

Économétrie II
Ch. 3. Hétéroscédasticité
L3 Économétrie – L3 MASS

Prof. Philippe Polomé, U. Lyon 2

Année 2016-2016

Rappel

1. $E(\epsilon_i) = 0 \forall i$: **Espérance nulle**
2. $\text{var}(\epsilon_i) = \sigma^2 \forall i$: **Homoscédasticité**
3. $\text{cov}(\epsilon_t, \epsilon_s) = 0 \forall t \neq s$: **Pas d'auto-corrélation**
4. $E(\epsilon_i x_i) = 0 \forall i$: **Exogénéité**
5. ✓ La matrice X est de plein rang : **Pas de multicolinéarité**
6. Le modèle est **correctement spécifié**
7. La variable dépendante Y est **continue**

Table des matières

Ch. 3. $\exists i : \text{var}(\epsilon_i) = \sigma_i^2$: Hétéroscédasticité

Définition

Sources

Conséquences

Estimer la matrice de variance-covariance

Moindres carrés pondérés “Weighted Least Squares”

Tests

Table des matières

Ch. 3. $\exists i : \text{var}(\epsilon_i) = \sigma_i^2$: Hétéroscédasticité

Définition

Sources

Conséquences

Estimer la matrice de variance-covariance

Moindres carrés pondérés “Weighted Least Squares”

Tests

Définition du problème

- ▶ L'hypothèse d'**homoscédasticité** requiert que la variance des termes d'erreur soit la **même** pour chaque observation
- ▶ Il y a hétéroscédasticité dans le modèle $Y = X\beta + \epsilon$ lorsque :

$$\text{var}(\epsilon) = E(\epsilon\epsilon') = \Sigma_\epsilon = \begin{bmatrix} \sigma_1^2 & & & 0 \\ & \sigma_2^2 & & \\ & & \dots & \\ 0 & & & \sigma_N^2 \end{bmatrix} \neq \sigma^2 I_N$$

Représentation graphique




Table des matières

Ch. 3. $\exists i : \text{var}(\epsilon_i) = \sigma_i^2$: Hétéroscédasticité

Définition

Sources

Conséquences

Estimer la matrice de variance-covariance

Moindres carrés pondérés “Weighted Least Squares”

Tests

Données en moyenne

- ▶ S'il y a homoscedasticité dans les données de départ, les données en moyenne seront hétéroscédastiques
 - ▶ y_{it} avec $\text{var}(y_{it}) = 1 \forall i, t$
- ▶ Mais on ne dispose que des moyennes $\frac{1}{T_g} \sum_t y_{it} = y_i$ où T_g est la taille du groupe
 - ▶ Par ex : des moyennes régionales de données individuelles
 - ▶ $\text{var}(y_i) = \frac{1}{T_g^2} \text{var}(\sum_t y_{it}) = \frac{1}{T_g^2} \sum_t \text{var}(y_{it}) = \frac{T_g}{T_g^2} = \frac{1}{T_g}$: dépend de la taille du groupe

Modèle à “coefficients aléatoires”

- ▶ Si le modèle sous-jacent est $Y_i = \alpha + (\beta + \mu_i)x_i + \epsilon_i$
 - ▶ Par ex. effet de l'éducation sur le salaire
- ▶ Alors $Y_i = \alpha + \beta x_i + \mu_i x_i + \epsilon_i = \alpha + \beta x_i + \eta_i$
- ▶ Et, avec des termes d'erreurs ϵ_i et μ_i homoscedastiques et indépendant et un régresseur x_i non-stochastique, on trouve
 - ▶ $\text{var}(\eta_i) = \sigma_\epsilon^2 + \sigma_\mu^2 x_i$ hétéroscédastique
- ▶ Semblable au cas suivant

Régresseur manquant hétéroscédastique

- ▶ Si le modèle sous-jacent est $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \epsilon_i$
- ▶ Mais le modèle estimé est $y_i = \beta_0 + \beta_1 x_{1i} + \mu_i$
- ▶ Alors $\mu_i = \beta_2 x_{2i} + \epsilon_i$ donc,
 - ▶ si x_{2i} n'est pas corrélé à ϵ_i , $\text{var}(\mu_i) = \beta_2^2 \text{var}(x_{2i}) + \sigma^2$
 - ▶ si x_{2i} n'est pas stochastique (analyse conditionnelle),
 $\text{var}(\mu_i) = \beta_2^2 x_{2i} + \sigma^2$
- ▶ Hétéroscédastique sauf cas particulier

