



# Résultats de l'analyse différentielle, points de vigilance en statistiques

Gaëlle LELANDAIS

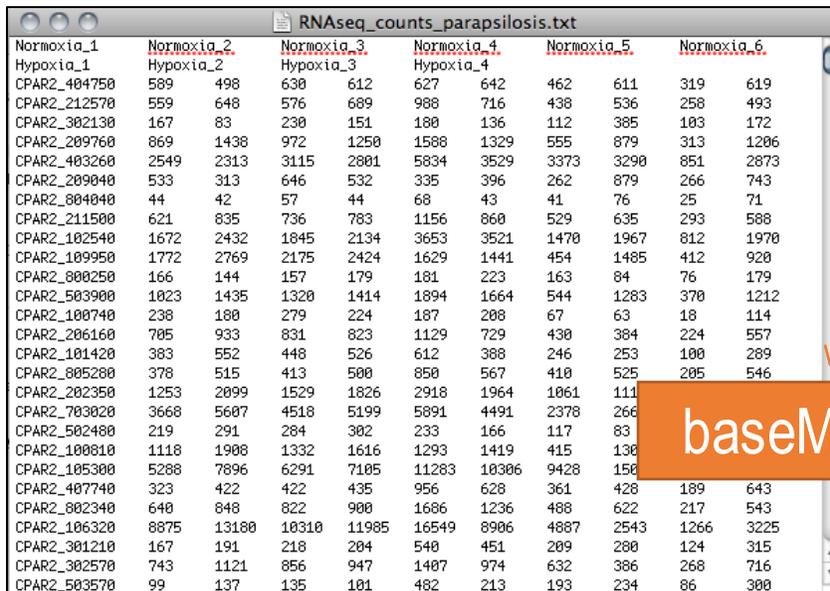
# Résultats d'une analyse différentielle

(et après ?)

➤ Table de comptage (*counts*)

