

Prédiction de suites individuelles  
Cours 1 : Prédiction avec experts

Gilles Stoltz (CNRS – Ecole normale supérieure – HEC Paris)

Jeudi 28 avril 2011

Coordonnées :

Gilles Stoltz

<http://www.math.ens.fr/~stoltz>

Plan de ce premier cours :

- Cadre de la prédiction avec experts, notion de regret
- Borne supérieure  $M\sqrt{\frac{n}{2} \ln N}$  sur le regret ( $\bar{a}$  n connu)
- Application: le lemme de Sion
- Adaptation en un membre de tous n inconnu à l'avance

CADRE.

\* Jeu répété entre le statisticien et un environnement (la nature ou le diable, selon que cet environnement joue indépendamment du ou contre le statisticien) :

- Ensemble d'observations  $Y$  (arbitraire) pour l'environnement
- Ensemble de décisions possibles  $X$  (convexe) pour le statisticien
- Fonction de perte  $l: X \times Y \rightarrow \mathbb{R}$  (souvent  $\mathbb{R}^+$ , souvent même un compact de  $\mathbb{R}^+$ )

... et surtout ...

- $N$  experts, indexés par  $j = 1, \dots, N$ , qui à chaque tour de jeu, procurent des prédictions.

\* Déroulement du jeu de prédiction séquentielle: Pour  $t = 1, 2, \dots$  :

1. 1.1 Les experts choisissent leurs prédictions (en fonction du passé)

$$f_{1t}, \dots, f_{Nt} \in X$$

tandis que simultanément

1.2 l'environnement choisit l'observation  $y_t \in Y$

2. Le statisticien a accès aux  $f_{jt}$  et forme une prédiction  $\hat{p}_t \in X$

3. Toutes les prédictions et l'observation sont révélés à l'ensemble des protagonistes.

\* But: Le statisticien veut que son regret soit faible:

Perte cumulée du statisticien au tour  $n$ :  $\hat{L}_n = \sum_{t=1}^n l(\hat{p}_t, y_t)$

de l'expert  $j$ :  $L_{jn} = \sum_{t=1}^n l(f_{jt}, y_t)$

Regret:  $\hat{L}_n - \min \{L_{1n}, L_{2n}, \dots, L_{Nn}\}$

Si  $l$  est bornée (p.ex. à valeurs dans  $[0,1]$ ) alors  $R_n = O(n)$ .

On veut ici  $R_n = o(n)$  i.e.,  $\overline{\lim}_{n \rightarrow +\infty} R_n/n \leq 0$ .

Interprétation: À la limite, on fait presque aussi bien que le meilleur expert, alors qu'on n'a aucune raison de savoir qui c'est à l'avance, d'une part, et que d'autre part, le meilleur expert change au cours du temps!

Rq: Souvent même, on voudra des bornes uniformes (voir th. page suivante).

\* Exemple: Prédire, en un point donné, s'il va y avoir un dépassement de seuil d'alerte au pas (p.ex. pour l'ozone):

$y = \{y_t\}$ , les experts produisent des prédictions  $f_t \in \{0,1\}$  et le statisticien indique une probabilité  $\hat{p}_t \in \mathcal{X} = [0,1]$  de dépassement.

Note: La prédiction du statisticien ne peut être dans  $\{0,1\}$ , vu que l'on veut minimiser le regret par toute suite  $y_1, y_2, \dots$  (environnement = nature) ou pour toute stratégie de l'environnement (= diable).

Puisque  $\hat{p}_t$  et  $y_t$  sont choisis simultanément en apparence  $\rightarrow$  Il existe en effet toujours une pire suite  $y_t = |1 - \hat{p}_t|$  alors que si les deux experts sont  $f_{1t} \equiv 0$  et  $f_{2t} \equiv 1$ , on a:  $\hat{L}_n = n$  et  $\min\{L_{1n}, L_{2n}\} \leq n/2$  soit  $R_n \geq n/2$ .

Conséquence de cet exemple: Il vaut mieux que  $\mathcal{X}$  soit convexe!

\* Remarque: On cherche donc des bornes plutôt "deterministes" (puisque on se place dans le cas le pire). En particulier, ici, les  $y_1, y_2, \dots$  ne sont pas la réalisation d'un certain processus stochastique.