Effet taille

- ▶ La variance est une mesure absolue, pas relative
 - ▶ Imaginons que le CA de toutes les entreprises varie de 10%
 - ▶ 10% est un grand nombre pour une grande entreprise
- ▶ Part du revenu disponible dépensé en loisirs
 - ▶ Les familles à faibles revenus dépensent relativement peu en loisirs. Les variations de ces dépenses entre ces familles sont donc faibles
 - ▶ Pour les familles avec des revenus importants, le montant moyen relatif dépensé en loisirs sera plus élevé, et il y aura une plus grande variabilité entre de telles familles

Variables explicatives de la variance

- ▶ Un régresseur définit des **groupes** de variances différentes dans la variable expliquée
- ▶ Ex. Rendement de l'éducation
 - ▶ **variance** en productivité propre inobservable ϵ diffère selon les niveaux h d'éducation atteints
 - ▶ $\ln(\text{ salaire}_i) = \alpha + \gamma \text{ education}_h + X_i \beta + \epsilon_i$
 - ▶ avec $i \in h$ et $\text{var}(\epsilon_i) = \sigma_h^2 = \text{fonction}(\text{ education}_h)$
 - ▶ Similaire à l'effet taille
 - ▶ Faible éducation : salaire proche du minimum
- ▶ Également :
 - ▶ Qualité inobservée d'un bien par niveau de prix
 - ▶ Taux d'épargne par niveau de revenu

Table des matières

Ch. 3. $\exists i : \text{var}(\epsilon_i) = \sigma_i^2$: Hétéroscédasticité

Définition

Sources

Conséquences

Estimer la matrice de variance-covariance

Moindres carrés pondérés “Weighted Least Squares”

Tests

Propriétés de $\hat{\beta}$

- ▶ MCO restent **sans biais** (X non-stochastique par facilité)

$$E(\hat{\beta}) = E\left(\left(X'X\right)^{-1} X' (X\beta + \epsilon)\right) = \beta + \left(X'X\right)^{-1} X' E(\epsilon) = \beta$$

- ▶ MCO **consistants** / convergents (sans démonstration)
- ▶ Matrice de variance-covariance des coefficients estimés n'est plus $\sigma^2 \left(X'X\right)^{-1}$, mais bien (**sandwich**)

$$\begin{aligned} \Sigma_{\hat{\beta}} &= E\left(\left(\hat{\beta} - \beta\right) \left(\hat{\beta} - \beta\right)'\right) = \left(X'X\right)^{-1} X' E\left(\epsilon\epsilon'\right) X \left(X'X\right)^{-1} \\ &= \left(X'X\right)^{-1} X' \Sigma_{\epsilon} X \left(X'X\right)^{-1} \end{aligned}$$

- ▶ Théorème de Gauss-Markov ne s'applique plus
 - ▶ MCO n'est plus **efficace**

Inférence

- ▶ Estimateur MCO $\frac{\hat{\epsilon}'\hat{\epsilon}}{N-k} (X'X)^{-1}$ est **biaisé** pour $\Sigma_{\hat{\beta}}$
 - ▶ Tests d'hypothèse usuels post-estimation (t-stat, F-stat ou LM) **invalides** dans leur forme classique
 - ▶ Le bootstrap reste par contre valide
 - ▶ asymptotiquement comme toujours
- ▶ Comment faire face à ces conséquences ? 2 approches
 - ▶ Estimer $\Sigma_{\hat{\beta}}$ à partir de MCO & refaire l'inférence
 - ▶ Proposer un estimateur **alternatif**
 - ▶ Moindres Carrés Pondérés
 - ▶ Vise à récupérer l'efficience

Table des matières

Ch. 3. $\exists i : \text{var}(\epsilon_i) = \sigma_i^2$: Hétéroscédasticité

Définition

Sources

Conséquences

Estimer la matrice de variance-covariance

Moindres carrés pondérés "Weighted Least Squares"

Tests

Estimateur robuste White (1980)

