très grand
    - Solution exacte est très difficile voir impossible
    - Calcul numérique rapide impossible (complexité)
  - **Approches existantes :**
    - Modélisation par une loi de probabilité connue
    - Représentation non fidèle du comportement du réseau
    - Résultats inexacts et approximatifs

# Motivation

- Analyser les performances d'un réseau sous des trafics généraux issus de traces réelles

- **Problème :**

- Chaînes de Markov à espace d'état très grand
- Solution exacte est très difficile voir impossible
- Calcul numérique rapide impossible (complexité)

- **Proposition :**

**Utiliser l'approche par histogramme et Réduire la taille des distributions en employant des bornes stochastiques**

- Borne stochastique  $\implies$  le résultat est une borne de la distribution exacte  
 $\implies$  Bornes sur les mesures de performance
- Contrôler la taille des distributions  $\implies$  Contrôler la complexité
- Compromis entre la qualité des bornes et la complexité du calcul.

# Sommaire

Motivation

Description du modèle de file d'attente

Notre méthodologie


Exemples à partir de traces réelles

Conclusion



# Description du modèle de file d'attente


## ► Trace du trafic utilisé comme exemple :



- Trace du trafic MAWI correspondant à une heure de mesure de trafic IP  
9 janvier 2007 entre 12h et 13h
- Échantillonnage avec une période de 40 ms

# Description du modèle de file d'attente


## ► Trace du trafic utilisé comme exemple :



- Trace du trafic MAWI correspondant à une heure de mesure de trafic IP  
9 janvier 2007 entre 12h et 13h
- Échantillonnage avec une période de 40 ms
- Représentation en histogramme
- Nombre de bins est de 80511

# Description du modèle de file d'attente

## ► Modèle de file d'attente :



Le trafic en entrée est stationnaire et i.i.d. ( $A(t) = \mathcal{A}$ ).

## Équations d'évolution

### ► Équation de récurrence sur la longueur du tampon :

$$Q(k) = \min(B, (Q(k-1) + \mathcal{A} - S)^+), \quad k \in \mathbb{N}. \quad (1)$$

### ► Distribution de sortie :


$$D(k) = \min(S, Q(k-1) + \mathcal{A}), \quad k \in \mathbb{N}. \quad (2)$$

### ► Chaîne de Markov à temps discret.

Hypothèse : chaînes de Markov ergodiques.

# Description du modèle de file d'attente

## ► Modèle de file d'attente :



Le trafic en entrée est stationnaire et i.i.d. ( $A(t) = \mathcal{A}$ ).

## Équations d'évolution

### ► Équation de récurrence sur la longueur du tampon :

$$Q(k) = \min(B, (Q(k-1) + \mathcal{A} - S)^+), \quad k \in \mathbb{N}. \quad (1)$$

### ► Distribution de sortie :

$$D(k) = \min(S, Q(k-1) + \mathcal{A}), \quad k \in \mathbb{N}. \quad (2)$$

► **Inconvénients** : Calcul trop coûteux  $\rightarrow$  Histogramme trop grand

# Description du modèle de file d'attente

- Distributions empiriques avec un grand nombre de bins (plusieurs milliers)
- Opérations élémentaires : la convolution augmente considérablement la taille de la description du résultat
- La taille de  $A \otimes B$  est bornée par la  $\text{taille}(A) * \text{taille}(B)$

# Description du modèle de file d'attente

- Distributions empiriques avec un grand nombre de bins (plusieurs milliers)
- Opérations élémentaires : la convolution augmente considérablement la taille de la description du résultat
- La taille de  $A \otimes B$  est bornée par la  $\text{taille}(A) * \text{taille}(B)$

## Exemple de Convolution

- Deux distributions  $X$  et  $Y$  définies respectivement sur  $\mathcal{G}_X$  et  $\mathcal{G}_Y$  ;  
avec  $\mathcal{G}_X = \{1, 3, 5\}$  et  $\mathcal{G}_Y = \{2, 5\}$  ;  
et des distributions de probabilités :  $p_X = [0.2, 0.5, 0.3]$  et  $p_Y = [0.6, 0.4]$ .
- **Distribution Résultante**  
 $p_Z = p_X \otimes p_Y = [0.12, 0.3, 0.08, 0.18, 0.2, 0.12]$  définie sur  
 $\mathcal{G}_Z = \{3, 5, 6, 7, 8, 10\}$ .

La convolution requière  $O(|\mathcal{G}_X| \times |\mathcal{G}_Y|)$  opérations (+) et au plus  $|\mathcal{G}_X| \times |\mathcal{G}_Y|$  états pour la distribution résultante.