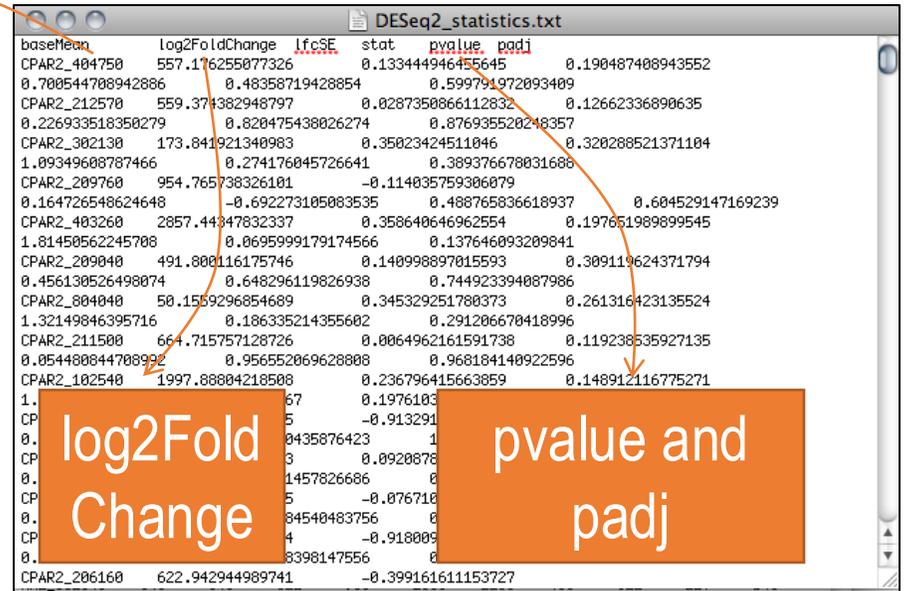
DESeq2  
→

➤ Table finale des résultats



Normoxia_1	Normoxia_2	Normoxia_3	Normoxia_4	Normoxia_5	Normoxia_6					
Hypoxia_1	Hypoxia_2	Hypoxia_3	Hypoxia_4							
CPAR2_404750	589	498	630	612	627	642	462	611	319	619
CPAR2_212570	559	648	576	689	988	716	438	536	258	493
CPAR2_302130	167	83	230	151	180	136	112	385	103	172
CPAR2_209760	869	1438	972	1250	1588	1329	555	879	313	1206
CPAR2_403260	2549	2313	3115	2801	5834	3529	3373	3290	851	2873
CPAR2_209040	533	313	646	532	335	396	262	879	266	743
CPAR2_804040	44	42	57	44	68	43	41	76	25	71
CPAR2_211500	621	835	736	783	1156	860	529	635	293	588
CPAR2_102540	1672	2432	1845	2134	3653	3521	1470	1967	812	1970
CPAR2_109950	1772	2769	2175	2424	1629	1441	454	1485	412	920
CPAR2_800250	166	144	157	179	181	223	163	84	76	179
CPAR2_503900	1023	1435	1320	1414	1894	1664	544	1283	370	1212
CPAR2_100740	238	180	279	224	187	208	67	63	18	114
CPAR2_206160	705	933	831	823	1129	729	430	384	224	557
CPAR2_101420	383	552	448	526	612	388	246	253	100	289
CPAR2_805280	378	515	413	500	850	567	410	525	205	546
CPAR2_202350	1253	2099	1529	1826	2918	1964	1061	1111		
CPAR2_703020	3668	5607	4518	5199	5891	4491	2378	2661		
CPAR2_502480	219	291	284	302	233	166	117	83		
CPAR2_100810	1118	1908	1332	1616	1293	1419	415	1301		
CPAR2_105300	5288	7896	6291	7105	11283	10306	9428	1501		
CPAR2_407740	323	422	422	435	956	628	361	428	189	643
CPAR2_802340	640	848	822	900	1686	1236	488	622	217	543
CPAR2_106320	8875	13180	10310	11985	16549	8906	4887	2543	1266	3225
CPAR2_301210	167	191	218	204	540	451	209	280	124	315
CPAR2_302570	743	1121	856	947	1407	974	632	386	268	716
CPAR2_503570	99	137	135	101	482	213	193	234	86	300

baseMean



baseMean	log2FoldChange	lfcSE	stat	pvalue	padj	
CPAR2_404750	557.176255877326	0.133444946455645	0.190487408943552	0.700544708942886	0.48358719428854	0.599791972093409
CPAR2_212570	559.374382948797	0.8287350866112832	0.12662336890635	0.226933518358279	0.828475438026274	0.876935520248357
CPAR2_302130	173.841921340983	0.35023424511046	0.320288521371104	CPAR2_209760	173.841921340983	0.35023424511046
CPAR2_403260	2549.2313	0.274176045726641	0.389376678031688	CPAR2_209040	533.313	0.274176045726641
CPAR2_209040	533.313	0.274176045726641	0.389376678031688	CPAR2_804040	44.42	0.274176045726641
CPAR2_211500	621.835	0.114035759306079	0.604529147169239	CPAR2_403260	2549.2313	0.274176045726641
CPAR2_102540	1672.2432	-0.692273105083535	0.488765836618937	CPAR2_804040	50.1559296854689	0.345329251780373
CPAR2_109950	1772.2769	0.285744347832337	0.197651989899545	CPAR2_209040	491.800	0.114035759306079
CPAR2_800250	166.144	0.8695999179174566	0.137646093209841	CPAR2_209040	491.800	0.114035759306079
CPAR2_503900	1023.1435	0.491800116175746	0.309119624371794	CPAR2_800250	166.144	0.114035759306079
CPAR2_100740	238.180	0.648296119826938	0.744923394087986	CPAR2_503900	1023.1435	0.114035759306079
CPAR2_206160	705.933	0.345329251780373	0.261316423135524	CPAR2_100740	238.180	0.114035759306079
CPAR2_101420	383.552	1.32149846395716	0.291206670418996	CPAR2_206160	705.933	0.114035759306079
CPAR2_805280	378.515	0.186335214355602	0.119238535927135	CPAR2_101420	383.552	0.114035759306079
CPAR2_202350	1253.2099	0.664715757128726	0.0064962161591738	CPAR2_805280	378.515	0.114035759306079
CPAR2_703020	3668.5607	0.054480044708992	0.968184140922596	CPAR2_202350	1253.2099	0.114035759306079
CPAR2_502480	219.291	1997.88804218508	0.236796415663859	CPAR2_703020	3668.5607	0.114035759306079
CPAR2_100810	1118.1908	0.956552069628808	0.148912116775271	CPAR2_502480	219.291	0.114035759306079
CPAR2_105300	5288.7896	0.236796415663859	0.1976103	CPAR2_100810	1118.1908	0.114035759306079
CPAR2_407740	323.422	0.0435876423	0.1976103	CPAR2_105300	5288.7896	0.114035759306079
CPAR2_802340	640.848	0.03	0.0920878	CPAR2_407740	323.422	0.114035759306079
CPAR2_106320	8875.13180	0.1457826686	0.0920878	CPAR2_802340	640.848	0.114035759306079
CPAR2_301210	167.191	0.05	0.076716	CPAR2_106320	8875.13180	0.114035759306079
CPAR2_302570	743.1121	0.84540483756	0.076716	CPAR2_301210	167.191	0.114035759306079
CPAR2_503570	99.137	0.4	-0.918009	CPAR2_302570	743.1121	0.114035759306079
		0.8398147556	0.076716	CPAR2_503570	99.137	0.114035759306079
		-0.399161611153727	0.076716			0.114035759306079

