



UNIVERSITÉ DE NANTES

Chapitre 1:

Comparaison d'une variable quantitative sur J groupes indépendants

(ANOVA à un facteur sur groupes indépendants)

Module HPS5-42

Année 2021-22


GALHARRET J-M,
Laboratoire de Mathématiques Jean Leray
Faculté de Psychologie.

Test de Fisher

(Test OMNIBUS de l'ANOVA)

Généralités


Conditions d'application de l'ANOVA



Généralités

Conditions d'application de l'ANOVA


- On considère X une variable indépendante catégorielle à J modalités ($J > 2$, on parle de facteur) et une variable dépendante Y quantitative.



Généralités

Conditions d'application de l'ANOVA

- On considère X une variable indépendante catégorielle à J modalités ($J > 2$, on parle de facteur) et une variable dépendante Y quantitative.
- On suppose que la distribution de la variable Y est connue sur la modalité j et que :




Généralités

Conditions d'application de l'ANOVA

- On considère X une variable indépendante catégorielle à J modalités ($J > 2$, on parle de facteur) et une variable dépendante Y quantitative.
- On suppose que la distribution de la variable Y est connue sur la modalité j et que :


$$Y_j \sim \mathcal{N}(\mu_j, \sigma^2)$$



Exemple sensibilité à la douleur/couleur de cheveux

McClave, J. T. and Dietrich, F. H. (1991). Statistics. San Francisco: Dellen publishing.

Identifica...	Hair Color	Pain Tole...
1	Light Blond	62
2	Light Blond	60
3	Light Blond	71
4	Light Blond	55
5	Light Blond	48
6	Dark Blond	63
7	Dark Blond	57
8	Dark Blond	52
9	Dark Blond	41
10	Dark Blond	43
11	Light Brunette	42
12	Light Brunette	50
13	Light Brunette	41
14	Light Brunette	37
15	Dark Brunette	32
16	Dark Brunette	39
17	Dark Brunette	51
18	Dark Brunette	30
19	Dark Brunette	35



Statistiques Descriptives

Statistiques Descriptives

Descriptives - Pain Tolerance

Hair Color	Mean	s	n
DBl	51,2	9,284	5
DBr	37,400	8,325	5
LBl	59,200	8,526	5
LBr	43,400	5,128	5

Statistiques Descriptives

Descriptives - Pain Tolerance

Hair Color	Mean	s	n
DBl	51,2	9,284	5
DBr	37,400	8,325	5
LBl	59,200	8,526	5
LBr	43,400	5,128	5

La moyenne des N=20 individus est :

Statistiques Descriptives

Descriptives - Pain Tolerance

Hair Color	Mean	s	n
DBl	51,2	9,284	5
DBr	37,400	8,325	5
LBl	59,200	8,526	5
LBr	43,400	5,128	5

La moyenne des N=20 individus est :