PREMIER ALGORITHME : POIDS EXPONENTIELS, CAS  $X$  CONVEXE

$$* \hat{P}_t = \mu_t \cdot (f_{1t}, \dots, f_{Nt}) = \sum_{k=1}^N \mu_{kt} f_{kt} \quad \text{où :}$$

$$\mu_1 = (\frac{1}{N}, \dots, \frac{1}{N}) \quad \text{puis pour } t \geq 2,$$

$$\mu_t \text{ définie par } \mu_{jt} = \frac{\exp(-\eta \sum_{s=1}^{t-1} \ell(f_{js}, y_s))}{\sum_{k=1}^N \exp(-\eta \sum_{s=1}^{t-1} \ell(f_{ks}, y_s))}$$

\* Interprétations :

- on utilise les performances passées des experts
- on ne mise pas tout sur l'expert qui s'est montré le meilleur jusque là ; en effet, un ou plusieurs experts peuvent avoir des performances pour l'instant presque aussi bonnes que la meilleur, et, pourquoi pas, meilleurs dans le futur.

\* Théorème : Si  $\ell$  est bornée à valeurs dans  $[0, M]$  et convexe en son premier argument, alors  $(\sup_{j=1, \dots, N} y_n) \in \mathcal{Y}^n$  ou sup sur les stratégies du diable

$$\sup \hat{L}_n - \min_{j=1, \dots, N} L_{jn} = \sup R_n \leq \frac{\ln N}{\eta} + \eta \frac{M^2}{8}$$

Corollaire :  $\sup R_n \leq M \sqrt{\frac{n}{2} \ln N}$  lorsque l'on connaît  $M$  et  $n$  et prend  $\eta = \frac{1}{M} \sqrt{8 \ln N / n}$ .

Remarque : Evidemment,  $n$  et  $M$  sont en général inconnus, et la calibration est un souci... On y reviendra en détails.

La preuve du théorème repose sur l'inégalité de probabilité suivante, dite lemme de Hoeffding :

Lemme (de Hoeffding) : Si  $X$  est une variable aléatoire à valeurs dans  $[a, b]$  alors  $\forall s \in \mathbb{R}, \ln \mathbb{E}[e^{sX}] \leq s \mathbb{E}[X] + \frac{s^2}{8} (b-a)^2$

Remarque: Par inégalité de Jensen, on a la minoration  
 $\ln \mathbb{E}[e^{sX}] \geq s \mathbb{E}[X]$ .

Preuve:  $\Psi_X(s) \stackrel{\text{def.}}{=} \ln \mathbb{E}[e^{sX}]$   
 (sera sauté en cours)  
 X étant bornée, il n'y a pas de problèmes pour appliquer le théorème de dérivation des intégrales à paramètre:

$$\Psi_X'(s) = \frac{\mathbb{E}[Xe^{sX}]}{\mathbb{E}[e^{sX}]}$$

$$\Psi_X''(s) = \frac{\mathbb{E}[X^2 e^{sX}] \mathbb{E}[e^{sX}] - (\mathbb{E}[X e^{sX}])^2}{(\mathbb{E}[e^{sX}])^2}$$

puisque

$$\frac{1}{\mathbb{E}[e^{sX}]} = e^{-\Psi_X(s)}$$

$$= \mathbb{E}[X^2 e^{sX} e^{-\Psi_X(s)}] - \left( \mathbb{E}[X e^{sX} e^{-\Psi_X(s)}] \right)^2$$

$$= \text{Var}_{\mathbb{Q}} X$$

où  $\mathbb{Q}$  est la probabilité absolument continue par rapport à  $\mathbb{P}$  de densité  
 $\omega \mapsto \frac{d\mathbb{Q}}{d\mathbb{P}}(\omega) = e^{sX(\omega)} e^{-\Psi_X(s)}$ .

X étant à valeurs dans  $[a, b]$ , on a  $|X - (\frac{b+a}{2})| \leq \frac{b-a}{2}$

$$\text{puis } \text{Var}_{\mathbb{Q}} X = \inf_{\mu \in \mathbb{R}} \mathbb{E}_{\mathbb{Q}}[(X - \mu)^2] \leq \frac{(b-a)^2}{4}$$

$$\text{Soit: } \Psi_X''(s) \leq \frac{(b-a)^2}{4}$$

puis en intégrant 2 fois, et en utilisant

$$\Psi_X'(0) = \mathbb{E}[X]$$

et  $\Psi_X(0) = \ln 1 = 0$ , il vient:

$$\Psi'_X(s) - \Psi'_X(0) \leq \int_0^s \frac{(b-a)^2}{4} du = \frac{(b-a)^2}{4} s$$

$$\Psi'_X(s) \leq \mathbb{E}[X] + \frac{(b-a)^2}{4} s$$

$$\begin{aligned} \Psi_X(s) - \cancel{\Psi_X(0)} &\leq \int_0^s \left( \mathbb{E}[X] + \frac{(b-a)^2}{4} u \right) du \\ &= s \mathbb{E}[X] + \frac{(b-a)^2}{8} s^2. \end{aligned}$$

