

# Économétrie

## Hétéroscédasticité

Stéphane Adjemian

[stephane.adjemian@univ-lemans.fr](mailto:stephane.adjemian@univ-lemans.fr)

Novembre 2025

# Le modèle linéaire classique

Considérons le modèle de régression linéaire :

$$Y_i = X_i' \beta + \varepsilon_i, \quad i = 1, \dots, n$$

## Hypothèses classiques :

- ▶  $\mathbb{E}[\varepsilon_i | X_i] = 0$  (exogénéité)
- ▶  $\text{Var}(\varepsilon_i | X_i) = \sigma^2$  (homoscédasticité)
- ▶  $\text{Cov}(\varepsilon_i, \varepsilon_j | X_i, X_j) = 0$  pour  $i \neq j$  (absence d'autocorrélation)

# Qu'est-ce que l'hétéroscédasticité ?

**Définition :** L'hétéroscédasticité se produit lorsque la variance des erreurs n'est pas constante :

$$\text{Var}(\varepsilon_i | X_i) = \sigma_i^2 \neq \sigma^2$$

**Conséquences :**

- ▶ Les estimateurs MCO restent **sans biais** et **convergents**
- ▶ Mais ils ne sont plus **efficients** (BLUE)
- ▶ Les écarts-types usuels sont **biaisés**
- ▶ Les tests de Student et de Fisher sont **invalides**

# Illustration graphique

## Homoscédasticité vs Hétéroscléasticité

### Homoscédasticité

Variance constante  $\sigma^2$

Nuage de points avec dispersion uniforme autour de la droite de régression

### Hétéroscléasticité

Variance  $\sigma_i^2$  variable

Dispersion croissante (ou décroissante) le long de la droite

# Préliminaires pour les démonstrations

## Hypothèses générales :

1.  $\mathbb{E}[\varepsilon_i | X_i] = 0$
2. Sous  $H_0$  :  $\text{Var}(\varepsilon_i | X_i) = \sigma^2$
3. Les observations sont i.i.d.
4.  $\mathbb{E}[X_i X_i']$  existe et est définie positive

## Estimateur MCO :

$$\hat{\beta} = \left( \sum_{i=1}^n X_i X_i' \right)^{-1} \sum_{i=1}^n X_i Y_i$$

## Résidus MCO :

$$\hat{\varepsilon}_i = Y_i - X_i' \hat{\beta} = \varepsilon_i - X_i' (\hat{\beta} - \beta)$$

# Test de Breusch-Pagan : Principe

**Idée :** Tester si la variance des résidus est liée aux variables explicatives.

**Hypothèses :**

- ▶  $H_0 : \sigma_i^2 = \sigma^2$  (homoscédasticité)
- ▶  $H_1 : \sigma_i^2 = h(Z'_i \alpha)$  où  $Z_i$  contient les régresseurs

**Forme spécifique :**

$$\sigma_i^2 = \alpha_0 + \alpha_1 Z_{i1} + \cdots + \alpha_p Z_{ip}$$

# Test de Breusch-Pagan : Procédure

## Étapes :

1. Estimer le modèle par MCO et obtenir les résidus  $\hat{\varepsilon}_i$
2. Calculer les résidus au carré  $\hat{\varepsilon}_i^2$
3. Régresser  $\hat{\varepsilon}_i^2$  sur  $Z_i$  (généralement  $Z_i = X_i$ ) :

$$\hat{\varepsilon}_i^2 = \alpha_0 + \alpha_1 Z_{i1} + \cdots + \alpha_p Z_{ip} + u_i$$

4. Récupérer le  $R^2$  de cette régression auxiliaire
5. Calculer la statistique de test :

$$LM = n \cdot R^2 \xrightarrow{H_0} \chi_p^2$$

# Test de Breusch-Pagan : Décision

## Règle de décision :

- ▶ On rejette  $H_0$  si  $LM > \chi^2_{p,\alpha}$  (valeur critique)
- ▶ Ou si la p-valeur  $< \alpha$  (seuil de significativité)

## Avantages :

- ▶ Simple à mettre en œuvre
- ▶ Test basé sur le multiplicateur de Lagrange

## Limites :

- ▶ Suppose une forme spécifique pour  $\sigma_i^2$
- ▶ Sensible aux hypothèses de normalité

# Démonstration Breusch-Pagan (1/4)

**Modèle de variance :**

$$\sigma_i^2 = Z_i' \alpha$$

où  $Z_i$  contient les variables explicatives (souvent  $Z_i = X_i$ ).