- ▶ On sait $\Sigma_{\hat{\beta}} = (X'X)^{-1} X' \Sigma_{\epsilon} X (X'X)^{-1}$ **sandwich**
- ▶ Sauf cas particulier, Σ_{ϵ} inconnue
- ▶ White : Pour obtenir un estimateur de $\Sigma_{\hat{\beta}}$, il suffit d'un estimateur de $X' \Sigma_{\epsilon} X$ (et pas de Σ_{ϵ})
- ▶ Sous des conditions très générales, $S = \frac{1}{N} \sum_{i=1}^N \hat{\epsilon}_i^2 X_i X_i'$ est un estimateur consistant de $\frac{1}{N} X' \Sigma_{\epsilon} X$
 - ▶ $\hat{\epsilon}_i = y_i - X_i' \hat{\beta}_{MCO}$ résidu MCO i
 - ▶ X_i vecteur-colonne correspondant à l'observation i de X
 - ▶ Donc $X_i X_i'$ est bien $k \times k$
- ▶ Expliciter la matrice $X' \Sigma_{\epsilon} X$: intuition estimateur de White

La matrice $X' \Sigma_{\epsilon} X_{k \times k}$

$$\begin{aligned}
 &= \begin{bmatrix} x_{11} & x_{21} & \dots & x_{N1} \\ x_{12} & x_{22} & \dots & x_{N2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1k} & x_{2k} & \dots & x_{Nk} \end{bmatrix} \begin{bmatrix} \sigma_1^2 & & & 0 \\ & \sigma_2^2 & & \\ & & \ddots & \\ 0 & & & \sigma_N^2 \end{bmatrix} \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1k} \\ x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nk} \end{bmatrix} \\
 &= \begin{bmatrix} \sigma_1^2 x_{11} & \sigma_2^2 x_{21} & \dots & \sigma_N^2 x_{N1} \\ \sigma_1^2 x_{12} & \sigma_2^2 x_{22} & \dots & \sigma_N^2 x_{N2} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_1^2 x_{1k} & \sigma_2^2 x_{2k} & \dots & \sigma_N^2 x_{Nk} \end{bmatrix} \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1k} \\ x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nk} \end{bmatrix}
 \end{aligned}$$

La matrice $X' \Sigma_{\epsilon} X_{k \times k}$

$$= \begin{bmatrix} \sum_{i=1}^N \sigma_i^2 x_{i1}^2 & \sum_{i=1}^N \sigma_i^2 x_{i1} x_{i2} & \dots & \sum_{i=1}^N \sigma_i^2 x_{i1} x_{ik} \\ & \sum_{i=1}^N \sigma_i^2 x_{i2}^2 & \dots & \sum_{i=1}^N \sigma_i^2 x_{i2} x_{ik} \\ & & \ddots & \vdots \\ \text{sym} & & & \sum_{i=1}^N \sigma_i^2 x_{ik}^2 \end{bmatrix}$$

Comparer avec $S = \frac{1}{N} \sum_{i=1}^N \hat{\epsilon}_i^2 X_i X_i'$

Matrice de variance-covariance “robuste”

- ▶ $\hat{\Sigma}_{\hat{\beta}} = N (X'X)^{-1} S (X'X)^{-1}$ consistant pour $\Sigma_{\hat{\beta}}$
 - ▶ Peut-être utilisé pour tests usuels post-estimation
- ▶ Écart-types issus de White : “robustes à l’hétéroscédasticité”
 - ▶ Suggestion : corriger la matrice de White par $n/(n - k - 1)$
 - ▶ Lorsque $n \rightarrow \infty$ les deux approches sont équivalentes
- ▶ L’estimateur de White est seulement consistant
 - ▶ Pas sans biais
 - ▶ Valable seulement asymptotiquement
 - ▶ Sur échantillons de petite taille
 - ▶ t de Student “de White” n’ont pas une distribution proche du t
 - ▶ Tests ont peu de puissance
 - ▶ Utile de voir si Bootstrap mène aux mêmes résultats

Matrice de White : logiciels

- ▶ La correction par la matrice de White est pré-programmée sur tous les logiciels d'économétrie.
 - ▶ Sous Gretl, cocher une case dans la boîte de dialogue d'estimation
 - ▶ Plusieurs variantes à la correction de White, manuel de Gretl pour les détails
- ▶ Dans GRETL
 - ▶ Prenez les données [hprice1.gdt](#) dans Gretl Wooldridge
 - ▶ Régressez *lprice* sur *llotsize*, *lsqrft*, *bdrms*, *colonial*
 - ▶ Pour obtenir l'estimation "robuste" des t-stats
 - ▶ Cocher "erreurs standards robustes" (la constante n'est plus significative)

Table des matières

Ch. 3. $\exists i : \text{var}(\epsilon_i) = \sigma_i^2$: Hétéroscédasticité

Définition

Sources

Conséquences

Estimer la matrice de variance-covariance

Moindres carrés pondérés "Weighted Least Squares"

