

Evaluation de la capacité de mesures d'inégalité à détecter des changements dans une distribution de revenus

Matti Langel Yves Tillé

Institut de statistique
Université de Neuchâtel, Suisse

Journées de méthodologie statistique, 2009

- 1 Introduction
- 2 Indices d'inégalité
 - Notation
 - Présentation des indices
- 3 Etude de simulations
 - Données
 - Types de perturbations
 - Méthode de simulations
 - Principaux résultats
- 4 Conclusion

- Une multitude d'indices synthétiques permettent de mesurer l'inégalité dans une distribution de revenus.
- Objectifs :
 - Parvenir à détecter et mesurer un (petit) changement dans le niveau d'inégalité.
 - Etudier quelle mesure permet de détecter quel type de changement.
 - Evaluer la performance des indicateurs de Laeken (*QSR* et Gini).
- Méthode : comparer par simulations le niveau d'inégalité (estimé sur un échantillon) dans une distribution avant et après perturbation.

- Population finie U , de taille N .
- y_i : le revenu de l'observation i .
- Distribution ordonnée : $\text{rang}(y_i) = i$.
- Q_p : le quantile d'ordre p .
- Y , \bar{Y} et $\text{Var}(y)$ représentent respectivement le revenu total, le revenu moyen et la variance dans la population.
- Quantile shares :

$$S_p^+ = \sum_{y_i \geq Q_p} y_i, \quad S_p^- = \sum_{y_i \leq Q_p} y_i.$$

Indice de Gini

$$Gini = \frac{2 \sum_{i=1}^N iy_i}{N \sum_{i=1}^N y_i} - \frac{1}{N} - 1.$$

- L'indice d'inégalité le plus utilisé dans la littérature.
- L'un des deux indicateurs d'inégalité de Laeken (Eurostat).

Coefficient de variation

$$CV = \frac{\sqrt{\text{Var}(y)}}{\bar{y}}.$$

● Indices d'Atkinson :

- Basé sur la SWF (fonction de "bien-être social").
- α : paramètre d'"aversion aux inégalités"
(forte aversion lorsque α est proche de 1).
- Forme générale :

$$A_{\alpha} = \begin{cases} 1 - \left[\frac{1}{N} \sum_{i=1}^N \left(\frac{y_i}{\bar{Y}} \right)^{1-\alpha} \right]^{\frac{1}{1-\alpha}}, & \text{si } 0 \leq \alpha < 1, \\ 1 - \prod_{i=1}^N \left(\frac{y_i}{\bar{Y}} \right)^{\frac{1}{N}}, & \text{si } \alpha = 1. \end{cases}$$

Deux indices d'Atkinson sont traités dans nos simulations :

Atkinson ($\alpha = 0.5$)

$$A_{1/2} = 1 - \frac{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{y_i}\right)^2}{\bar{Y}}.$$

Atkinson ($\alpha = 1$)

$$A_1 = 1 - \prod_{i=1}^N \left(\frac{y_i}{\bar{Y}}\right)^{\frac{1}{N}} = 1 - \frac{G}{\bar{Y}}.$$

avec G , la moyenne géométrique : $G = \left(\prod_{i=1}^N y_i\right)^{\frac{1}{N}}$.

Indices IV : Quantile Share Ratios

- famille d'indices basés sur les *quantile shares*.
- Le *Quintile Share Ratio (QSR)* est le deuxième indicateur de Laeken.

Quintiles (*QSR*), déciles (*DSR*), médiane (*MSR*)

$$QSR = \frac{S_{80}^+}{S_{20}^-}, \quad DSR = \frac{S_{90}^+}{S_{10}^-}, \quad MSR = \frac{S_{50}^+}{S_{50}^-}.$$

- Une nouvelle mesure :

Average Share Ratio (*ASR*)

$$ASR = N \left(\sum_{j=1}^N \frac{\sum_{i=1}^j y_i}{\sum_{i=N-j+1}^N y_i} \right)^{-1}.$$

Indices V : Indice de Zenga

- proposé par Michele Zenga (2007).
- basé sur des ratios de moyennes arithmétiques.