**Hypothèses :**

- ▶  $H_0 : \alpha_1 = \cdots = \alpha_p = 0$  (seul  $\alpha_0 = \sigma^2$ )
- ▶  $H_1 : \text{au moins un } \alpha_j \neq 0 \text{ pour } j \geq 1$

**Régression auxiliaire :**

$$\hat{\varepsilon}_i^2 = Z_i' \hat{\alpha} + u_i$$

## Démonstration Breusch-Pagan (2/4)

### Étape 1 : Résidus MCO

Les résidus MCO vérifient :

$$\hat{\varepsilon}_i = \varepsilon_i - X_i'(\hat{\beta} - \beta)$$

Sous  $H_0$  et par le TCL :

$$\sqrt{n}(\hat{\beta} - \beta) \xrightarrow{d} \mathcal{N}(0, \sigma^2 Q^{-1})$$

où  $Q = \mathbb{E}[X_i X_i']$ .

Donc :

$$\hat{\varepsilon}_i^2 = \varepsilon_i^2 - 2\varepsilon_i X_i'(\hat{\beta} - \beta) + O_p(n^{-1})$$

## Démonstration Breusch-Pagan (3/4)

### Étape 2 : Régression auxiliaire

La somme des carrés expliquée de la régression de  $\hat{\varepsilon}_i^2$  sur  $Z_i$  est :

$$SCE = \hat{\alpha}' \sum_{i=1}^n Z_i Z_i' \hat{\alpha}$$

où  $\hat{\alpha}$  est l'estimateur MCO de la régression auxiliaire.

Sous  $H_0 : \mathbb{E}[\hat{\varepsilon}_i^2] = \sigma^2$  et :

$$\hat{\alpha} \approx \left( \sum_{i=1}^n Z_i Z_i' \right)^{-1} \sum_{i=1}^n Z_i (\varepsilon_i^2 - \sigma^2)$$

## Démonstration Breusch-Pagan (4/4)

### Étape 3 : Distribution asymptotique

Par le TCL, sous  $H_0$  :

$$\frac{1}{\sqrt{n}} \sum_{i=1}^n Z_i(\varepsilon_i^2 - \sigma^2) \xrightarrow{d} \mathcal{N}(0, \Omega)$$

où  $\Omega = \text{Var}(Z_i(\varepsilon_i^2 - \sigma^2))$ .

La statistique  $nR^2$  de la régression auxiliaire vérifie :

$$LM = n \cdot R^2 = \frac{SCE}{\hat{\sigma}^4} \xrightarrow{d} \chi_p^2$$

où  $p$  est le nombre de régresseurs dans  $Z_i$  (hors constante).

**Conclusion :** Sous  $H_0$ ,  $LM \sim \chi_p^2$  asymptotiquement.

## Test de White : Principe

**Idée :** Version plus générale du test de Breusch-Pagan, sans spécifier de forme fonctionnelle.

**Hypothèses :**

- ▶  $H_0$  : Homoscédasticité
- ▶  $H_1$  : Toute forme d'hétéroscédisticité

**Caractéristique :** Utilise tous les régresseurs, leurs carrés et leurs produits croisés.

# Test de White : Procédure

## Étapes :

1. Estimer le modèle par MCO :  $Y = X\beta + \varepsilon$
2. Calculer les résidus  $\hat{\varepsilon}_i$  et leurs carrés  $\hat{\varepsilon}_i^2$
3. Régresser  $\hat{\varepsilon}_i^2$  sur :
  - ▶ Tous les régresseurs  $X_{ij}$
  - ▶ Leurs carrés  $X_{ij}^2$
  - ▶ Leurs produits croisés  $X_{ij}X_{ik}$  pour  $j \neq k$
4. Obtenir le  $R^2$  de cette régression auxiliaire
5. Calculer :

$$W = n \cdot R^2 \xrightarrow{H_0} \chi_q^2$$

où  $q$  est le nombre de régresseurs dans la régression auxiliaire (moins 1)

# Test de White : Décision et remarques

## Règle de décision :

- ▶ Rejeter  $H_0$  si  $W > \chi^2_{q,\alpha}$  ou si p-valeur <  $\alpha$

## Avantages :

- ▶ Ne suppose aucune forme spécifique pour l'hétéroscédasticité
- ▶ Test très général et robuste

## Limites :

- ▶ Peut inclure beaucoup de régresseurs (problème si  $n$  petit)
- ▶ Perte de degrés de liberté
- ▶ Possibilité de multicolinéarité dans la régression auxiliaire

# Démonstration Test de White (1/3)

## Principe du test :

Le test de White est une extension du test de Breusch-Pagan sans hypothèse spécifique sur la forme de l'hétéroscédasticité.