Tests

Moindres carrés pondérés "Weighted Least Squares"

- ▶ Approche alternative à celle de White pour traiter l'hétéroscédasticité
 - ▶ + ancienne
- ▶ Disposer d'informations supplémentaires sur la forme de l'hétéroscédasticité rencontrée permet toujours de dériver un estimateur **plus efficient** que celui donné par l'estimation "robuste"
 - ▶ Donc si on connaît la forme de l'hétéroscédasticité, on devrait pouvoir obtenir un gain en efficience
- ▶ L'idée générale est de transformer les données de sorte à ce que les erreurs deviennent homoscedastiques

Forme de l'hétéroscédasticité connue à une constante près

- ▶ Supposons que l'hétéroscédasticité puisse être modélisée sous la forme $\text{var}(\epsilon|X) = \sigma^2 h(X)$

- ▶ On peut alors écrire $\Sigma_\epsilon = \sigma^2 \begin{pmatrix} h_1 & 0 & \dots & 0 \\ 0 & h_2 & & \vdots \\ \vdots & & \ddots & \\ 0 & \dots & & h_N \end{pmatrix} = \sigma^2 \Psi$

avec $h_i = h(X_i) > 0$

- ▶ Si on réécrit le modèle $Y = X\beta + \epsilon$
 - ▶ sous la forme $\frac{Y_i}{\sqrt{h_i}} = \frac{X_i}{\sqrt{h_i}}\beta + \frac{\epsilon_i}{\sqrt{h_i}}$
 - ▶ alors le terme d'erreur est homoscedastique

Remarque

- ▶ Le résidu MCP est $\hat{\epsilon}^* = Y^* - X^* \hat{\beta}_{MCP}$
- ▶ Le but de MCP est minimiser la \sum des carrés des résidus sur les données **transformées** :
$$\begin{aligned} \min \hat{\epsilon}^{*'} \hat{\epsilon}^* &= \min \sum_i \left(Y_i^* - X_i^* \hat{\beta}_{MCP} \right)^2 \\ &= \min \sum_i \left(\frac{Y_i}{\sqrt{h_i}} - \frac{X_i}{\sqrt{h_i}} \hat{\beta}_{MCP} \right)^2 \\ &= \min \sum_i \left(Y_i - X_i \hat{\beta}_{MCP} \right)^2 / h_i \end{aligned}$$
- ▶ Chaque observation est **pondérée** par l'inverse de sa variance
 - ▶ Plus une observation a une variance élevée, moins elle **pèse** dans la somme des carrés des résidus
 - ▶ La qualité de l'ajustement (R^2) aux données originales n'est donc plus recherchée : R^2 n'est **plus une mesure intéressante**

MCP en pratique

- ▶ Il faut connaître la forme de l'hétéroscédasticité
- ▶ Dans la plupart des cas on ne sait rien sur cette forme
- ▶ Il faut donc un estimateur de $h(X)$ ou éventuellement d'autres formes $h(X, Z)$
 - ▶ Moindres Carrés Pondérés **Faisables** / *Feasible Weighted Least Squares*

MCP Faisable

- ▶ On suppose une forme simple de type

$$h(X_i) = \exp(\delta_0 + \delta_1 x_{1i} + \delta_2 x_{2i} + \dots)$$
 - ▶ exp garanti la positivité
 - ▶ $\text{var}(\epsilon_i | X_i) = \sigma^2 \exp(\delta_0 + \delta_1 x_{1i} + \delta_2 x_{2i} + \dots)$
- ▶ Comme MCO est sans biais en présence d'hétéroscédasticité, $\hat{\epsilon}_i^2$ peut être vu comme une estimation de $\text{var}(\epsilon_i | X_i)$
 - ▶ $\hat{\epsilon}_i^2 = \sigma^2 \exp(\delta_0 + \delta_1 x_{1i} + \delta_2 x_{2i} + \dots) \nu_i$; ν_i terme d'erreur
- ▶ Estimer $\ln(\hat{\epsilon}_i^2) = \alpha_0 + \delta_1 x_{1i} + \delta_2 x_{2i} + \dots + \ln(\nu_i)$ par MCO
 - ▶ On peut rajouter des régresseurs $Z \not\subseteq X$ dans cette équation
- ▶ Estimation de h_i : $\hat{h}_i = \exp\left(\hat{\alpha}_0 + \hat{\delta}_1 x_{1i} + \hat{\delta}_2 x_{2i} + \dots + \frac{1}{2} \hat{\sigma}_\nu^2\right)$
 - ▶ Il faut ajouter un terme en variance au carré parce que exp est non-linéaire (Verbeek) – sans démonstration