$$m = \frac{51.2 + 36.4 + 59.2 + 43.4}{4} = 47.8$$

Variabilité de la variable dépendante Y

Somme des carrés des écarts

Variabilité de la variable dépendante Y

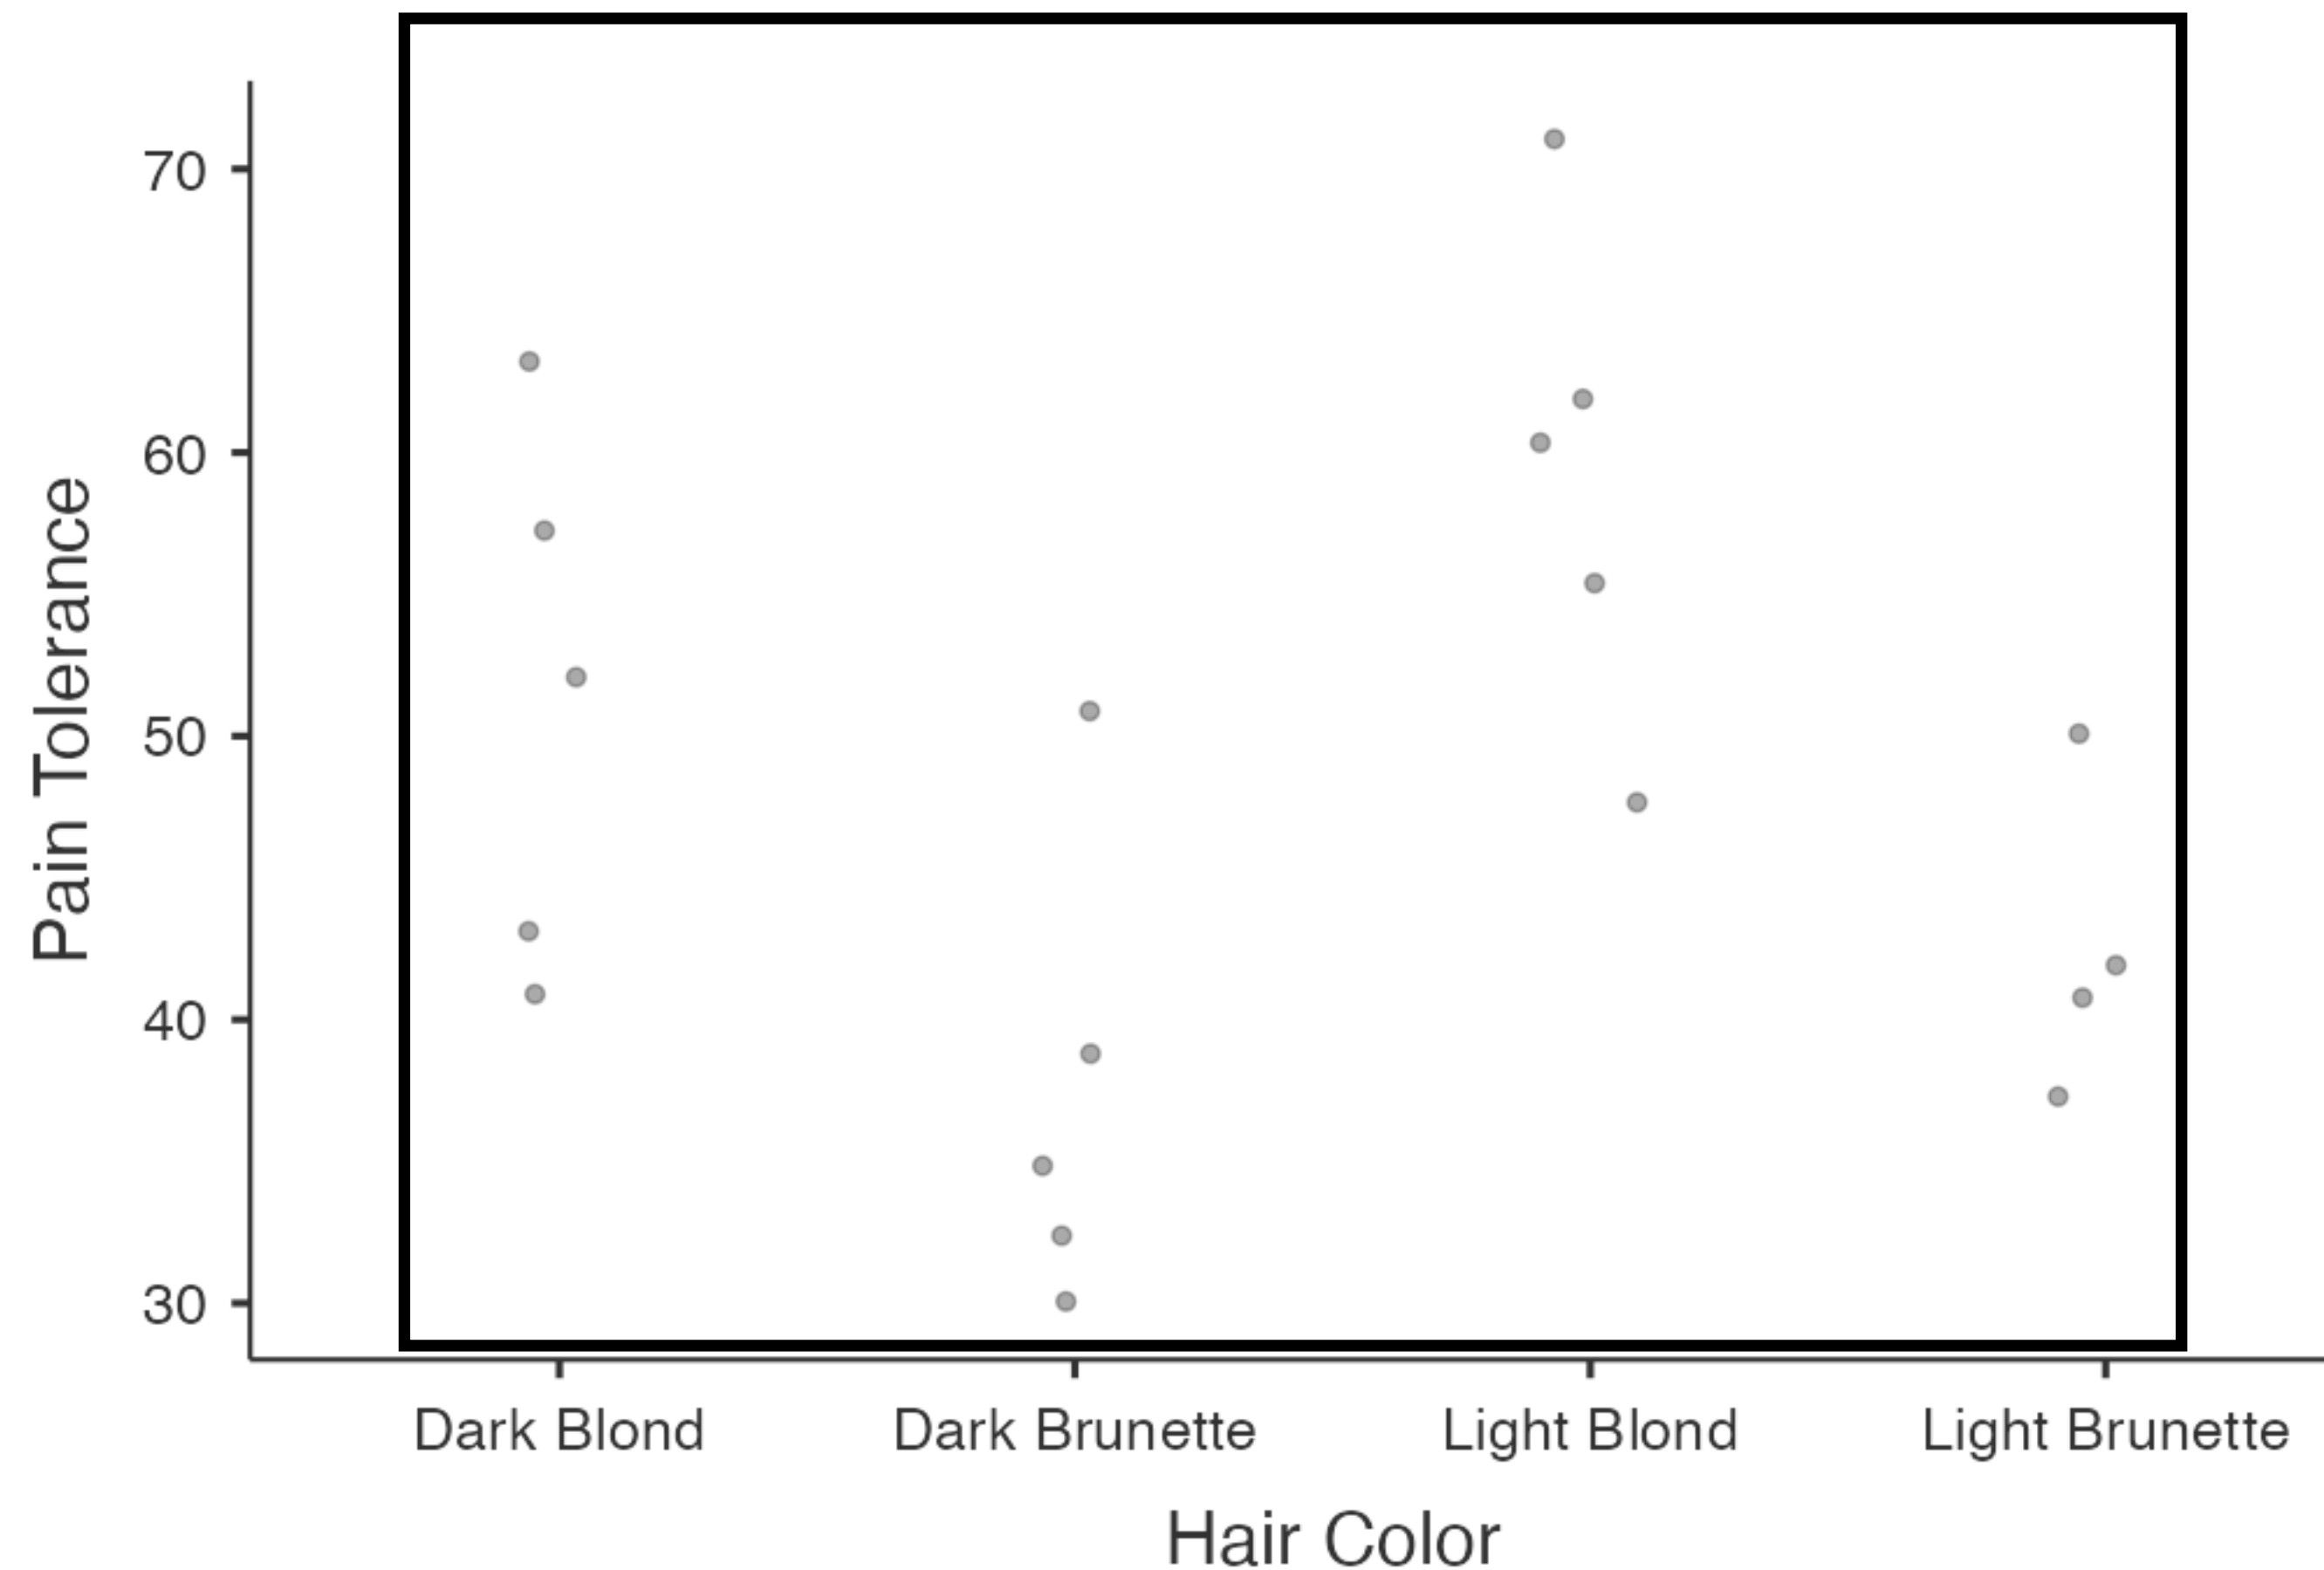
Somme des carrés des écarts

La variabilité de Y (Pain tolerance) est mesurée par SCE (somme carrée des écarts) :

Variabilité de la variable dépendante Y

Somme des carrés des écarts

La variabilité de Y (Pain tolerance) est mesurée par SCE (somme carrée des écarts) :




Variabilité de la variable dépendante Y

Somme des carrés des écarts

La variabilité de Y (Pain tolerance) est mesurée par SCE (somme carrée des écarts) :

$$\begin{aligned} SCE_Y &= N\sigma_Y^2 \\ &= (62 - 47.8)^2 + (60 - 47.8)^2 + \dots \\ &= 2363.2 \end{aligned}$$