## Régression auxiliaire :

$$\hat{\varepsilon}_i^2 = \gamma_0 + \sum_{j=1}^k \gamma_j X_{ij} + \sum_{j=1}^k \gamma_{jj} X_{ij}^2 + \sum_{j < \ell} \gamma_{j\ell} X_{ij} X_{i\ell} + u_i$$

Le vecteur  $\gamma$  contient tous les coefficients à tester.

## Hypothèses :

- ▶  $H_0 : \gamma_j = 0$  pour tout  $j \geq 1$
- ▶  $H_1 : \text{au moins un } \gamma_j \neq 0$

## Démonstration Test de White (2/3)

### Étape 1 : Développement de Taylor

Sous une forme générale d'hétéroscléasticité :

$$\sigma_i^2 = h(X_i)$$

On peut approximer  $h$  par un développement de Taylor du second ordre :

$$h(X_i) \approx h(0) + \nabla h(0)'X_i + \frac{1}{2}X_i'H(0)X_i$$

où  $H(0)$  est la matrice hessienne en 0.

Cela justifie l'inclusion des termes quadratiques et croisés dans la régression auxiliaire.

## Démonstration Test de White (3/3)

### Étape 2 : Distribution asymptotique

Soit  $W_i$  le vecteur contenant  $(1, X_{i1}, \dots, X_{ik}, X_{i1}^2, \dots, X_{ij}X_{i\ell}, \dots)$ .

Sous  $H_0$ , la statistique de test est :

$$W = n \cdot R^2$$

où  $R^2$  provient de la régression de  $\hat{\varepsilon}_i^2$  sur  $W_i$ .

Par un raisonnement similaire au test de Breusch-Pagan :

$$W = n \cdot R^2 \xrightarrow{d} \chi_q^2$$

où  $q$  est le nombre de régresseurs dans  $W_i$  (hors constante).

**Remarque :**  $q = k + \frac{k(k+1)}{2}$  si on inclut tous les termes.

# Test de Goldfeld-Quandt : Principe

**Idée :** Comparer les variances des résidus dans deux sous-échantillons.

**Contexte :** Utile quand on suspecte que la variance dépend d'une variable spécifique.

**Hypothèses :**

- ▶  $H_0 : \sigma_1^2 = \sigma_2^2$  (variances égales)
- ▶  $H_1 : \sigma_1^2 \neq \sigma_2^2$  (variances différentes)

# Test de Goldfeld-Quandt : Procédure

## Étapes :

1. Ordonner les observations selon la variable suspectée de causer l'hétéroscédasticité
2. Diviser l'échantillon en 3 parties :
  - ▶ Premier tiers :  $n_1$  observations
  - ▶ Observations centrales : à exclure (environ  $c$  observations)
  - ▶ Dernier tiers :  $n_2$  observations
3. Estimer le modèle séparément sur les deux sous-échantillons
4. Calculer les sommes des carrés des résidus  $SCR_1$  et  $SCR_2$
5. Calculer la statistique de test :

$$F = \frac{SCR_2/(n_2 - k)}{SCR_1/(n_1 - k)} \xrightarrow{H_0} F_{n_2 - k, n_1 - k}$$

où  $k$  est le nombre de paramètres

# Test de Goldfeld-Quandt : Décision

## Règle de décision :

- ▶ On rejette  $H_0$  si  $F > F_{n_2-k, n_1-k, \alpha}$
- ▶ Ou si la p-valeur <  $\alpha$

## Avantages :

- ▶ Simple à comprendre et à mettre en œuvre
- ▶ Ne nécessite pas d'hypothèse de normalité stricte
- ▶ Utile pour des formes monotones d'hétérosécédasticité

## Limites :

- ▶ Nécessite de choisir une variable d'ordonnancement
- ▶ Perte d'observations (celles du milieu)
- ▶ Moins puissant que d'autres tests dans certains cas

# Démonstration Test de Goldfeld-Quandt (1/2)

## Principe :

On divise l'échantillon en deux groupes selon une variable  $Z_i$  :

- ▶ Groupe 1 :  $n_1$  observations avec  $Z_i$  faible
- ▶ Groupe 2 :  $n_2$  observations avec  $Z_i$  élevé

On estime le modèle séparément sur chaque groupe et on obtient :

- ▶  $SCR_1 = \sum_{i \in \text{Groupe 1}} \hat{\varepsilon}_i^2$
- ▶  $SCR_2 = \sum_{i \in \text{Groupe 2}} \hat{\varepsilon}_i^2$

## Hypothèses :

- ▶  $H_0 : \sigma_1^2 = \sigma_2^2$
- ▶  $H_1 : \sigma_1^2 \neq \sigma_2^2$

## Démonstration Test de Goldfeld-Quandt (2/2)

**Distribution sous  $H_0$  :**

Sous l'hypothèse de normalité des erreurs et sous  $H_0$  :

$$\frac{SCR_j}{\sigma^2} \sim \chi^2_{n_j - k}$$

pour  $j = 1, 2$ , où  $k$  est le nombre de paramètres.