Mise en garde sur les MCP faisables

- ▶ Dans le doute sur la présence et la forme de l'hétéroscédasticité
 - ▶ il peut être tentant de prendre une forme usuelle et d'appliquer les MCP
 - ▶ D'autant plus tentant si le logiciel utilisé propose une procédure simple
- ▶ Mais
 - ▶ Si les termes d'erreurs sont homoscedastiques au départ,
 - ▶ l'estimateur des **MCPF pourra être biaisé et inconsistant**
 - ▶ Par monte-carlo, on voit que ce sont des configurations peu courantes
 - ▶ Si l'hétéroscédasticité dépend d'une variable inconnue,
 - ▶ ou ne dépend pas d'une variable,
 - ▶ il peut être difficile d'apporter une correction significative

Comparaison des deux approches

▶ Approche 1 : MCP

- ▶ $\hat{\beta}_{MCP} \neq \hat{\beta}_{MCO}$

- ▶ Approche historique, en principe meilleure que MCO

- ▶ Si l'hyp sur forme de l'hétéroscédasticité est correcte

- ▶ Permet alors un gain d'efficacité

- ▶ Mais risques l'hyp est fautive

▶ Approche 2 : $\widehat{\text{var}}(\hat{\beta}_{MCO})$ robuste

- ▶ On garde les $\hat{\beta}_{MCO}$

- ▶ 2.a. White : basé sur un résultat plus récent (1980) que MCP ; requiert une plus grande puissance de calcul

- ▶ 2.b. bootstrap : puissance de calcul encore plus grande

- ▶ 2.a et 2.b : pas d'hypothèses supplémentaires par rapport à MCO mais seulement valables pour de grands échantillons

- ▶ Évite de tester l'hétéroscédasticité

- ▶ et de chercher quelle forme elle pourrait prendre

- ▶ Renonce au gain potentiel d'efficacité

Importance de l'hétéroscédasticité en pratique

- ▶ L'hétéroscédasticité est la norme avec les données micro en coupe transversale
 - ▶ L'homoscédasticité est l'exception
 - ▶ On va habituellement utiliser White / bootstrap
 - ▶ Plus rarement MCP / MCG
- ▶ Pas aussi évident pour les séries temporelles
 - ▶ Car c'est toujours la même unité qui est observée
 - ▶ White est aussi disponible
 - ▶ Mais existence de modèles alternatifs propres

Exemple dans Gretl

- ▶ Prenez les données [hprice1.gdt](#) dans Gretl Wooldridge
- ▶ Régressez *lprice* sur *llotsize*, *lsqrft*, *bdrms*, *colonial*
- ▶ Moindres Carrés Pondérés : "Modèle" – "autres modèles linéaires" – "MCP"
 - ▶ Un seul régresseur est associé à l'hét.
 - ▶ Une façon alternative est "Hétéroscédasticité corrigée" qui impose une correction "à la White"
 - ▶ c'est-à-dire : l'hét. est approximée à partir d'une regression contenant les régresseurs et leurs carrés
 - ▶ comme dans le test de White (plus loin)

Table des matières

Ch. 3. $\exists i : \text{var}(\epsilon_i) = \sigma_i^2$: Hétéroscédasticité

Définition

Sources

Conséquences

Estimer la matrice de variance-covariance

Moindres carrés pondérés “Weighted Least Squares”

Tests

Principe des tests d'hétéroscédasticité

- ▶ On n'observe jamais les vrais termes d'erreur.
- ▶ On les "estime" à partir des résidus de la régression par MCO $\hat{\epsilon}_i$
 - ▶ "car" MCO sans biais en présence d'hétéroscédasticité
- ▶ 3 tests populaires
 - ▶ Breusch-Pagan
 - ▶ White
 - ▶ Goldfeld-Quandt

Test de Breusch-Pagan

- ▶ On veut tester $H_0 : \text{var}(\epsilon_i | x_{1i}, \dots, x_{ki}) = \sigma^2 \forall i$
 - ▶ Equivalent à tester $H_0 : E(\epsilon_i^2 | x_{1i}, \dots, x_{ki}) = \sigma^2 \forall i$ car $E(\epsilon) = 0$
- ▶ Si on suppose que la relation entre ϵ_i^2 et X_i est suffisamment proche du linéaire
 - ▶ $\epsilon_i^2 = \delta_0 + \delta_1 x_{1i} + \dots + \delta_k x_{ki} + \nu$
 - ▶ Alors tester H_0 revient à tester $H_0 : \delta_1 = \delta_2 = \dots = \delta_k = 0$
- ▶ Régresser carré des résidus $\hat{\epsilon}_i^2$ sur toutes les variables explicatives X
 - ▶ Tester significativité globale via la procédure habituelle (F-test ou LM-test)