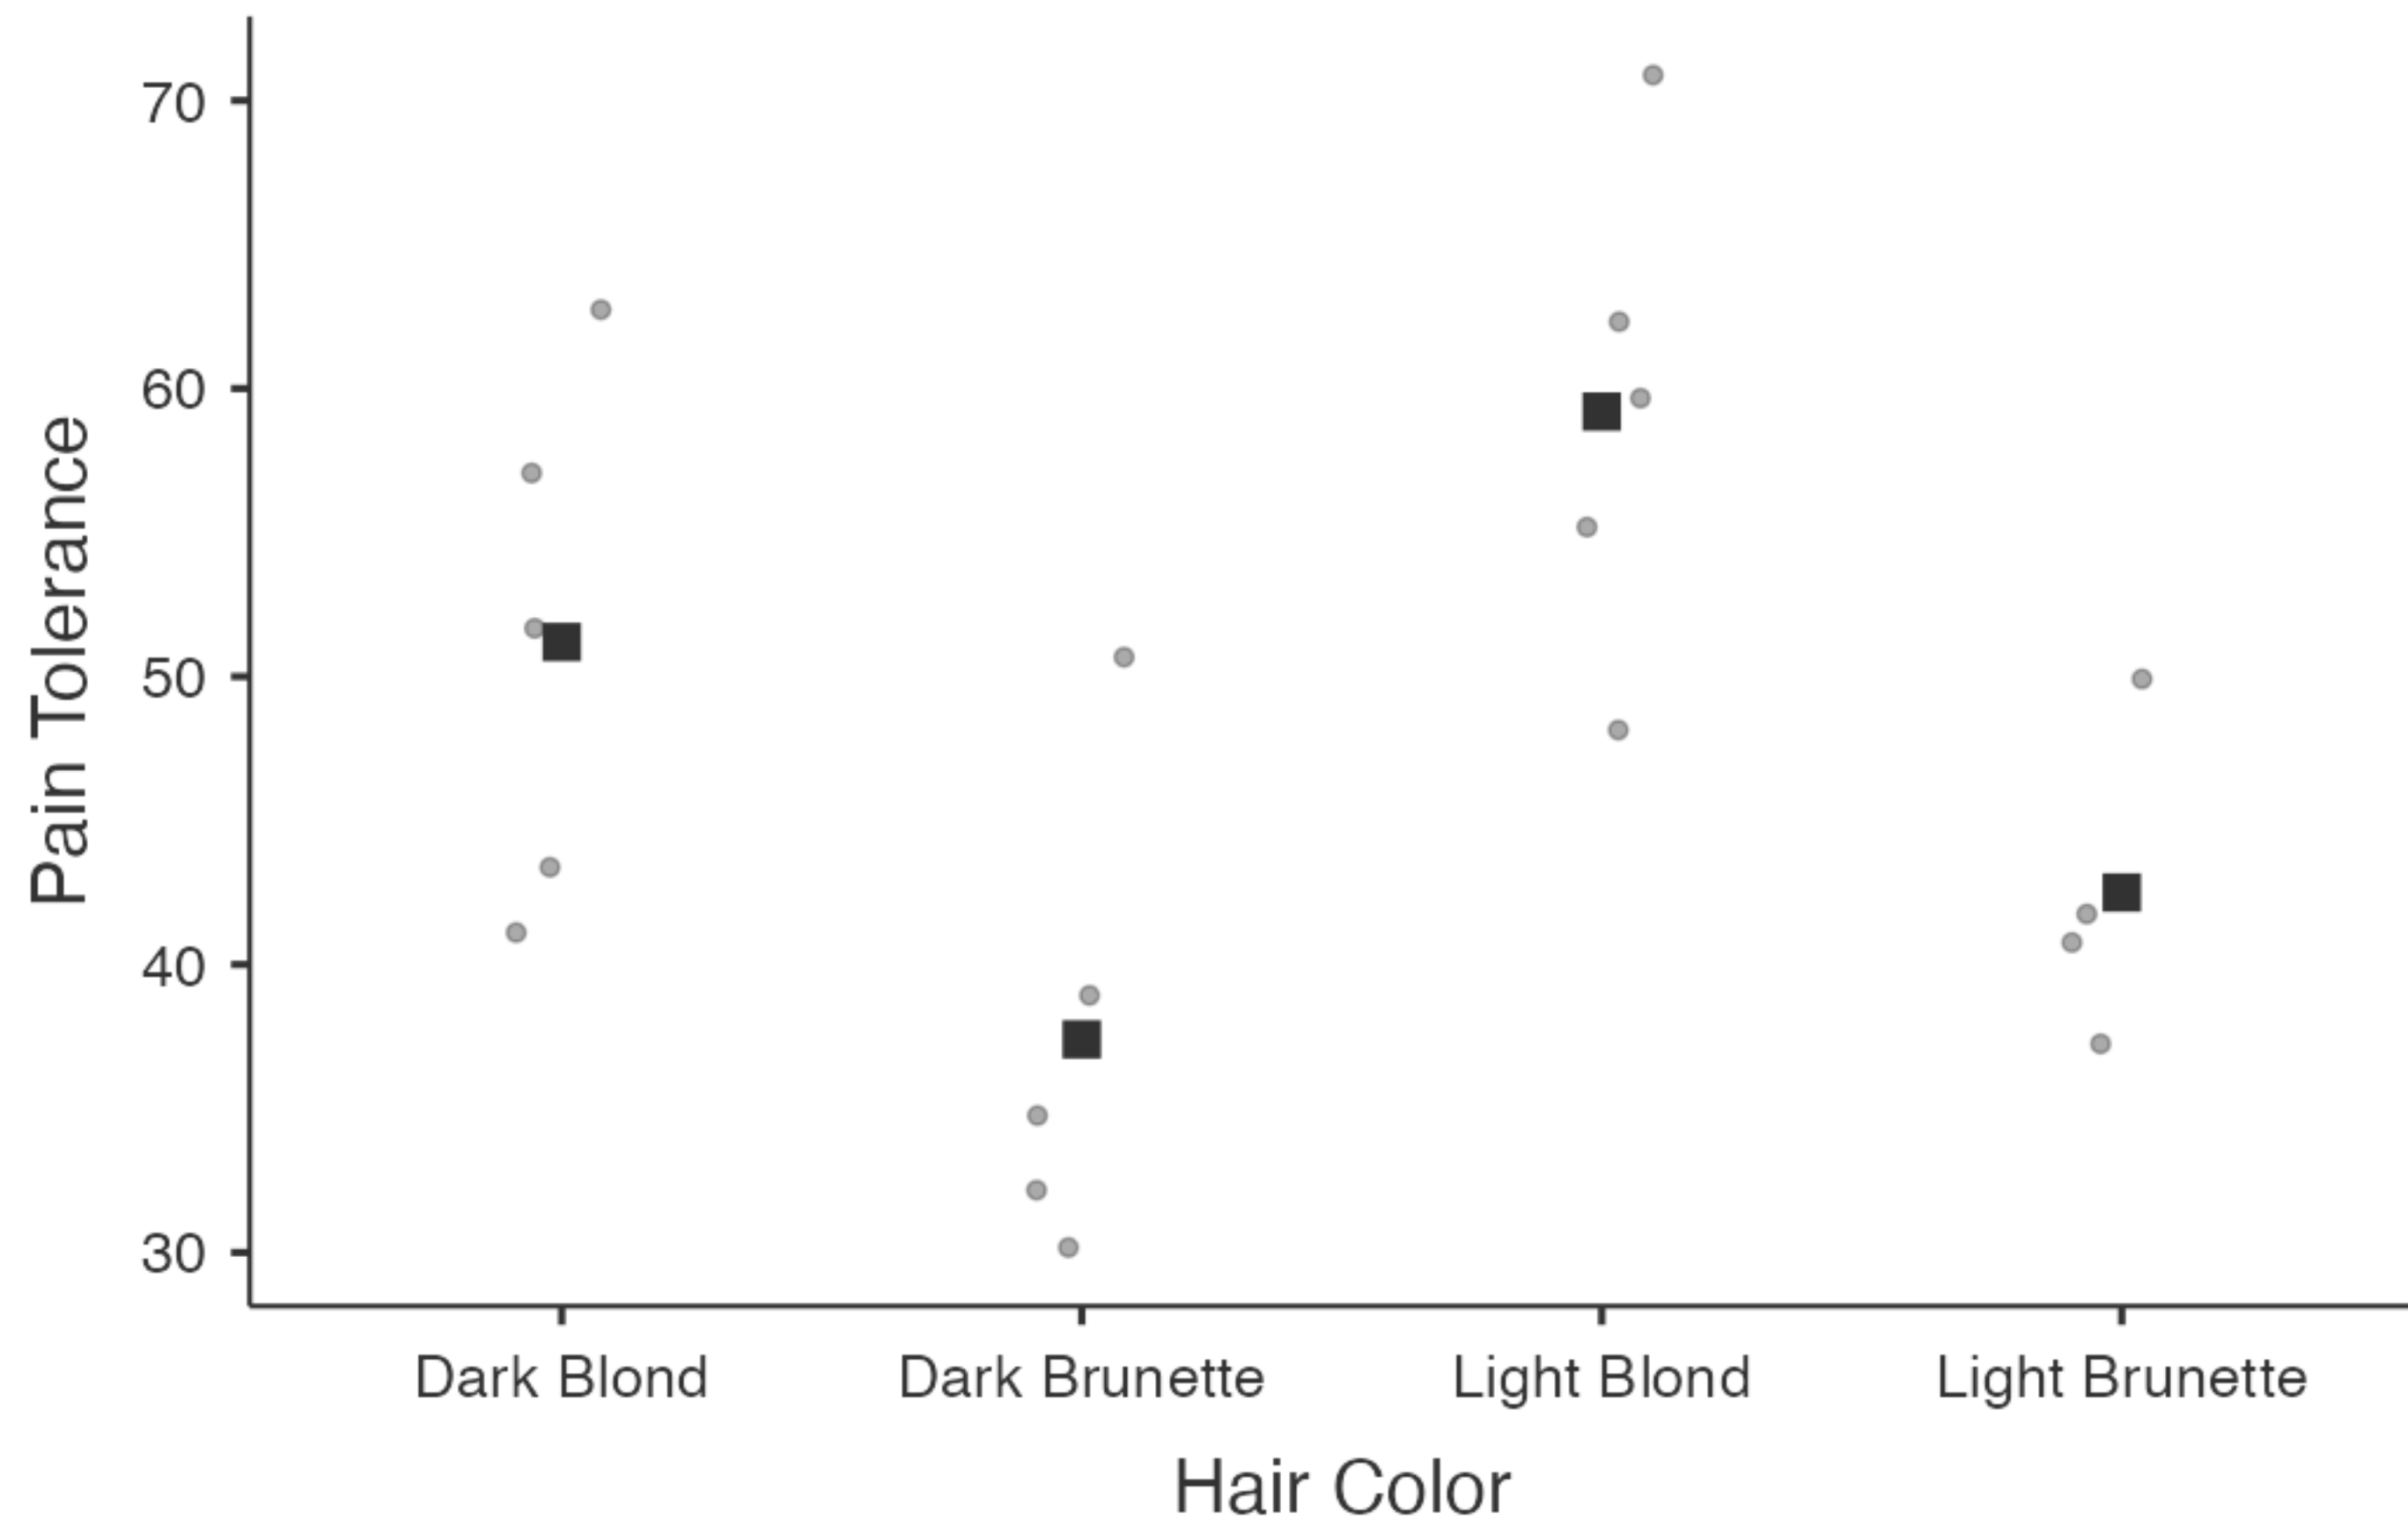
Variabilité inter-groupes (factorielle)