Par conséquent, le rapport :

$$F = \frac{SCR_2/(n_2 - k)}{SCR_1/(n_1 - k)} = \frac{\hat{\sigma}_2^2}{\hat{\sigma}_1^2} \sim F_{n_2 - k, n_1 - k}$$

sous  $H_0$ .

**Remarque :** Ce test nécessite l'hypothèse de normalité, contrairement aux tests LM.

# Maximum de vraisemblance sous hétéroscédasticité

**Modèle avec hétéroscédasticité :**

$$Y_i = X_i' \beta + \varepsilon_i, \quad \varepsilon_i \sim \mathcal{N}(0, \sigma_i^2)$$

où  $\sigma_i^2 = \sigma_i^2(Z_i, \alpha)$  dépend de paramètres  $\alpha$  à estimer.

**Log-vraisemblance :**

$$\ell(\beta, \alpha) = -\frac{n}{2} \log(2\pi) - \frac{1}{2} \sum_{i=1}^n \log(\sigma_i^2(Z_i, \alpha)) - \frac{1}{2} \sum_{i=1}^n \frac{(Y_i - X_i' \beta)^2}{\sigma_i^2(Z_i, \alpha)}$$

**Objectif :** Maximiser  $\ell(\beta, \alpha)$  par rapport à  $\beta$  et  $\alpha$  conjointement.

# Conditions de premier ordre

**Dérivée par rapport à  $\beta$  :**

$$\frac{\partial \ell}{\partial \beta} = \sum_{i=1}^n \frac{X_i(Y_i - X'_i \beta)}{\sigma_i^2(Z_i, \alpha)} = 0$$

Cela donne :

$$\hat{\beta}_{MV} = \left( \sum_{i=1}^n \frac{X_i X'_i}{\sigma_i^2(Z_i, \hat{\alpha})} \right)^{-1} \sum_{i=1}^n \frac{X_i Y_i}{\sigma_i^2(Z_i, \hat{\alpha})}$$

**Dérivée par rapport à  $\alpha$  :**

$$\frac{\partial \ell}{\partial \alpha} = -\frac{1}{2} \sum_{i=1}^n \frac{1}{\sigma_i^2} \frac{\partial \sigma_i^2}{\partial \alpha} + \frac{1}{2} \sum_{i=1}^n \frac{(Y_i - X'_i \beta)^2}{(\sigma_i^2)^2} \frac{\partial \sigma_i^2}{\partial \alpha} = 0$$

Les deux conditions doivent être satisfaites simultanément.

## Lien avec les MCG

### Rappel : MCG (Moindres Carrés Généralisés)

Si  $\Omega = \text{diag}(\sigma_1^2, \dots, \sigma_n^2)$  est **connu**, l'estimateur MCG est :

$$\hat{\beta}_{MCG} = (X' \Omega^{-1} X)^{-1} X' \Omega^{-1} Y = \left( \sum_{i=1}^n \frac{X_i X'_i}{\sigma_i^2} \right)^{-1} \sum_{i=1}^n \frac{X_i Y_i}{\sigma_i^2}$$

**Question :**  $\hat{\beta}_{MV} = \hat{\beta}_{MCG}$  ?

**Réponse :** **NON en général !**

- ▶ MCG suppose  $\Omega$  **connu** (ou estimé indépendamment)
- ▶ MV estime  $\beta$  et  $\alpha$  (donc  $\sigma_i^2$ ) **conjointement**
- ▶ Les deux approches coïncident seulement si  $\alpha$  est connu a priori

## Lien avec les MCQG (MCG Faisables)

### Rappel : MCQG/FGLS (Feasible GLS)

Procédure en deux étapes :

1. Estimer  $\hat{\alpha}$  par une méthode préliminaire (ex: régression de  $\hat{\varepsilon}_i^2$  sur  $Z_i$ )
2. Calculer  $\hat{\sigma}_i^2(Z_i, \hat{\alpha})$  et appliquer MCG :

$$\hat{\beta}_{FGLS} = \left( \sum_{i=1}^n \frac{X_i X_i'}{\hat{\sigma}_i^2} \right)^{-1} \sum_{i=1}^n \frac{X_i Y_i}{\hat{\sigma}_i^2}$$