log2Fold Change

pvalue and padj

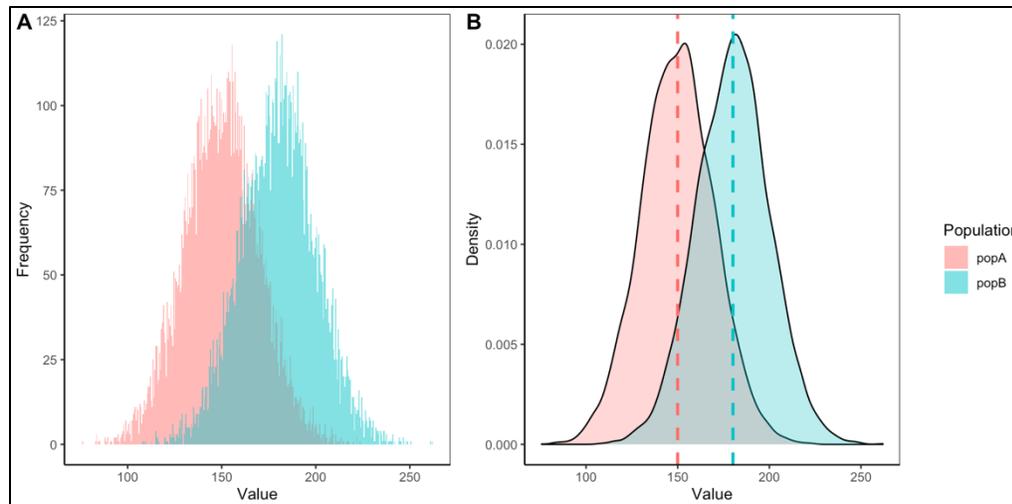
Votre travail consiste maintenant à **créer votre liste de gènes candidats**. Les paramètres statistiques peuvent vous aider à **prendre des décisions** raisonnées et argumentées. Ils ne décident pas à votre place.

# Confrontation des points de vue (biologique et statistique)

D'un point de vue biologique, un **gène différentiellement exprimé** est un gène dont l'expression est soumise à des **mécanismes de régulations différents** entre les conditions.