Variabilité inter-groupes (factorielle)

La variabilité entre les 4 groupes est l'écart entre les moyennes des groupes et la moyenne totale

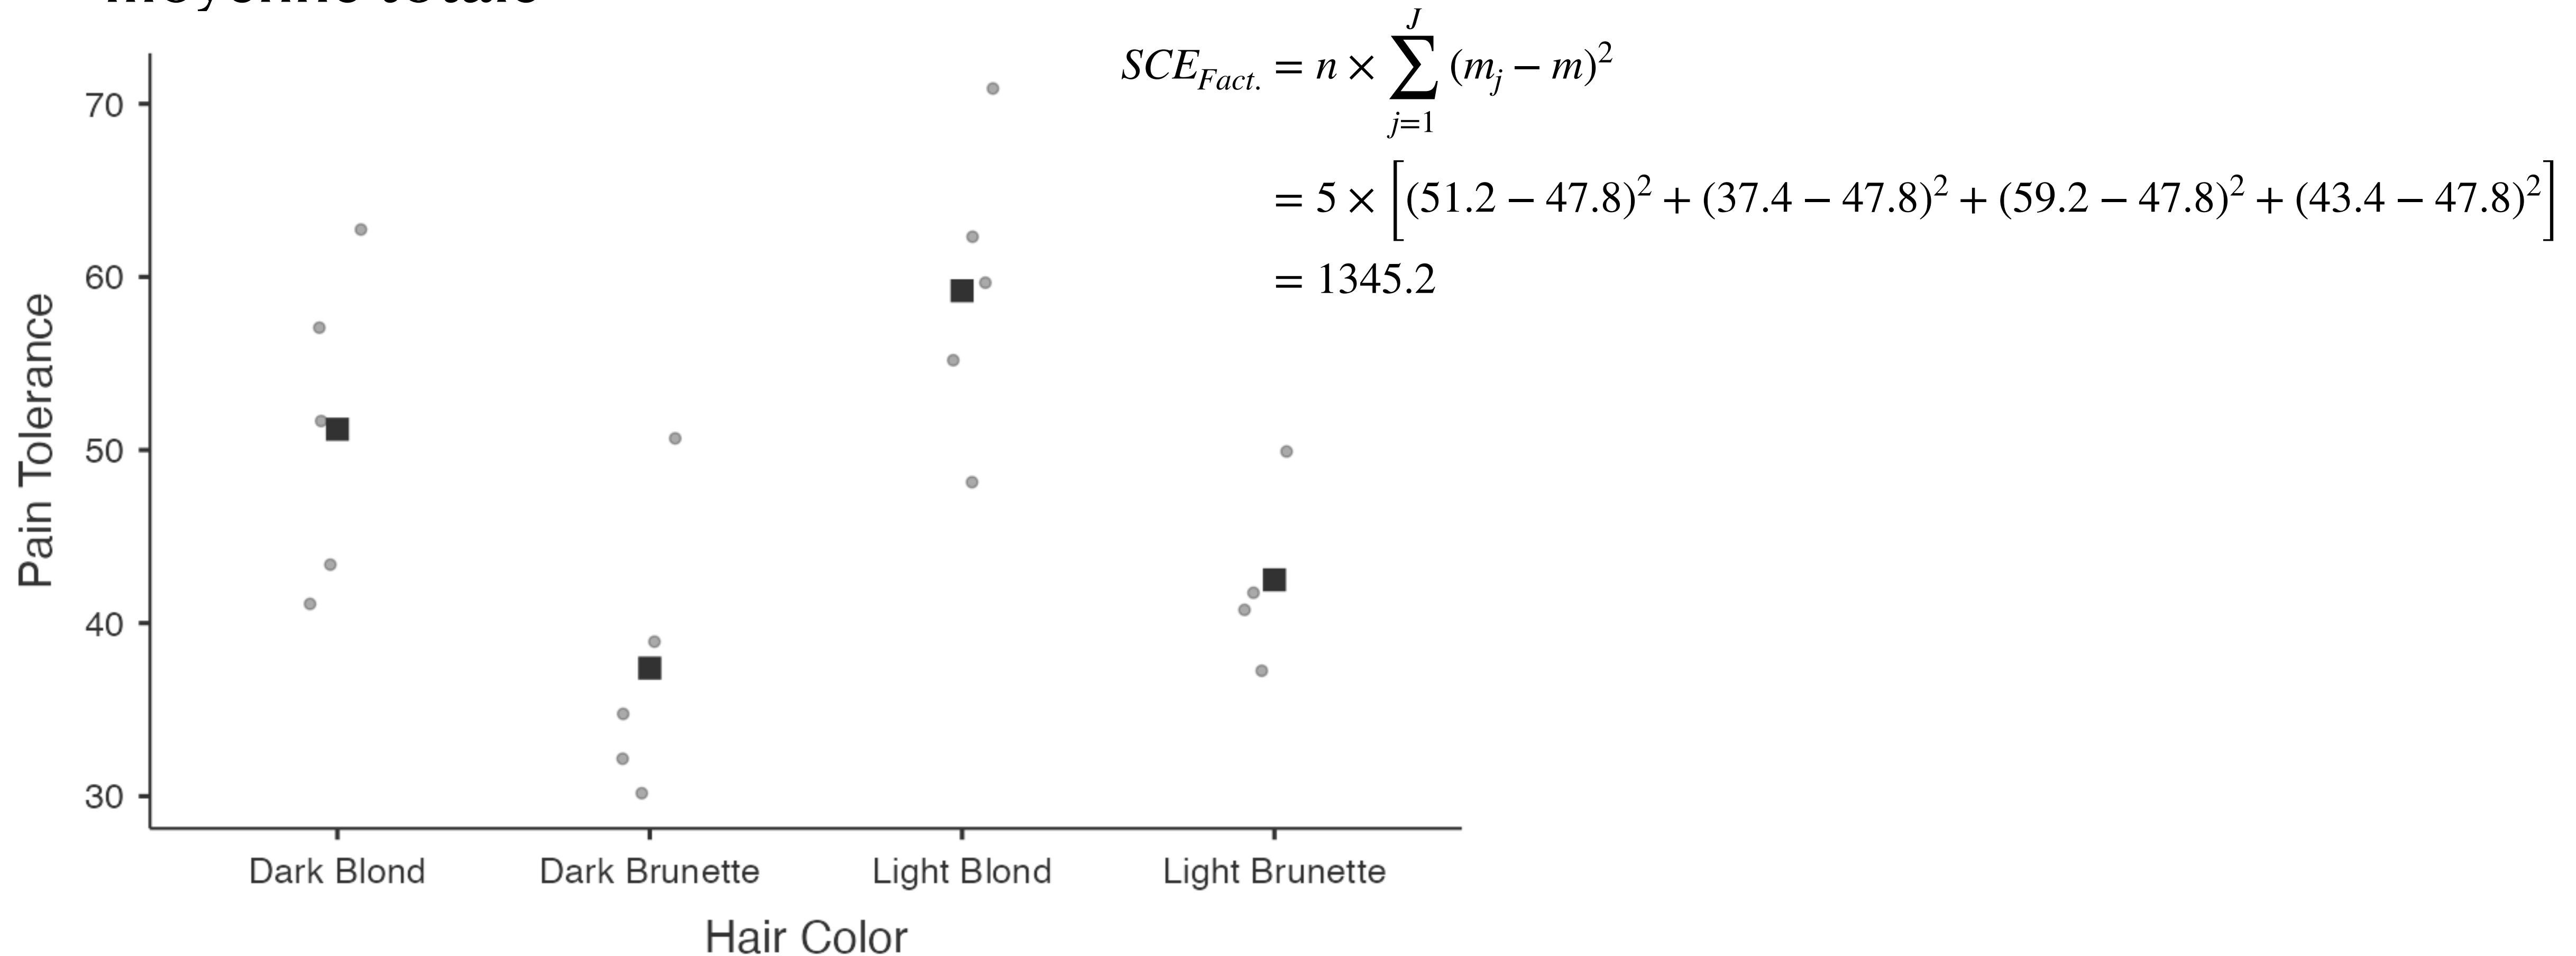
Variabilité inter-groupes (factorielle)