⇒ Explosion de la taille de l'espace d'état.

# Sommaire

Motivation

Description du modèle de file d'attente

**Notre méthodologie**

Exemples à partir de traces réelles

Conclusion

# Bornes stochastiques

- ▶  $\mathcal{G} = \{1, 2, \dots, n\}$  un espace fini.
- ▶  $X, Y$  : distributions discrètes à valeur sur  $\mathcal{G}$ ;
- ▶  $p_X(i) = \text{prob}(X = i)$  et  $p_Y(i) = \text{prob}(Y = i)$  pour  $i \in \mathcal{G}$ .

## Ordre stochastique sur les distribution $\leq_{st}$

- **Définition de l'ordre  $\leq_{st}$  :**  $X \leq_{st} Y$  ssi  $\sum_{k=i}^n p_X(k) \leq \sum_{k=i}^n p_Y(k), \quad \forall i.$
- **Comparaison de fonctions non décroissantes :**

$$X \leq_{st} Y \iff \mathbb{E}[f(X)] \leq \mathbb{E}[f(Y)]$$

pour toutes les fonctions non décroissantes  $f$ , pour lesquelles l'espérance existent.


- Soient  $F_X$  et  $F_Y$  leurs fonctions de répartition. Alors

$$X \leq_{st} Y \iff F_X(a) \geq F_Y(a), \quad \forall a \in \mathcal{G}$$




# Bornes stochastiques

**Exemple :**  $\mathcal{G} = \{1, 2, \dots, 7\}$ ,  $\mathbf{p}_X = [0.1, 0.2, 0.1, 0.2, 0.05, 0.1, 0.25]$  et  $\mathbf{p}_Y = [0, 0.25, 0.05, 0.1, 0.15, 0.15, 0.3]$ .



The pmf of a discrete distributions  $X$  and  $Y$



Cumulative distribution functions

# Bornes sur les histogrammes

- On a une distribution  $\mathbf{d}$  et  $\mathbf{r}$  : fonction de récompense positive croissante,  $R[\mathbf{d}] = \sum \mathbf{r}(i)\mathbf{d}(i)$ .
- Hypothèse : ordre total sur l'espace  $\mathcal{H}$ , de taille  $N$ ;
- Déterminer  $\mathbf{d1}$  et  $\mathbf{d2}$  tel que :
  1.  $\mathbf{d2} \leq_{st} \mathbf{d} \leq_{st} \mathbf{d1}$ ;
  2.  $\mathbf{d1}$  et  $\mathbf{d2}$  ont exactement  $K \ll N$  états (pas nécessairement le même).  $\mathbf{d1}$  a comme support  $\mathcal{H}^u$ .  $\mathbf{d2}$  a comme support  $\mathcal{H}^l$ .
  3.  $\sum_{i \in \mathcal{H}} \mathbf{r}(i)\mathbf{d}(i) - \sum_{i \in \mathcal{H}^l} \mathbf{r}(i)\mathbf{d2}(i)$  est minimal pour les distributions bornes inférieures de  $\mathbf{d}$  avec  $K$  états;
  4.  $\sum_{i \in \mathcal{H}^u} \mathbf{r}(i)\mathbf{d1}(i) - \sum_{i \in \mathcal{H}} \mathbf{r}(i)\mathbf{d}(i)$  est minimal pour les distributions bornes supérieures de  $\mathbf{d}$  avec  $K$  états;

# Bornes sur les histogrammes de trafic

## Bornes optimales, programmation dynamique

- Problème de théorie des graphes.
- On considère un graphe pondéré  $G = (V, E)$  avec :
  - ▶ **Borne inférieure** :  $w(e) = \sum_{j \in \mathcal{H}: u < j < v} d(j)(r(j) - r(u))$
  - ▶ **Borne supérieure** :  $w(e) = \sum_{j \in \mathcal{H}: u < j < v} d(j)(r(v) - r(j))$
- **Calcul de la borne optimale**  $\equiv$  Calculer le plus court chemin dans le graphe  $G$  avec  $K$  nœuds ( $K \ll N$ ). Complexité :  $O(N^2 K)$
- La masse de probabilités des nœuds supprimés est sommée avec
  - ▶ **Borne inférieure** : Les prédécesseurs immédiats
  - ▶ **Borne supérieure** : Les successeurs immédiats


## Exemple : Borne supérieure optimale

On considère

- Distribution discrète  $\mathcal{A} = (\mathbf{A}, p(\mathbf{A}))$  avec support  $\mathbf{A} = \{0, 2, 3, 5, 7\}$  et probabilités  $p(\mathbf{A}) = [0.05, 0.3, 0.15, 0.2, 0.3]$

- Fonction de récompense  $r : \forall a_i \in \mathbf{A}, r(a_i) = a_i$ ,  
 $R[\mathcal{A}] = \sum_{a_i \in \mathbf{A}} r(a_i) p_{\mathbf{A}}(i) = 4.15$ .