**Question :**  $\hat{\beta}_{MV} = \hat{\beta}_{FGLS}$  ?

**Réponse :** NON en général !

- ▶ FGLS : estimation séquentielle ( $\alpha$  puis  $\beta$ )
- ▶ MV : estimation conjointe et optimale
- ▶ Asymptotiquement, sous certaines conditions, les deux sont équivalents

# Comparaison des trois approches

Critère	MCG	FGLS	MV
$\Omega$ connu ?	Oui	Non	Non
Estimation	Une étape	Deux étapes	Conjointe
Efficience	Optimale	Asympt. opt.	Optimale
Complexité	Faible	Moyenne	Élevée
Normalité	Non requise	Non requise	Requise

## Remarques :

- ▶ Si  $\Omega$  est connu : MCG est le meilleur (BLUE)
- ▶ Si  $\Omega$  est inconnu : MV est asymptotiquement efficace sous normalité
- ▶ FGLS est une approximation pratique du MV
- ▶ Sous normalité et avec  $n \rightarrow \infty$  :  $\hat{\beta}_{MV} \approx \hat{\beta}_{FGLS}$

# Conditions d'équivalence MV et MCG

**Question :** Quand a-t-on  $\hat{\beta}_{MV} = \hat{\beta}_{MCG}$  ?

**Réponse :** L'équivalence exacte requiert :

1. **Connaissance parfaite de  $\Omega$  :**

$$\sigma_i^2 = \sigma_i^2(\alpha) \text{ avec } \alpha \text{ connu}$$

2. **Indépendance des paramètres :**

Les paramètres de variance  $\alpha$  ne dépendent pas de  $\beta$

3. **Normalité des erreurs :**

$$\varepsilon_i | X_i \sim \mathcal{N}(0, \sigma_i^2)$$

**Remarque :** Si  $\Omega$  est parfaitement connu, alors :

$$\hat{\beta}_{MV} = \hat{\beta}_{MCG} = (X' \Omega^{-1} X)^{-1} X' \Omega^{-1} Y$$

# Conditions d'équivalence asymptotique MV et MCQG

**Question :** Quand a-t-on  $\hat{\beta}_{MV} \approx \hat{\beta}_{FGLS}$  asymptotiquement ?

**Conditions pour l'équivalence asymptotique :**

1. **Convergence de l'estimateur préliminaire :**

$$\sqrt{n}(\hat{\alpha} - \alpha) = O_p(1)$$

L'estimateur  $\hat{\alpha}$  doit être  $\sqrt{n}$ -convergent

2. **Spécification correcte du modèle de variance :**

La forme fonctionnelle  $\sigma_i^2(Z_i, \alpha)$  doit être correctement spécifiée

3. **Conditions de régularité :**

- ▶  $\mathbb{E}[X_i X_i']$  existe et est définie positive
- ▶  $\mathbb{E}[\varepsilon_i^4] < \infty$  (moments d'ordre 4 finis)
- ▶ Conditions de continuité sur  $\sigma_i^2(\cdot)$

# Résultat d'équivalence asymptotique

**Théorème :** Sous les conditions précédentes, on a :

$$\sqrt{n}(\hat{\beta}_{MV} - \beta) - \sqrt{n}(\hat{\beta}_{FGLS} - \beta) \xrightarrow{p} 0$$

**Conséquences :**

1. Les deux estimateurs ont la même distribution asymptotique :

$$\sqrt{n}(\hat{\beta}_{MV} - \beta) \xrightarrow{d} \mathcal{N}(0, (X'\Omega^{-1}X)^{-1})$$

$$\sqrt{n}(\hat{\beta}_{FGLS} - \beta) \xrightarrow{d} \mathcal{N}(0, (X'\Omega^{-1}X)^{-1})$$

2. Les deux estimateurs sont asymptotiquement efficaces
3. En pratique, MCQG est souvent préféré pour sa simplicité computationnelle

**Attention :** En échantillon fini, MV peut être plus efficace que MCQG si la normalité est vérifiée.

## Cas particulier : Variance linéaire

Modèle de variance linéaire :

$$\sigma_i^2 = Z_i' \alpha$$

Estimation MCQG :

1. Estimer  $\beta$  par MCO :  $\hat{\beta}_{MCO}$
2. Régresser  $\hat{\varepsilon}_i^2$  sur  $Z_i$  :  $\hat{\alpha} = (Z'Z)^{-1}Z'\hat{\varepsilon}^2$
3. Calculer  $\hat{\sigma}_i^2 = Z_i' \hat{\alpha}$
4. Appliquer MCG :  $\hat{\beta}_{FGLS} = (X'\hat{\Omega}^{-1}X)^{-1}X'\hat{\Omega}^{-1}Y$

Résultat : Si  $n \rightarrow \infty$  et sous normalité :

$$\hat{\beta}_{MV} \approx \hat{\beta}_{FGLS}$$

avec une différence d'ordre  $O_p(n^{-1})$ .