La variabilité entre les 4 groupes est l'écart entre les moyennes des groupes et la moyenne totale



Variabilité inter-groupes (factorielle)

La variabilité entre les 4 groupes est l'écart entre les moyennes des groupes et la moyenne totale



Variabilité résiduelle

Somme des Carrés des Ecart Résiduels

Variabilité résiduelle

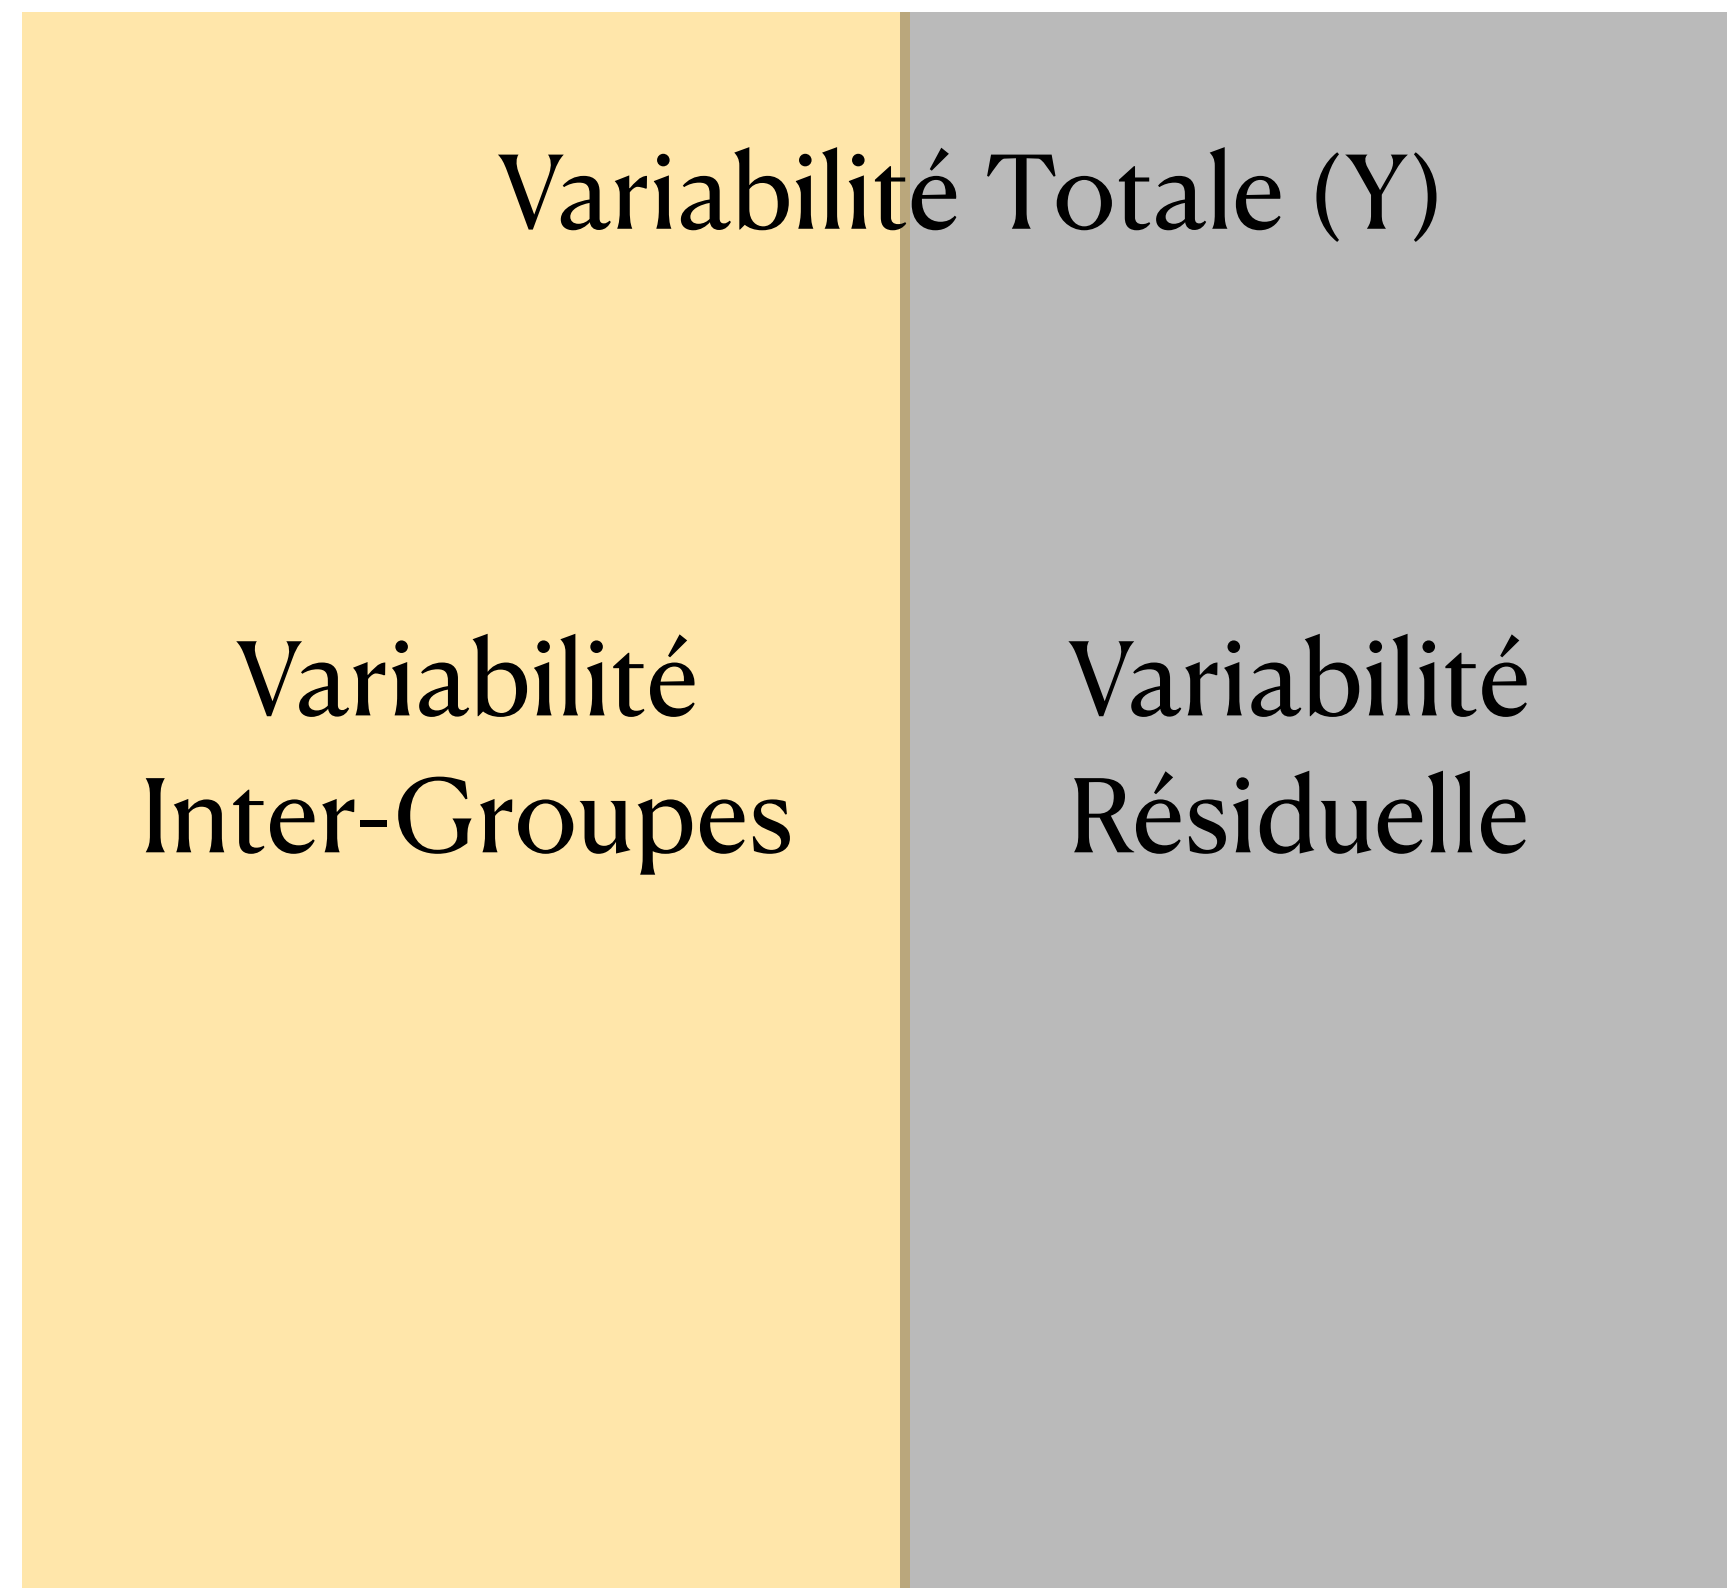