Preuve du théorème : On commence par utiliser la convexité des  $l(\cdot, y_t)$  :

$$\begin{aligned} \hat{L}_n &= \sum_{t=1}^n l(\hat{p}_t, y_t) = \sum_{t=1}^n l\left(\mu_t \cdot \left(\frac{f_{jt}}{N}\right)_j, y_t\right) \\ &\leq \sum_{t=1}^n \sum_{j=1}^N \mu_{jt} l(f_{jt}, y_t) \end{aligned}$$

et donc

$$R_n \leq \sum_{t=1}^n \sum_{k=1}^N \mu_{kt} l(f_{kt}, y_t) - \min_{j=1, \dots, N} \sum_{t=1}^n l(f_{jt}, y_t).$$

On note  $l_t(k) = l(f_{kt}, y_t)$ , pour aller plus vite d'une part, et d'autre part, pour voir le côté générique de la méthode.

On a défini  $\mu_{kt} = \frac{w_{kt}}{W_t}$  où  $w_{kt+1} = \exp\left(-\eta \sum_{s=1}^t l_s(k)\right)$   
(=1 si  $t=1$ )

et  $W_{t+1} = w_{1t+1} + \dots + w_{Nt+1}$ .

Il suffit d'étudier

le log-rapport  $\ln \frac{W_n}{W_0}$ .

Minoration :  $W_n \geq e^{-\eta L_{jn}}$  pour tout  $j$  et  $W_0 = N$ , soit

$$\ln \frac{W_n}{W_0} \geq -\eta L_{jn} - \ln N$$

Majoration :

Pour  $t = 1, \dots, n$  :

$$\ln \frac{W_t}{W_{t-1}} = \ln \frac{\sum_k W_{k,t-1} e^{-\eta l_t(k)}}{\sum_k W_{k,t-1}}$$

$$= \ln \sum_k \mu_{kt} e^{-\eta l_t(k)}$$

$$\stackrel{\text{par Hoeffding}}{\leq} -\eta \sum_k \mu_{kt} l_t(k) + \frac{\eta^2}{8} M^2$$

où  $X = l_t(\cdot)$ soit  $a = M$ ,  $b = 0$ , et  $s = -\eta$ En sommant sur  $t$  et en combinant avec la minoration :

$$\forall j = 1, \dots, N, \quad -\eta L_{jn} - \ln N \leq -\eta \sum_t \sum_k \mu_{kt} l_t(k) + \frac{\eta^2}{8} M_n^2$$

Au final :

$$R_n \leq \sum_t \sum_k \mu_{kt} l_t(k) - \min_j L_{jn} \leq \frac{\ln N}{\eta} + \frac{\eta}{8} M_n^2$$

APPLICATION:LE LEMME DE SION. → (Utilisé notamment en théorie de l'information pour prouver que  $\min_{\max} = \max_{\min}$ )Lemme (de Sion):Soit  $X$  et  $Y$  deux ensembles convexes.Soit  $f: X \times Y \rightarrow [0, M]$  une fonction telle que-  $\forall x \in X, f(x, \cdot)$  est concave,-  $\forall y \in Y, f(\cdot, y)$  est convexe.