Intuition : L'erreur d'estimation de  $\alpha$  devient négligeable asymptotiquement.

# Exemple : Hétéroscédasticité multiplicative

## Spécification courante :

$$\sigma_i^2 = \sigma^2 \exp(Z'_i \gamma)$$

## Approche MV :

La log-vraisemblance devient :

$$\ell(\beta, \sigma^2, \gamma) = -\frac{n}{2} \log(2\pi) - \frac{n}{2} \log(\sigma^2) - \frac{1}{2} \sum_{i=1}^n Z'_i \gamma - \frac{1}{2\sigma^2} \sum_{i=1}^n \frac{(Y_i - X'_i \beta)^2}{\exp(Z'_i \gamma)}$$

On maximise conjointement en  $(\beta, \sigma^2, \gamma)$ .

## Approche FGLS :

1. Estimer par MCO et obtenir  $\hat{\varepsilon}_i$
2. Régresser  $\log(\hat{\varepsilon}_i^2)$  sur  $Z_i$  pour obtenir  $\hat{\gamma}$
3. Calculer  $\hat{\sigma}_i^2 = \exp(\hat{\delta}_0 + Z'_i \hat{\gamma})$
4. Appliquer MCG avec ces poids

# Efficience asymptotique

## Résultat théorique :

Sous normalité et conditions de régularité, l'estimateur du MV atteint la borne de Cramér-Rao :

$$\text{Var}(\hat{\theta}_{MV}) = \mathcal{I}(\theta)^{-1}$$

où  $\theta = (\beta', \alpha')'$  et  $\mathcal{I}(\theta)$  est la matrice d'information de Fisher.

## Pour FGLS :

- ▶ Si  $\hat{\alpha}$  est  $\sqrt{n}$ -convergent, alors  $\hat{\beta}_{FGLS}$  est asymptotiquement équivalent à  $\hat{\beta}_{MV}$
- ▶  $\sqrt{n}(\hat{\beta}_{FGLS} - \beta) \xrightarrow{d} \mathcal{N}(0, (X'\Omega^{-1}X)^{-1})$
- ▶ Même distribution asymptotique que MCG avec  $\Omega$  connu

**En pratique :** FGLS est souvent préféré pour sa simplicité, malgré une légère perte d'efficience en échantillon fini.

# Motivation

**Problème** : Sous hétéroscédasticité, la variance usuelle des MCO est biaisée :

$$\text{Var}_{\text{usuelle}}(\hat{\beta}) = \sigma^2(X'X)^{-1}$$

Cette formule suppose  $\text{Var}(\varepsilon_i | X_i) = \sigma^2$  (homoscédasticité).

**Solution** : Utiliser des estimateurs de variance **robustes** qui restent valides sous hétéroscédasticité.

**Avantage** :

- ▶ Garder l'estimateur MCO (simple à calculer)
- ▶ Corriger uniquement les écarts-types
- ▶ Tests et intervalles de confiance valides

# Vraie variance des MCO sous hétéroscédasticité

## Expression générale :

Sous hétéroscédasticité, la vraie variance de  $\hat{\beta}$  est :

$$\text{Var}(\hat{\beta}) = (X'X)^{-1} X' \Omega X (X'X)^{-1}$$

où  $\Omega = \text{diag}(\sigma_1^2, \dots, \sigma_n^2)$ .

En notation par observation :

$$\text{Var}(\hat{\beta}) = \left( \sum_{i=1}^n X_i X_i' \right)^{-1} \left( \sum_{i=1}^n \sigma_i^2 X_i X_i' \right) \left( \sum_{i=1}^n X_i X_i' \right)^{-1}$$

C'est la formule "sandwich" :  $(X'X)^{-1}$  entoure le terme central.

# Estimateur de White (HC0)

**Idée :** Estimer  $\sigma_i^2$  par  $\hat{\varepsilon}_i^2$ .

**Estimateur de White (1980) :**

$$\widehat{\text{Var}}_{HC0}(\hat{\beta}) = (X'X)^{-1} \left( \sum_{i=1}^n \hat{\varepsilon}_i^2 X_i X_i' \right) (X'X)^{-1}$$

ou en notation matricielle :

$$\widehat{\text{Var}}_{HC0}(\hat{\beta}) = (X'X)^{-1} X' \hat{\Omega} X (X'X)^{-1}$$

où  $\hat{\Omega} = \text{diag}(\hat{\varepsilon}_1^2, \dots, \hat{\varepsilon}_n^2)$ .