Somme des Carrés des Ecartés Résiduels

- La variabilité résiduelle est la variabilité de Y qui n'est pas associée au fait d'appartenir aux groupes c'est à dire

Variabilité résiduelle

Somme des Carrés des Ecartés Résiduels

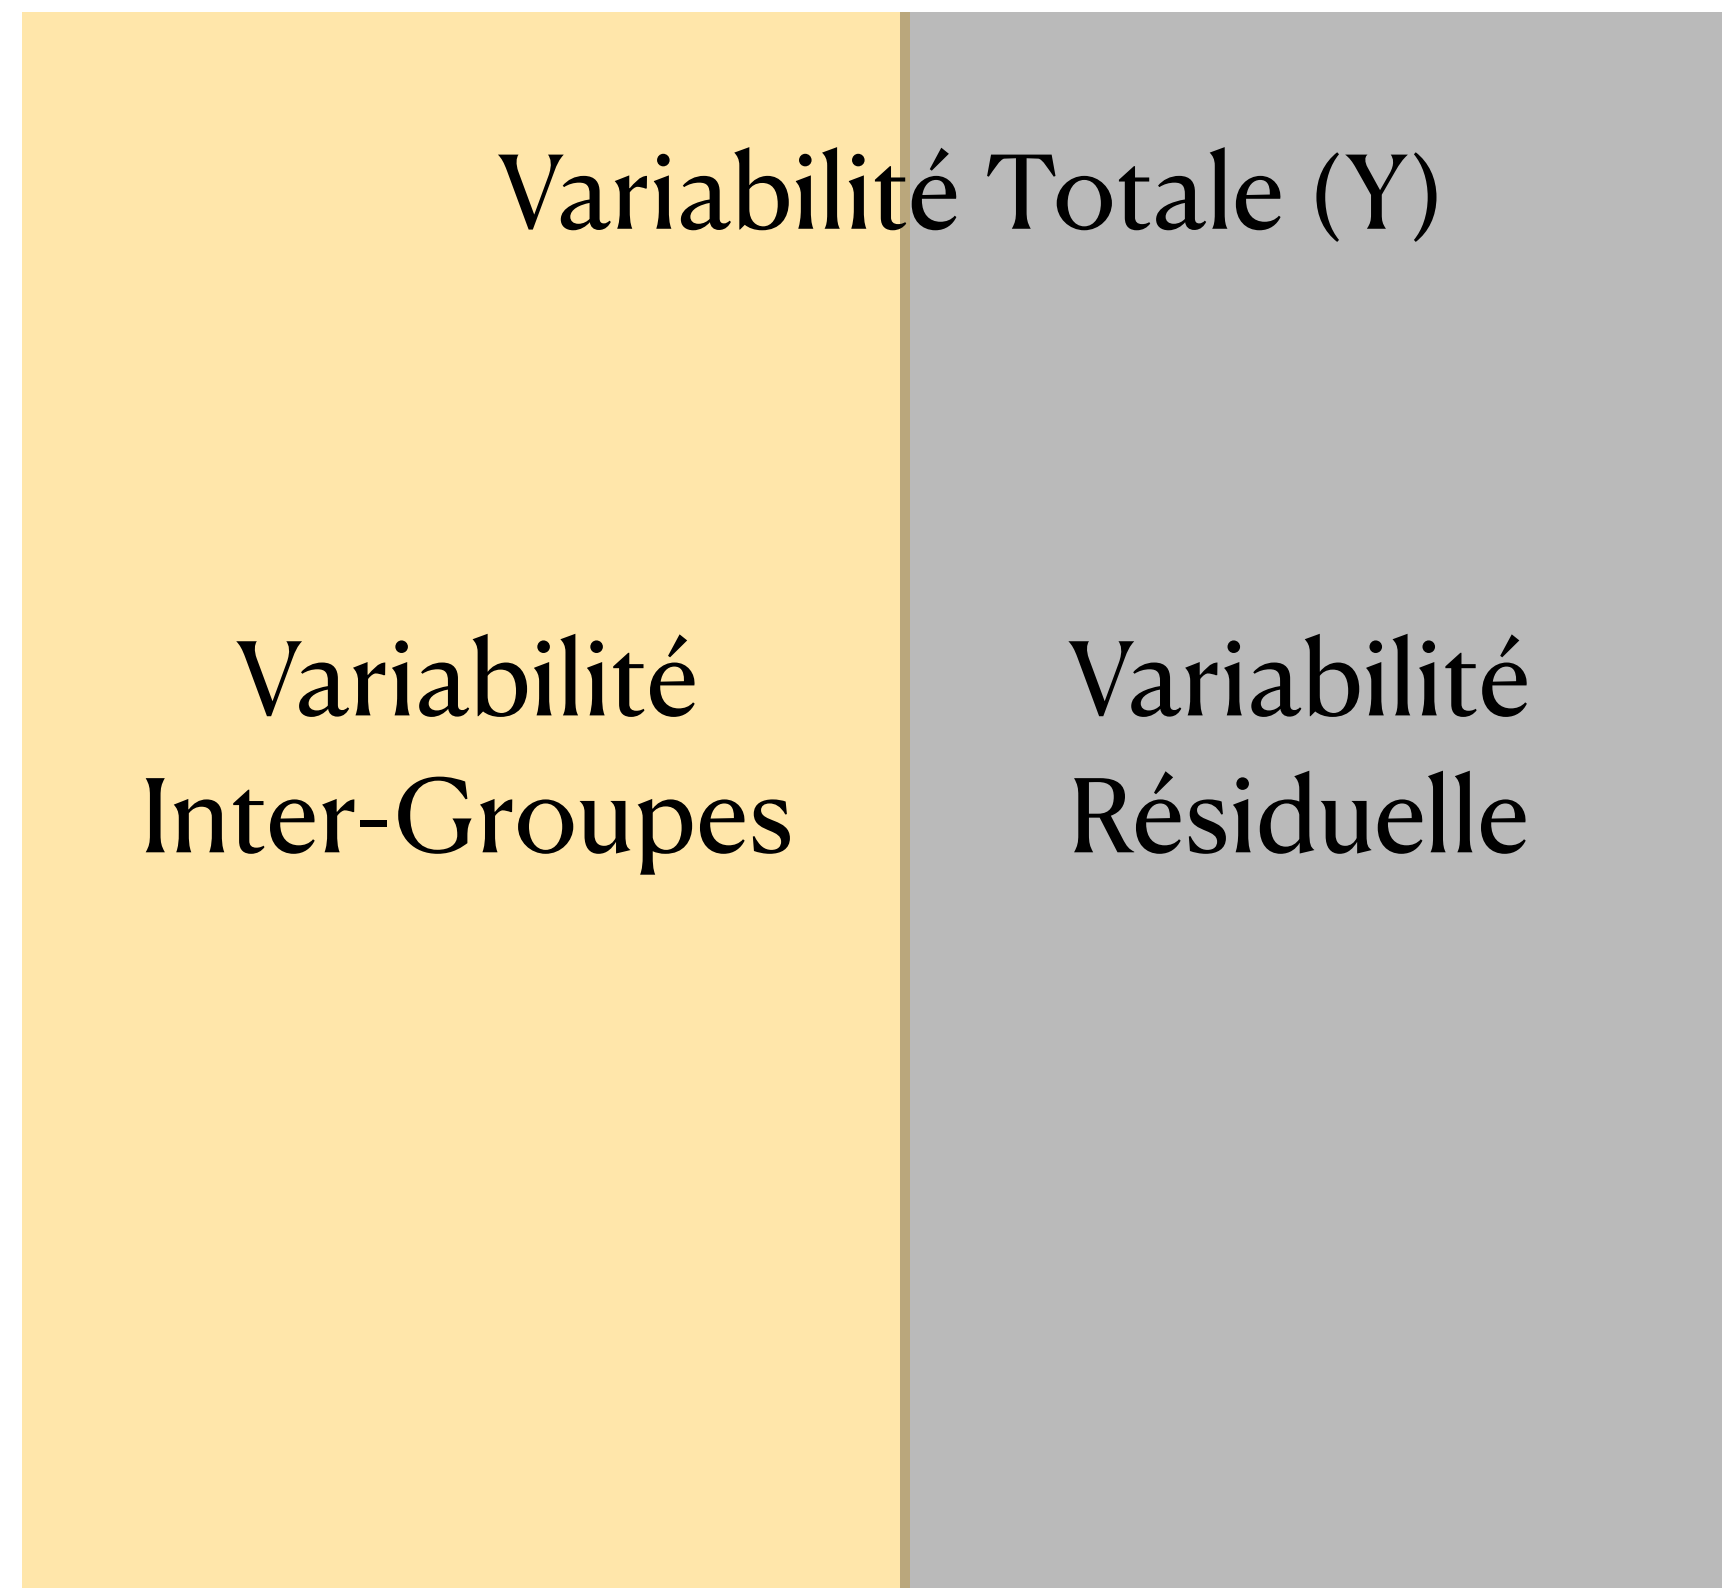
- La variabilité résiduelle est la variabilité de Y qui n'est pas associée au fait d'appartenir aux groupes c'est à dire