Indice de Zenga

$$Z = 1 - \frac{1}{N} \sum_{j=1}^N \frac{\bar{Y}_j^-}{\bar{Y}_j^+}.$$

$$\text{avec } \bar{Y}_j^- = \frac{1}{j} \sum_{i=1}^j y_i \quad \text{et} \quad \bar{Y}_j^+ = \frac{1}{N-j+1} \sum_{i=j}^N y_i.$$

Indices VI : Entropie généralisée

- Forme générale : $GE_{\alpha} = \frac{1}{N} \sum_{i=1}^N \left(\frac{y_i}{Y}\right)^{\alpha} - 1$.
- Quand α tend vers 1 :

Indice de Theil (T)

$$GE_1 = T = \sum_{i=1}^N \frac{y_i}{Y} \log \frac{Ny_i}{Y}.$$

- Deux autres cas utilisés :

Entropie généralisée avec $\alpha = 0.5$ ($GE_{1/2}$) et $\alpha = 2$ (GE_2)

$$GE_{1/2} = 4 \left(1 - \sum_{i=1}^N \sqrt{\frac{y_i}{NY}} \right) \quad \text{et} \quad GE_2 = \frac{1}{2N} \sum_{i=1}^N \frac{y_i^2}{Y^2} - \frac{1}{2}.$$

- Forme générale : $R_\alpha = \frac{1}{\alpha - 1} \log N^{\alpha-1} \sum_{i=1}^N \left(\frac{y_i}{Y}\right)^\alpha$.
- Deux cas utilisés :

Divergence de Renyi avec $\alpha = 0.5$ ($R_{1/2}$) et $\alpha = 2$ (R_2)

$$R_{1/2} = -2 \log \sum_{i=1}^N \sqrt{\frac{y_i}{NY}} \quad \text{et} \quad R_2 = \log N \sum_{i=1}^N \frac{y_i^2}{Y^2}$$

- Note : Lorsque α tend vers 1, on retrouve l'indice de Theil.

- Simples rapports de quantiles (\neq *quantile shares*).

Rapports de quartiles (*IQR*), de déciles (*IDR*)

$$IQR = \frac{Q_{75}}{Q_{25}} \quad \text{et} \quad IDR = \frac{Q_{90}}{Q_{10}}.$$

- Une nouvelle mesure :

Mean Quantile Ratio (*MQR*)

$$MQR = \frac{N}{2 \sum_{i=1}^{N/2} \frac{y_i}{y_{N-i+1}}}.$$

- Distribution initiale (distribution A) :
 - Revenu imposable annuel des ménages du canton de Neuchâtel.
 - 88'011 contribuables au revenu non nul.
- Distribution modifiée (distribution B) :
 - Obtenue en **appliquant une perturbation** à la distribution A .
- Simulations réalisées avec **11** perturbations différentes.

1 Plafonnement des hauts revenus.

⇒ Nivellement de tous les revenus supérieurs à Q_{90} au revenu de Q_{90} .

2 Doublement des très hauts revenus.

⇒ Doublement du revenu des 5% les plus riches.

3 Réductions des très hauts revenus.

⇒ Réduction de moitié du revenu des 5% les plus riches.

4 Translation.

⇒ Ajout d'un revenu fixe de CHF 10'000 à toutes les observations.

5 Reduction de la dispersion de la distribution.

$$\Rightarrow y_{i_B} = 0.9y_{i_A} + 0.1\bar{Y}_A.$$

6 Revenus après imposition.

⇒ Le montant réel de la taxation est fourni par la base de données.

7 Revenu minimum garanti.

⇒ Pour cette simulation, tous les plus bas revenus ont été nivellés à un revenu égale à 30% du revenu médian.

8 Augmentation des plus bas revenus.

⇒ Le revenu des 5% les plus pauvres est multiplié par 10.

9 Diminution des plus bas revenus.

⇒ Le revenu des 5% les plus pauvres est divisé par 10.

10 **Reduction de la dispersion au centre de la distribution.**

$$\Rightarrow y_{iB} = \begin{cases} 0.1y_{iA} + 0.9\bar{Y}_A, & \text{si } Q_{30} \leq y_{iA} \leq Q_{70} \\ y_{iA}, & \text{sinon.} \end{cases}$$

11 **Evaluation de la robustesse.**

⇒ Sensibilité à une valeur extrême : un revenu sélectionné aléatoirement a été multiplié par dix mille.

Note : Cette perturbation est appliquée directement aux échantillons, non à la population.

Pour chacune des 11 perturbations :

- Sélection d'un échantillon S_A (plan simple sans remise, $n = 1000$) issu de la distribution A et de S_B (idem) issu de B .
- Estimation de chaque indice d'inégalité I sur S_A et sur S_B .
- 10'000 répliques.
- Calcul de \widehat{I}_A , \widehat{I}_B , $Var(\widehat{I}_A)$ et $Var(\widehat{I}_B)$, pour chaque indice d'inégalité sur les 10'000 simulations.
- Calcul de la statistique z :

$$z = \left| \frac{\widehat{I}_B - \widehat{I}_A}{\sqrt{Var(\widehat{I}_A) + Var(\widehat{I}_B)}} \right|.$$

⇒ une forte valeur de z indique une forte capacité à déceler le changement du niveau d'inégalités entre les deux distributions.