► Calculer la borne optimale supérieure  $\bar{A}$  sur 3 états tel que la variation de  $R$  est minimale.




## Exemple : Borne supérieure optimale

On considère

- Distribution discrète  $\mathcal{A} = (\mathbf{A}, p(\mathbf{A}))$  avec support  $\mathbf{A} = \{0, 2, 3, 5, 7\}$  et probabilités  $p(\mathbf{A}) = [0.05, 0.3, 0.15, 0.2, 0.3]$

- Fonction de récompense  $r : \forall a_i \in \mathbf{A}, r(a_i) = a_i$ ,  
 $R[\mathcal{A}] = \sum_{a_i \in \mathbf{A}} r(a_i) p_{\mathbf{A}}(i) = 4.15$ .

► Calculer la borne optimale supérieure  $\bar{\mathcal{A}}$  sur 3 états tel que la variation de  $R$  est minimale.



Distribution bornante  $[0.35, 0.35, 0.3]$  avec support  $\{2, 5, 7\}$

# Résultats théoriques

**Objectif** : Bornes stochastiques sur le processus d'entrée  $\implies$  bornes sur les mesures de performance.

Nous avons montré le résultat important suivant :

## Monotonie

Si  $A(k) \leq_{st} A^U(k), \forall k \geq 0$ , alors  $Q(k) \leq_{st} Q^U(k), \forall k \geq 0$

et

Si  $A(k) \leq_{st} A^U(k), \forall k \geq 0$ , alors  $D(k) \leq_{st} D^U(k), \forall k \geq 0$ .

Également vrai pour les processus stationnaires.

## Autre algorithme possible

- Une approche approximative divisant l'espace d'états  $\mathcal{H}$  en  $K$  sous ensembles de même mesure et en calculant la somme des probabilités sur ces sous-ensembles (approche de Hernández et *al.* 2007, appelée HBSP).

# Sommaire

Motivation

Description du modèle de file d'attente

Notre méthodologie

**Exemples à partir de traces réelles**

Conclusion



# Exemples à partir de traces réelles

## Objectif :


Comparer les différentes méthodes (résultat exact, méthode HBSP et nos bornes).

## 1- File simple

- Influence du nombre de bins sur la précision des résultats
- Relation entre la taille du tampon et certaines mesures de performance


## 2- Réseau de files d'attente

On considère le réseau en tandem suivant




# Nombre de bins vs précision : Paramètres QoS en utilisant la trace de trafic MAWI

## 1- File simple




(a) Probabilités de blocage




(b) Moyenne de la longueur du tampon

## Influence du nombre de bins sur la précision des résultats

### Distribution de probabilités cumulée (cdf) de la longueur du tampon sous la trace MAWI




(c) bins=20




(d) bins=100

## Influence du nombre de bins sur la précision des résultats

### Distribution de probabilités cumulée (cdf) de la longueur du tampon sous la trace MAWI



(e) bins=20



(f) bins=100

Temps de calcul pour  $bins = 100$  :



**Exacte : 1897 s**

**HBSP : 0.007 s, BI : 0.35 s**



**BS : 0.33 s**

# Paramètres QoS en utilisant la trace de trafic CAIDA OC-48


$bins = 10$



$bins = 100$




## 2- Réseau de file d'attente : Réseau en tandem




- Hypothèse : indépendance (approximation)
- Chaque file est analysée séparément
- Monotonie  $\implies$  bornes à chaque étape intermédiaire

## 2- Réseau de file d'attente : Réseau en tandem




- Hypothèse : indépendance (approximation)
- Chaque file est analysée séparément
- Monotonie  $\implies$  bornes à chaque étape intermédiaire

### Distribution de probabilités cumulée de la longueur du tampon de la file 3.



bins=100



bins=500

# Sommaire

Motivation

Description du modèle de file d'attente

Notre méthodologie

Exemples à partir de traces réelles

**Conclusion**



# Conclusion

- Proposer une nouvelle approche fondée sur les bornes stochastiques;
- Deriver des bornes sur différentes mesures de performance : probabilités de blocage, occupation du tampon. . .
- Les bornes sur les performances sont très pertinentes pour le dimensionnement d'une file d'attente.

Notre méthode nous permet de

- Contrôler la taille des distributions;
- Compromis entre la précision et la complexité en changeant la taille des distributions.

Merci pour votre attention