Variabilité résiduelle

Somme des Carrés des Ecartés Résiduels

- La variabilité résiduelle est la variabilité de Y qui n'est pas associée au fait d'appartenir aux groupes c'est à dire



$$SCE_Y = SCE_{Fact} + SCE_{Res}$$

Les ddl et les variances associées

Calculs

Les ddl et les variances associées

Calculs

- Le ddl factoriel est égal à $J-1$ et la variance factorielle à $s_{Fact.}^2 = \frac{SCE_{Fact.}}{J-1}$,

Les ddl et les variances associées

Calculs

- Le ddl factoriel est égal à $J-1$ et la variance factorielle à $s_{Fact.}^2 = \frac{SCE_{Fact.}}{J-1}$,
- Le ddl résiduel est égal à $N-J$ et la variance résiduelle à $s_{Res.}^2 = \frac{SCE_{Res.}}{N-J}$,

Les ddl et les variances associées

Calculs

- Le ddl factoriel est égal à $J-1$ et la variance factorielle à $s_{Fact.}^2 = \frac{SCE_{Fact.}}{J-1}$,
- Le ddl résiduel est égal à $N-J$ et la variance résiduelle à $s_{Res.}^2 = \frac{SCE_{Res.}}{N-J}$,
- La variance estimée de Y est égale à $s_Y^2 = \frac{SCE_Y}{N-1}$ (formule habituelle).

Le pourcentage de variation associée au facteur

ETA carré (η^2)

Le pourcentage de variation associée au facteur

ETA carré (η^2)

- Le pourcentage de variance associée au facteur F est définie par : $\eta^2 = \frac{SCE_{Fact.}}{SCE_Y} \times 100$

Le pourcentage de variation associée au facteur

ETA carré (η^2)

- Le pourcentage de variance associée au facteur F est définie par : $\eta^2 = \frac{SCE_{Fact.}}{SCE_Y} \times 100$
- Dans l'exemple $\eta^2 = \frac{1345.2}{2363.2} \times 100 = 56.9$. Ce qui signifie que 56.9% de la variabilité de la tolérance à la douleur est associée à la couleur des cheveux.

Le pourcentage de variation associée au facteur

ETA carré (η^2)

- Le pourcentage de variance associée au facteur F est définie par : $\eta^2 = \frac{SCE_{Fact.}}{SCE_Y} \times 100$
- Dans l'exemple $\eta^2 = \frac{1345.2}{2363.2} \times 100 = 56.9$. Ce qui signifie que 56.9% de la variabilité de la tolérance à la douleur est associée à la couleur des cheveux.

η^2	[0.01,0.06[[0.06,0.14[[0.14,1]
Effet	Faible	Modéré	Fort

Hypothèse testée

Hypothèse testée

- $H_0 : \mu_1 = \dots = \mu_J$

Hypothèse testée

- $H_0 : \mu_1 = \dots = \mu_J$
- $H_0 : \eta^2 = 0$

Hypothèse testée

- $H_0 : \mu_1 = \dots = \mu_J$
- $H_0 : \eta^2 = 0$
- H_0 : Les variations de Y ne sont pas significativement associées au facteur considéré

Hypothèse testée

- $H_0 : \mu_1 = \dots = \mu_J$
- $H_0 : \eta^2 = 0$
- H_0 : Les variations de Y ne sont pas significativement associées au facteur considéré
- H_0 : Il n'existe pas de différence significative au niveau de Y entre les J groupes considérés

Test de Fisher

Test Omnibus de l'ANOVA

Test de Fisher

Test Omnibus de l'ANOVA

Sous $H_0 : \mu_1 = \dots = \mu_J$ la statistique

$F = \frac{s_{Fact.}^2}{s_{Res.}^2}$ suit une loi de Fisher à

$(J - 1, N - J)$ degrés de liberté.