Simulations : Tableau des résultats (statistique z)

| | haut de la distribution | | | toute la distribution | | | bas de la distribution | | | centre | robust. |
|--------------|-------------------------|-------------|-------------|-----------------------|-------------|-------------|------------------------|-------------|-------------|-------------|-------------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | | |
| <i>Gini</i> | 3.52 | 2.86 | 2.53 | 2.67 | 1.76 | 0.78 | 0.75 | 1.01 | 0.14 | 1.49 | 5.52 |
| <i>CV</i> | 1.01 | 0.78 | 0.65 | 0.28 | 0.20 | 0.12 | 0.04 | 0.07 | 0.01 | 0.12 | 5.40 |
| $A_{1/2}$ | 2.37 | 2.28 | 1.72 | 2.19 | 1.54 | 0.55 | 0.99 | 1.04 | 0.51 | 0.50 | 5.31 |
| A_1 | 2.29 | 2.47 | 1.77 | 4.24 | 3.14 | 0.78 | 2.58 | 2.43 | 2.34 | 0.41 | 5.48 |
| <i>QSR</i> | 2.21 | 2.12 | 1.81 | 4.10 | 2.92 | 0.97 | 2.29 | 2.34 | 0.43 | 0.01 | 0.96 |
| <i>DSR</i> | 2.11 | 1.93 | 1.50 | 3.79 | 2.96 | 0.72 | 3.49 | 2.79 | 0.92 | 0.01 | 0.91 |
| <i>MSR</i> | 2.51 | 2.33 | 2.12 | 3.52 | 2.37 | 1.02 | 0.90 | 1.45 | 0.16 | 3.13 | 0.99 |
| <i>ASR</i> | 3.03 | 2.49 | 2.30 | 3.16 | 2.11 | 0.84 | 1.20 | 1.34 | 0.22 | 1.46 | 1.24 |
| <i>Zenga</i> | 4.19 | 2.88 | 2.55 | 3.90 | 2.61 | 0.89 | 2.08 | 1.80 | 0.35 | 1.34 | 6.33 |
| $GE_{1/2}$ | 2.32 | 2.22 | 1.69 | 2.17 | 1.52 | 0.55 | 0.98 | 1.02 | 0.50 | 0.49 | 4.13 |
| <i>T</i> | 1.71 | 1.59 | 1.21 | 0.99 | 0.68 | 0.31 | 0.31 | 0.38 | 0.10 | 0.34 | 4.74 |
| GE_2 | 0.47 | 0.39 | 0.34 | 0.14 | 0.12 | 0.07 | 0.01 | 0.03 | 0.01 | 0.06 | 3.77 |
| $R_{1/2}$ | 2.28 | 2.16 | 1.67 | 2.14 | 1.50 | 0.54 | 0.96 | 1.01 | 0.50 | 0.48 | 3.00 |
| R_2 | 1.18 | 1.03 | 0.73 | 0.32 | 0.23 | 0.14 | 0.05 | 0.08 | 0.01 | 0.14 | 8.45 |
| <i>IQR</i> | 0.00 | 0.01 | 0.38 | 3.43 | 2.27 | 0.95 | 0.00 | 1.39 | 0.01 | 0.01 | 0.00 |
| <i>IDR</i> | 0.08 | 0.01 | 0.71 | 3.72 | 2.59 | 0.84 | 0.84 | 2.25 | 0.00 | 0.01 | 0.01 |
| <i>MQR</i> | 0.12 | 0.06 | 0.45 | 4.70 | 3.06 | 1.18 | 0.77 | 2.03 | 0.14 | 5.97 | 0.00 |

- Robustesse :
 - Performance vs robustesse.
 - Importance des mesures basées sur les quantiles et les *quantile shares*.
- Trois types de mesures détectent mal les changements :
 - Indices basés sur l'entropie.
 - Rapports simples de quantiles.
 - Coefficient de variation.
- Bonne performance des indices basés sur les *quantile shares*.

- Les indices les plus performants :
 - **Zenga** : très polyvalent, mais très sensible aux valeurs extrêmes.
 - **Atkinson** ($\alpha = 1$) : peu robuste et problème des revenus nuls.
 - **ASR** : meilleure mesure basée sur les quantile shares (robuste).
- Globalement, les indicateurs de Laeken (Gini et *QSR*) donnent des résultats plutôt acceptables, surtout *QSR*.
- Pour des mesures basées sur les queues de distribution, *QSR* et *DSR* se montrent performants et robustes.
- *MQR* est dans l'ensemble la meilleure mesure construite sur les rapports simples de quantiles.

- Compromis performance / robustesse.
- Importance des mesures utilisant les *quantile shares*.
- Importance des mesures nouvelles (*ASR*, *MQR*) ou récentes (*Zenga*).
- Perspectives : estimation dans des plans de sondage complexes.