**Propriétés :**

- ▶ Convergent :  $\widehat{\text{Var}}_{HC0}(\hat{\beta}) \xrightarrow{p} \text{Var}(\hat{\beta})$
- ▶ Valide sous hétéroscédasticité arbitraire
- ▶ Peut être biaisé à la baisse en petit échantillon

## Variantes : HC1, HC2, HC3

Pour améliorer les propriétés en petit échantillon, plusieurs corrections ont été proposées :

**HC1 (correction des degrés de liberté) :**

$$\widehat{\text{Var}}_{HC1}(\hat{\beta}) = \frac{n}{n-k} (X'X)^{-1} \left( \sum_{i=1}^n \hat{\varepsilon}_i^2 X_i X_i' \right) (X'X)^{-1}$$

**HC2 (MacKinnon & White, 1985) :**

$$\widehat{\text{Var}}_{HC2}(\hat{\beta}) = (X'X)^{-1} \left( \sum_{i=1}^n \frac{\hat{\varepsilon}_i^2}{1-h_{ii}} X_i X_i' \right) (X'X)^{-1}$$

où  $h_{ii}$  est l'élément diagonal de la matrice chapeau  $H = X(X'X)^{-1}X'$ .

**HC3 (Davidson & MacKinnon, 1993) :**

$$\widehat{\text{Var}}_{HC3}(\hat{\beta}) = (X'X)^{-1} \left( \sum_{i=1}^n \frac{\hat{\varepsilon}_i^2}{(1-h_{ii})^2} X_i X_i' \right) (X'X)^{-1}$$

# Comparaison des estimateurs robustes

Estimateur	Biais petit échantillon	Usage
HC0 (White)	Plus élevé	Grands échantillons
HC1	Moyen	Usage général
HC2	Faible	Recommandé
HC3	Très faible	Petits échantillons

## Recommandations :

- ▶ **HC1** : le plus utilisé en pratique (bon compromis)
- ▶ **HC3** : recommandé pour  $n < 250$  (Long & Ervin, 2000)
- ▶ **HC0** : acceptable si  $n$  est grand ( $n > 500$ )

## Illustration : Matrice chapeau

**Rappel :** La matrice chapeau est définie par :

$$H = X(X'X)^{-1}X'$$

**Propriétés :**

- ▶  $\hat{Y} = HY$  (valeurs ajustées)
- ▶  $\hat{\varepsilon} = (I - H)\varepsilon$  (résidus)
- ▶  $0 \leq h_{ii} \leq 1$  pour tout  $i$
- ▶  $\sum_{i=1}^n h_{ii} = k$  (nombre de paramètres)

**Interprétation de  $h_{ii}$  :**

- ▶ Mesure le "levier" de l'observation  $i$
- ▶  $h_{ii}$  élevé  $\Rightarrow$  observation influente
- ▶ HC2 et HC3 donnent plus de poids aux observations à fort levier

# Démonstration : Convergence de l'estimateur de White

**Objectif** : Montrer que  $\widehat{\text{Var}}_{HC0}(\hat{\beta}) \xrightarrow{p} \text{Var}(\hat{\beta})$ .

**Étape 1** : La vraie variance est

$$\text{Var}(\hat{\beta}) = \left( \sum_{i=1}^n X_i X_i' \right)^{-1} \left( \sum_{i=1}^n \sigma_i^2 X_i X_i' \right) \left( \sum_{i=1}^n X_i X_i' \right)^{-1}$$

**Étape 2** : L'estimateur de White utilise  $\hat{\varepsilon}_i^2$  à la place de  $\sigma_i^2$  :

$$\widehat{\text{Var}}_{HC0}(\hat{\beta}) = \left( \sum_{i=1}^n X_i X_i' \right)^{-1} \left( \sum_{i=1}^n \hat{\varepsilon}_i^2 X_i X_i' \right) \left( \sum_{i=1}^n X_i X_i' \right)^{-1}$$

## Démonstration : Convergence de l'estimateur de White (suite)

**Étape 3 :** Il suffit de montrer que

$$\frac{1}{n} \sum_{i=1}^n \hat{\varepsilon}_i^2 X_i X_i' \xrightarrow{p} \frac{1}{n} \sum_{i=1}^n \sigma_i^2 X_i X_i'$$

**Étape 4 :** On a  $\hat{\varepsilon}_i = \varepsilon_i - X_i'(\hat{\beta} - \beta)$ , donc :

$$\hat{\varepsilon}_i^2 = \varepsilon_i^2 - 2\varepsilon_i X_i'(\hat{\beta} - \beta) + (\hat{\beta} - \beta)' X_i X_i' (\hat{\beta} - \beta)$$

Par la loi des grands nombres et le fait que  $\hat{\beta} \xrightarrow{p} \beta$  :

$$\frac{1}{n} \sum_{i=1}^n (\hat{\varepsilon}_i^2 - \varepsilon_i^2) X_i X_i' \xrightarrow{p} 0$$

Et  $\frac{1}{n} \sum_{i=1}^n \varepsilon_i^2 X_i X_i' \xrightarrow{p} \mathbb{E}[\sigma_i^2 X_i X_i']$ .