Test de Fisher


Test Omnibus de l'ANOVA

Sous $H_0 : \mu_1 = \dots = \mu_J$ la statistique

$$F = \frac{s_{Fact.}^2}{s_{Res.}^2} \text{ suit une loi de Fisher à}$$

$(J - 1, N - J)$ degrés de liberté.


Loi de Fisher pour différents (ddl1,ddl2)



Test de Test Omnibu

Sous $H_0 : \mu_1 = \dots = \mu_J$ la statistique

$$F = \frac{s_{Fact.}^2}{s_{Res.}^2}$$
 suit une loi de Fisher à
 $(J - 1, N - J)$ degrés de liberté.



ddl résiduel	p_value			
	0,1	0,05	0,01	0,001
10	2,728	3,708	6,552	12,553
11	2,660	3,587	6,217	11,561
12	2,606	3,490	5,953	10,804
13	2,560	3,411	5,739	10,209
14	2,522	3,344	5,564	9,729
15	2,490	3,287	5,417	9,335
20	2,380	3,098	4,938	8,098
25	2,317	2,991	4,675	7,451
30	2,276	2,922	4,510	7,054
35	2,247	2,874	4,396	6,787
40	2,226	2,839	4,313	6,595
50	2,197	2,790	4,199	6,336
60	2,177	2,758	4,126	6,171
120	2,130	2,680	3,949	5,781
inf	2,084	2,605	3,782	5,422



Résultat Test de Fisher

ANOVA à un facteur sur groupes indépendants

Résultat Test de Fisher

ANOVA à un facteur sur groupes indépendants

ANOVA - Pain Tolerance

Cases	Sum of Squares	df	Mean Square	F	p
Hair Color	1345.2	3	448.4	7.05	0.003
Residuals	1018.0	16	63.6		

Résultat Test de Fisher

ANOVA à un facteur sur groupes indépendants

ANOVA - Pain Tolerance

Cases	Sum of Squares	df	Mean Square	F	p
Hair Color	1345.2	3	448.4	7.05	0.003
Residuals	1018.0	16	63.6		

Une ANOVA à un facteur sur groupes indépendants a permis de mettre en évidence une relation entre la couleur des cheveux et la sensibilité à la douleur des individus de l'échantillon considéré, $F(3,16) = 7.05$, $p = .003$.

Attention : on parle de relation, d'association on ne parle pas de causalité ! On peut aussi dire « expliqué par » même si c'est moins exact.

Test Post-Hoc

Position du problème

Comparaison groupes à groupes

Position du problème

Comparaison groupes à groupes

- Lorsque le test de Fisher conduit au rejet de H_0 , c'est à dire qu'il existe une différence significative entre les moyennes des différents groupes alors on peut se poser la question de savoir quels sont les groupes qui sont différents les uns des autres.

Position du problème

Comparaison groupes à groupes

- Lorsque le test de Fisher conduit au rejet de H_0 , c'est à dire qu'il existe une différence significative entre les moyennes des différents groupes alors on peut se poser la question de savoir quels sont les groupes qui sont différents les uns des autres.
- On va comparer deux à deux les groupes mais on n'utilise pas le test de Student qui induirait un problème de niveau de la procédure.

Position du problème

Comparaison groupes à groupes

- Lorsque le test de Fisher conduit au rejet de H_0 , c'est à dire qu'il existe une différence significative entre les moyennes des différents groupes alors on peut se poser la question de savoir quels sont les groupes qui sont différents les uns des autres.
- On va comparer deux à deux les groupes mais on n'utilise pas le test de Student qui induirait un problème de niveau de la procédure.
- On va utiliser le test de Tukey qui est une version corrigée du test de Student.

Test Post-Hoc de Tukey

Mise en oeuvre du test

Test Post-Hoc de Tukey

Mise en oeuvre du test

- Soient A et B deux groupes parmi les J groupes que l'on veut comparer. On note leurs moyennes m_A, m_B .

Test Post-Hoc de Tukey

Mise en oeuvre du test

- Soient A et B deux groupes parmi les J groupes que l'on veut comparer. On note leurs moyennes m_A, m_B .
- On teste l'hypothèse $H_0 : \mu_A = \mu_B$ contre $H_1 : \mu_A \neq \mu_B$

Test Post-Hoc de Tukey

Mise en oeuvre du test

- Soient A et B deux groupes parmi les J groupes que l'on veut comparer. On note leurs moyennes m_A, m_B .
- On teste l'hypothèse $H_0 : \mu_A = \mu_B$ contre $H_1 : \mu_A \neq \mu_B$
- Sous H_0 la statistique $t_{A-B} = \frac{m_A - m_B}{\sqrt{\frac{2 \times s_{Res.}^2}{n}}}$ suit une loi de Tukey à $(J, ddl_{Res.})$ degrés de liberté.

Exemple de calcul

Test de Tukey

Exemple de calcul

Test de Tukey

ANOVA - Pain Tolerance

Cases	Sum of Squares	df	Mean Square	F	p
Hair Color	1345.2	3	448.4	7.05	0.003
Residuals	1018.0	16	63.6		

Descriptives - Pain Tolerance

Hair Color	Mean	s	n	
DBl	51,2	9,284	8,303	5
DBr	37,400	8,325	7,446	5
LB1	59,200	8,526	7,625	5
LBr	43,400	5,128	4,586	5

Exemple de calcul

Test de Tukey

ANOVA - Pain Tolerance

Cases	Sum of Squares	df	Mean Square	F	p
Hair Color	1345.2	3	448.4	7.05	0.003
Residuals	1018.0	16	63.6		

Descriptives - Pain Tolerance

Hair Color	Mean	s	n	
DBl	51,2	9,284	8,303	5
DBr	37,400	8,325	7,446	5
LB1	59,200	8,526	7,625	5
LBr	43,400	5,128	4,586	5

$$t_{DBl-DBr} = \frac{51.2 - 37.4}{\sqrt{\frac{2 \times 63.6}{5}}} = 2.736$$

Retour sur l'exemple

Table Résumé

Retour sur l'exemple


Table Résumé

Post Hoc Comparisons - Hair Color					
		Mean Diff.	SE	t	p tukey
DBr	LBr	6.000	5.045	1.189	0.642
	DB1	13.800	5.045	2.735	0.063
	LB1	21.800	5.045	4.321	0.003
LBr	DB1	7.800	5.045	1.546	0.435
	LB1	15.800	5.045	3.132	0.030
DB1	LB1	8.000	5.045	1.586	0.414

Retour sur l'exemple

Table Résumé

Post Hoc Comparisons - Hair Color					
		Mean Diff.	SE	t	p tukey
DBr	LBr	6.000	5.045	1.189	0.642
	DBl	13.800	5.045	2.735	0.063
	LB1	21.800	5.045	4.321	0.003
LBr	DB1	7.800	5.045	1.546	0.435
	LB1	15.800	5.045	3.132	0.030
DB1	LB1	8.000	5.045	1.586	0.414



On classe les groupes en fonction de leur moyenne (de la + grande à la plus petite ou le contraire !)

Vérification des conditions d'application de l'ANOVA

Conditions d'application


Normalité et homogénéité des variances

- La condition de normalité requise n'est en fait pas que $Y_j \sim \mathcal{N}(\mu_j, \sigma^2)$ mais que les résidus du modèle soit normaux. Pour le vérifier il suffit de faire le test de Shapiro-Wilk ou bien de regarder le Q-Q plot.
- La condition d'homogénéité des variances c'est à dire que $\sigma_1^2 = \dots = \sigma_J^2$ se vérifie avec le test de Levene.

Normalité des résidus

Test de Shapiro-Wilk

On teste H_0 les résidus standardisés du modèle suivent une loi normale contre H_1 les résidus ne sont pas distribués normalement. Ici la condition de normalité ne peut pas être rejetée, $W = .96$, $p = .553$.



Homogénéité des variances

Test de Levene

- On teste $H_0 : \sigma_1^2 = \dots = \sigma_j^2$ contre H_1 l'une au moins des variance est significativement différentes des autres.
- On considère pour ce faire le test de Levene (voir table ci-dessous) : on ne peut pas considérer au risque de 5% que l'une des variances est significativement différentes des autres, $F(3,16) = 0.511, p = .681$

Test for Equality of Variances (Levene's)			
F	df1	df2	p
0.511	3.000	16.000	0.681