Test de White

- ▶ Test de Breusch-Pagan permet de détecter les formes linéaires d'hétéroscédasticité
- ▶ Test de White permet de prendre en compte certaines non-linéarités en utilisant les carrés et les produits croisés de toutes les variables explicatives
 - ▶ Même procédure que Breusch-Pagan
 - ▶ En introduisant tous les x_j^2 et les $x_j x_m$
 - ▶ Et en testant que les paramètres associés sont conjointement significatifs (F-test ou LM-test)
 - ▶ Rapidement : nombre de paramètres à estimer impraticable...
 - ▶ En proba (5%) erreur type I : $\neg R H_0$ fréquente

Forme alternative du test de White

- ▶ Les valeurs ajustées $\hat{y}_i = X_i\hat{\beta}$ sont fonction de toutes les X
 - ▶ \hat{y}^2 est une fonction des carrés x_j^2 et des produits croisés x_jx_m
 - ▶ \hat{y}^2 peut être utilisé pour représenter les non-linéarités
 - ▶ On peut utiliser \hat{y} pour représenter tous les X à la fois
- ▶ Procédure
 1. Régresser le carré des résidus MCO $\hat{\epsilon}_i^2$ sur les valeurs ajustées \hat{y}_i et \hat{y}_i^2
 2. F-test ou un LM-test sur la significativité globale de cette régression
- ▶ On ne teste plus que les coef. de ces 2 paramètres
- ▶ Ce test repose sur une hypothèse forte concernant la forme de l'hétéroscédasticité
 - ▶ Celle-ci est fonction des variables incluses
 - ▶ N'impose pas la linéarité de cette forme (on peut étendre aux cubes...)

Test de Goldfeld-Quandt

- ▶ Dans le cas où la théorie permet d'envisager une hétéroscédasticité causée par une seule explicative x_m
- 1. Trier les observations par les valeurs de la variable explicative soupçonnée source d'hétéroscédasticité
 - ▶ et donc corrélée avec $\hat{\epsilon}_i^2$
- 2. Supprimer la partie des données triées qui se trouve au milieu de l'échantillon
 - ▶ entre $1/3$ et $1/5$ des données
- 3. Estimations séparées (MCO) sur les deux sous échantillons : hautes et basses valeurs de x_m
- 4. Les rapport des variances estimées des termes d'erreur des deux régressions suit une distribution de Fisher
 - ▶ $GQ = \frac{\hat{\sigma}_1^2}{\hat{\sigma}_2^2} \sim F_{N_1-K, N_2-K}$
 - ▶ $N_1 - K =$ nombre de degrés de liberté de la 1ère régression

Exemple dans Gretl

- ▶ Prenez les données [hprice1.gdt](#) dans Gretl Wooldridge
- ▶ Régressez *lprice* sur *llotsize*, *lsqft*, *bdrms*, *colonial*
- ▶ Pour tester : MCO puis post-estimation
 - ▶ Gretl propose 2 tests : White (1^o forme), Breusch-Pagan, mais pas Goldfeld-Quandt
 - ▶ Breusch-Pagan R homoscedasticité
 - ▶ White (1^o forme) $\rightarrow R$
 - ▶ Difficile de conclure

Devoir #3 Hétéroscédasticité

Conception d'une feuille de tableur pour montrer l'effet de **l'hétéroscédasticité** sur les coefficients estimés dans une régression linéaire MCO à deux variables x_1 et x_2 et une constante.

1. Générer le terme d'erreur ϵ_i ; par exemple pour chaque observation i , générer d'abord un nombre aléatoire $\alpha_i \in [1, 10]$, puis générer $\epsilon_i = \alpha_i n(0, 1)$
2. Illustrer que les MCO sont inconsistants ou non lorsqu'il y a hétéroscédasticité
3. Employer la formule classique de calcul de la matrice de variance-covariance des estimations MCO
 - 3.1 (pour les plus motivés) Montrer que la diagonale de cette matrice ne s'approche pas des variances des coefficients estimés en Monte-Carlo