Alors sous des hypothèses de régularité: (à préciser)

$$\inf_{x \in X} \sup_{y \in Y} f(x, y) = \sup_{y \in Y} \inf_{x \in X} f(x, y).$$

Remarque: Autre application en théorie des jeux pour montrer l'existence d'une valeur pour les jeux à somme nulle (voir un prochain cours).Preuve:\*  $\geq$  est toujours vraie:

$$\forall y, \forall x_1, x_2 \quad f(x_1, y) \geq \inf_{x \in X} f(x, y)$$

$$\text{passant aux sup:} \quad \sup_{y \in Y} f(x_1, y) \geq \sup_{y \in Y} \inf_{x \in X} f(x, y)$$

puis passer à l'inf en  $x \in X$ .\* Pour  $\leq$ :soit  $N$  un entier fixé et  $\{x^{(1)}, \dots, x^{(N)}\}$  $N$  points de  $X$  (quelconques).On fixe  $n$ 

↳ On fait jouer un statisticien et un diable fichtifs de la sorte:

le diable sait que le statisticien utilise l'algorithme de pondération par poids exponentiels:

$$x_1 = \frac{1}{N} \sum_i x^{(i)} \quad \text{puis pour } t \geq 2,$$

$$x_t = \frac{\sum_{i=1}^N x^{(i)} \exp(-\eta \sum_{s=1}^{t-1} f(x^{(i)}, y_s))}{\sum_{i=1}^N \exp(-\eta \sum_{s=1}^{t-1} f(x^{(i)}, y_s))}$$

et peut donc faire le choix simultané au tour  $t = 1, 2, \dots, n$  (choix ne

dépendent lui aussi que du passé) de  $y_t$  tq.

$$f(x_t, y_t) \geq \sup_{y \in \mathcal{Y}} f(x_t, y) - \frac{1}{m}$$

Alors, pour le choix  $\eta = \frac{1}{M} \sqrt{\frac{8 \ln N}{n}}$

et par le théorème principal, par convexité de  $f$  en son premier argument :

$$\frac{1}{n} \sum_{t=1}^n f(x_t, y_t) \leq \min_{i=1, \dots, N} \frac{1}{n} \sum_{t=1}^n f(x^{(i)}, y_t) + M \sqrt{\frac{1}{2n} \ln N}$$

Et donc :

$$\inf_{x \in \mathcal{X}} \sup_{y \in \mathcal{Y}} f(x, y) \leq \sup_{y \in \mathcal{Y}} f\left(\frac{1}{n} \sum_{t=1}^n x_t, y\right)$$

$$\leq \sup_{y \in \mathcal{Y}} \frac{1}{n} \sum_{t=1}^n f(x_t, y)$$

par convexité des  $f(\cdot, y)$

$$\leq \frac{1}{n} \sum_{t=1}^n \sup_{y \in \mathcal{Y}} f(x_t, y)$$

convexité du sup

$$\leq \frac{1}{n} \sum_{t=1}^n f(x_t, y_t) + \frac{1}{n}$$

def des  $y_t$

$$\leq \min_{i=1, \dots, N} \frac{1}{n} \sum_{t=1}^n f(x^{(i)}, y_t) + M \sqrt{\frac{\ln N}{2n}} + \frac{1}{n}$$

→ on réinjecte l'eq. de haut de la page

$$\leq \min_{i=1, \dots, N} f(x^{(i)}, \frac{1}{n} \sum_{t=1}^n y_t) + M \sqrt{\frac{\ln N}{2n}} + \frac{1}{n}$$

par concavité des  $f(x^{(i)}, \cdot)$

$$\leq \sup_{y \in \mathcal{Y}} \min_{i=1, \dots, N} f(x^{(i)}, y) + o(1)$$

Conclusion: —  $n$  ayant été choisi arbitrairement, on a, en faisant  $n \rightarrow +\infty$  :

$$\inf_{x \in \mathcal{X}} \sup_{y \in \mathcal{Y}} f(x, y) \leq \sup_{y \in \mathcal{Y}} \min_{i=1, \dots, N} f(x^{(i)}, y)$$

En utilisant simplement les hypothèses de convexité / concavité, on a prouvé :

$$\inf_{x \in X} \sup_{y \in Y} f(x, y) \leq \inf_{N \in \mathbb{N}} \inf_{\{z_1, \dots, z_N\} \subset X} \sup_{y \in Y} \min_{j=1, \dots, N} f(z^j, y)$$

Les hypothèses de régularité vont assurer que le membre droit, a priori  $\geq \sup_y \inf_x f(x, y)$  et en fait aussi  $\leq \sup_y \inf_x f(x, y)$ , et donc =.