**Conclusion :** L'estimateur de White est convergent.

## Tableau comparatif

Critère	Breusch-Pagan	White	Goldfeld-Quandt
Forme fonctionnelle	Linéaire	Générale	Aucune
Puissance	Moyenne	Élevée	Variable
Simplicité	Élevée	Moyenne	Élevée
Normalité requise	Oui	Non	Oui
Taille échantillon	Moyenne	Grande	Moyenne

**Recommandation :** Le test de White est généralement le plus utilisé en pratique pour sa généralité.

# Que faire en cas d'hétéroscédasticité ?

Si l'hétéroscédasticité est détectée, plusieurs solutions :

## 1. Écarts-types robustes (White/Huber)

- ▶ Corriger les écarts-types sans changer les estimateurs
- ▶ Solution la plus courante en pratique

## 2. Moindres Carrés Généralisés (MCG)

- ▶ Si la forme de l'hétéroscédasticité est connue
- ▶ Estimateurs plus efficaces

## 3. Transformation des variables

- ▶ Logarithme, racine carrée, etc.
- ▶ Peut stabiliser la variance

## Exemple sous Python

```
import pandas as pd
import statsmodels.api as sm
from statsmodels.stats.diagnostic import het_breuschpagan
from statsmodels.stats.diagnostic import het_white

# Charger les données
data = pd.read_csv("donnees.csv")

# Estimer le modèle
X = sm.add_constant(data[['X1', 'X2', 'X3']])
model = sm.OLS(data['Y'], X).fit()

# Test de Breusch-Pagan
bp_test = het_breuschpagan(model.resid, X)
print(f"BP = {bp_test[0]:.2f}, p-value = {bp_test[1]:.4f}")

# Test de White
white_test = het_white(model.resid, X)
print(f"White = {white_test[0]:.2f}, p-value = {white_test[1]:.4f}")
```

## Exemple Python : Estimateurs robustes

```
# Écarts-types robustes (différentes variantes)
model_hc0 = model.get_robustcov_results(cov_type='HC0')
model_hc1 = model.get_robustcov_results(cov_type='HC1')
model_hc2 = model.get_robustcov_results(cov_type='HC2')
model_hc3 = model.get_robustcov_results(cov_type='HC3')

print("Écarts-types standard:", model.bse)
print("Écarts-types HC1:", model_hc1.bse)

# MCG faisables (FGLS)
# Spécifier un modèle pour la variance
import numpy as np
log_resid_sq = np.log(model.resid**2 + 1e-8)
variance_model = sm.OLS(log_resid_sq, X).fit()
weights = 1 / np.exp(variance_model.fittedvalues)

# Estimation par MCG
model_gls = sm.WLS(data['Y'], X, weights=weights).fit()
print(model_gls.summary())
```

# Interprétation des résultats

## Exemple de sortie :

BP = 12.45, p-value = 0.0060

White = 15.32, p-value = 0.0180

## Interprétation :

- ▶ Les statistiques BP et White suivent des lois  $\chi^2$
- ▶ p-valeurs < 0.05 pour les deux tests
- ▶ On rejette  $H_0$  au seuil de 5%
- ▶ Conclusion : présence d'hétéroscédasticité
- ▶ Action : utiliser des écarts-types robustes

## Points clés à retenir

1. L'hétérosécédasticité affecte l'efficience des estimateurs MCO et invalide les tests usuels
2. Trois tests principaux pour détecter l'hétérosécédasticité :
  - ▶ **Breusch-Pagan** : forme linéaire spécifique
  - ▶ **White** : forme générale, le plus utilisé
  - ▶ **Goldfeld-Quandt** : comparaison de sous-échantillons
3. Deux approches principales pour traiter l'hétérosécédasticité :
  - ▶ **Estimateurs robustes** (HC0, HC1, HC2, HC3) : corriger les écarts-types
  - ▶ **MCG/FGLS** : ré-estimer le modèle avec pondération optimale
4. En pratique : utiliser HC1 ou HC3 pour les écarts-types robustes

# Références

-  Greene, William H. (2017). *Econometric analysis*. Pearson.
-  Schmidt, Peter (1976). *Econometrics*. Taylor & Francis.