[ Hyp:  $X$  compact et  $f: X \times Y \rightarrow [0, M]$  uniformément continue p.a. Soit  $\varepsilon > 0$ , soit  $\delta > 0$  le module d'uniforme continuité sur  $X \times Y$  correspondant. Soit  $z^{(1)}, \dots, z^{(N_\delta)}$  tq. les boules  $B(z^{(j)}, \delta)$  recouvrent  $X$ . Par uniforme continuité,

( $X, Y$  métriques, distances  $d_X$  et  $d_Y$ )  
 $d_{X \times Y}$  donnée par la somme des distances)

$$d_X(z, z^{(j)}) \leq \delta \Rightarrow \forall y, |f(x, y) - f(z^{(j)}, y)| \leq \varepsilon$$

$$\text{soit en particulier, } \forall y, \min_{j=1, \dots, N_\delta} f(z^{(j)}, y) \leq f(x, y) + \varepsilon$$

Passant à l'inf puis sup :

$$\sup_y \min_{j=1, \dots, N_\delta} f(z^{(j)}, y) \leq \sup_y \inf_{x \in X} f(x, y) + \varepsilon$$

Soit donc, en réinjectant en haut de la page :

$$\forall \varepsilon > 0, \inf_{x \in X} \sup_{y \in Y} f(x, y) \leq \sup_{y \in Y} \inf_{x \in X} f(x, y) + \varepsilon.$$

D'où l'inégalité recherchée.

CALIBRATION DE  $\eta$ :ADAPTATION EN  $n$ .

Dans le premier théorème, pour avoir la bonne borne  $M \sqrt{\frac{n}{2} \ln N}$  sur le regret, il fallait choisir  $\eta = \frac{1}{M} \sqrt{\frac{8 \ln N}{n}}$  pour optimiser la borne théorique  $\frac{\ln N}{\eta} + \eta \frac{M^2}{8}$ .

Si  $\eta$  est mal choisi ou si on joue pour une infinité de tours, alors potentiellement, la borne peut être linéaire.

On n'a pas toujours de raisons de savoir pour combien de tours  $n$  on joue ni quelle est l'étendue  $[0, M]$  des pertes.

Solution:

Calibrez  $\eta$  en fonction du passé, i.e., trouvez une règle de choix de  $\eta_t$  au tour  $t$  en fonction des informations procurées par les tours  $s = 1, \dots, t-1$ ; et utilisez, pour  $t \geq 2$ , la probabilité

$$\mu_t = (\mu_{jt})_{j=1, \dots, N} \text{ avec } \mu_{jt} = \frac{\exp(-\eta_t \sum_{s=1}^{t-1} \ell_{js})}{\sum_{k=1}^N \exp(-\eta_t \sum_{s=1}^{t-1} \ell_{ks})}$$

où l'on note  $\ell_{ks} = \ell(f_{ks}, y_s)$  la perte de l'expert  $k$  au tour  $s$  (juste pour aller plus vite ici encore).

Lemme: Si la règle est telle que  $(\eta_t)_t$  est décroissante et que les  $\ell(\cdot, y)$  sont tous convexes et à valeurs dans  $[0, M]$ , alors:

$$R_n \leq \frac{\ln N}{\eta_n} + \sum_{t=1}^n \eta_t \frac{M^2}{8}.$$

Rq: La valeur de  $\eta_1$ , ou  $\mu_1 = (\frac{1}{N}, \dots, \frac{1}{N})$ , n'a pas d'importance.

Note: Dans ce qui suit, on ne s'intéressera qu'à l'adaptation en  $n$ .

Preuve: On note  $\mu_j^t = \frac{w_{j,t-1}}{W_{t-1}}$  où  $w_{j,t-1} = e^{-\eta_t \sum_{s=1}^t l_{js}}$   
 et  $W_{t-1} = \sum_{j=1}^N w_{j,t-1}$

tandis que  $w'_{j,t-1} = e^{-\eta_{t-1} \sum_{s=1}^{t-1} l_{js}}$   
 et  $W'_{t-1} = \sum_{j=1}^N w'_{j,t-1}$ .

La technique consiste, selon la même logique que précédemment, à majorer et minorer  $\frac{1}{\eta_m} \ln W_m - \frac{1}{\eta_1} \ln W_0$ .

D'une part, cette quantité est  $\geq -\sum_{t=1}^m l_{jt} - \frac{1}{\eta_1} \ln N$   
 (pour tout  $j$ )

D'autre part, en notant toujours  $L_{j,t-1} = \sum_{s=1}^{t-1} l_{js}$ , il vient, pour tout  $t \in \{1, \dots, m\}$ :

$$\begin{aligned} & \frac{1}{\eta_{t+1}} \ln W_t - \frac{1}{\eta_t} \ln W_{t-1} \\ &= \underbrace{\left( \frac{1}{\eta_{t+1}} \ln W_t - \frac{1}{\eta_t} \ln W'_t \right)}_{\text{mesure le coût de l'adaptabilité}} + \underbrace{\left( \frac{1}{\eta_t} \ln \frac{W'_t}{W_t} \right)}_{\text{terme Hoeffding}} \\ &= \frac{1}{\eta_{t+1}} \ln \sum_j (e^{-L_{jt}})^{\eta_{t+1}} - \frac{1}{\eta_t} \ln \sum_j (e^{-L_{jt}})^{\eta_t} \\ &= \ln \frac{\| (e^{-L_{jt}})_{j=1..N} \|_{\eta_{t+1}}}{\| (e^{-L_{jt}})_{j=1..N} \|_{\eta_t}} \\ &\leq \ln \| (1, \dots, 1) \|_q \quad \left. \begin{array}{l} \text{mg. de} \\ \text{Hölder} \end{array} \right\} \\ &= \ln N^{1/q} = \frac{1}{q} \ln N \\ &= \left( \frac{1}{\eta_{t+1}} - \frac{1}{\eta_t} \right) \ln N \end{aligned}$$

$$\begin{aligned} &= \frac{1}{\eta_t} \ln \left( \sum_j \mu_j^t e^{-\eta_t l_{jt}} \right) \\ &\leq \frac{1}{\eta_t} \left( -\eta_t \sum_j \mu_j^t l_{jt} + \eta_t^2 \frac{M^2}{8} \right) \\ &= -\sum_j \mu_j^t l_{jt} + \eta_t \frac{M^2}{8} \end{aligned}$$

où l'on a appliqué l'inégalité de Hölder avec

$$\begin{cases} r = \eta_{t+1} \\ p = \eta_t \\ \frac{1}{q} = \frac{1}{\eta_{t+1}} - \frac{1}{\eta_t} \geq 0 \end{cases}$$

Rappel: si  $p, q, r$  sont trois réels positifs tels que  $\frac{1}{p} + \frac{1}{q} = \frac{1}{r}$ , l'inégalité de Hölder assure que

$$\| (u_j v_j)_j \|_r \leq \| u \|_p \| v \|_q$$

pour tous vecteurs  $u = (u_j)_j$  et  $v = (v_j)_j$ .

En combinant majoration et minoration, on conclut :

$$-L_j n - \frac{1}{\eta_1} \ln N \leq - \underbrace{\sum_{t=1}^n \sum_{k=1}^N \mu_{kt} l_{kt}}_{\leq -\hat{L}_n \text{ par convexité}} + \sum_{t=1}^n \eta_t \frac{M^2}{8} + (\ln N) \sum_{t=1}^n \left( \frac{1}{\eta_{t+1}} - \frac{1}{\eta_t} \right)$$

D'où (après telescoping) la borne annoncée.

Corollaire: Si  $M$  est connu, avec la règle de choix

$$\eta_t = \frac{1}{M} \sqrt{4 \ln N / t}$$

assure que :

$$\sup R_n \leq M \sqrt{(n+1) \ln n}.$$

Le coût de l'adaptation en  $m$  est donc inférieur à  $\sqrt{2}$ .

Preuve: La borne précédente se ré-écrit (avec  $\eta_t = \frac{\gamma}{M} \sqrt{\ln N / t}$ ):

$$\frac{\ln N}{\eta_{n+1}} + \frac{M^2}{8} \sum_{t=1}^n \eta_t = M \sqrt{\ln n} \left( \frac{\sqrt{n+1}}{\gamma} + \frac{\gamma}{8} \sum_{t=1}^n \frac{1}{\sqrt{t}} \right).$$

Or par comparaison  $\sum / \int$ :

$$\sum_{t=1}^n \frac{1}{\sqrt{t}} \leq \int_1^{n+1} \frac{1}{\sqrt{u}} du \leq 2\sqrt{n+1}$$

Reste à optimiser en  $\gamma$  la quantité :

$$\frac{1}{\gamma} + \frac{\gamma}{4} \rightarrow \gamma = 2 \text{ est la meilleure valeur}$$

et on trouve  $M \sqrt{(n+1) \ln n} \left( \frac{1}{2} + \frac{1}{2} \right)$ .