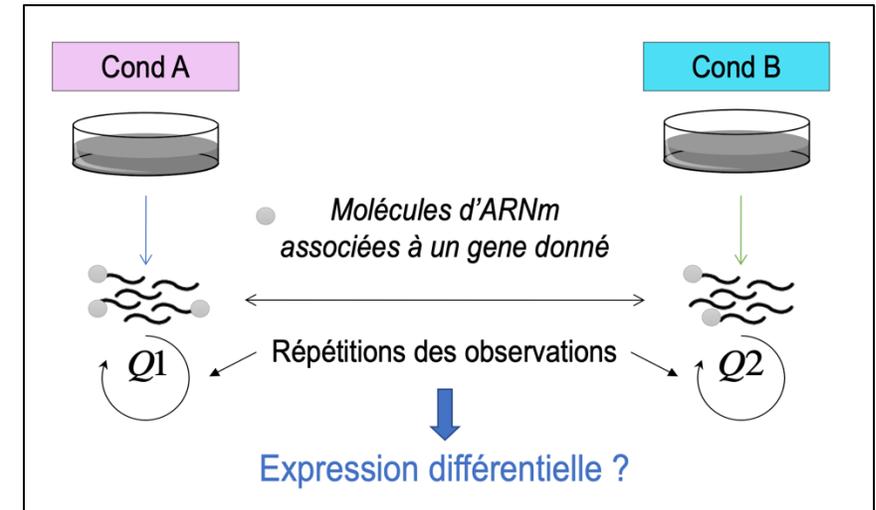
D'un point de vue statistique, un gène différentiellement exprimé est un gène dont la **loi de probabilité** (qui décrit son niveau d'expression) est différente entre les conditions.

➤ Simulation de données\* :



\* Simulations réalisées pour la formation du DU « Création, analyse et valorisation des données omiques »

➤ Stratégie expérimentale utilisées :

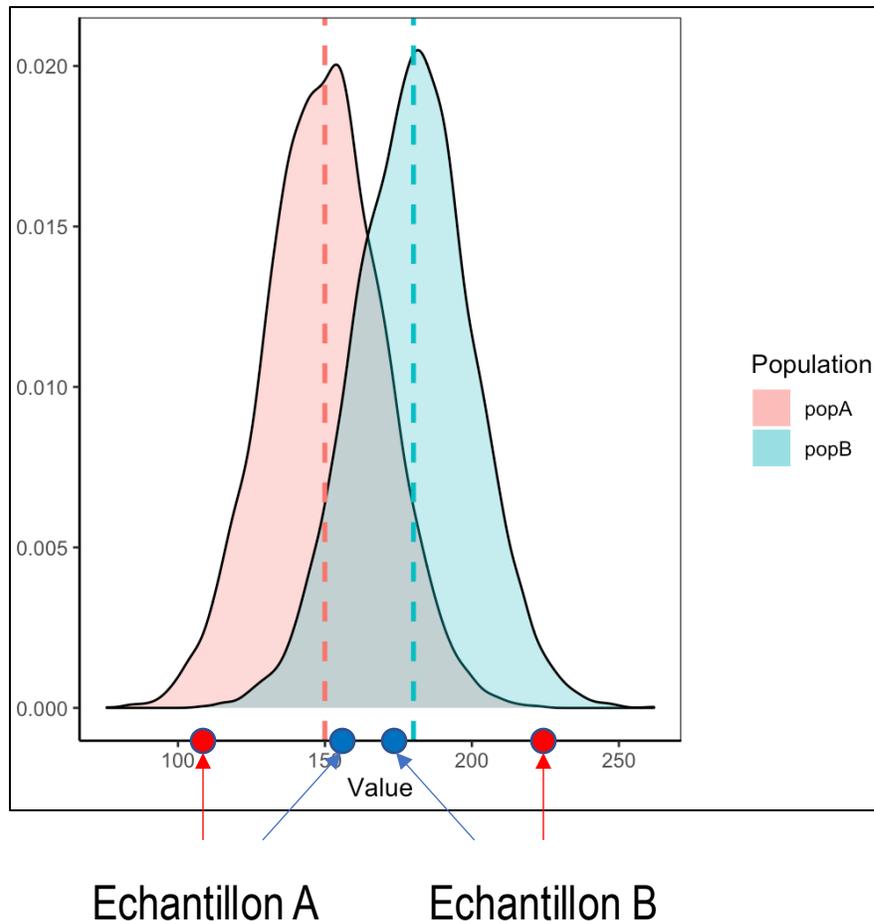


Les **paramètres statistiques** calculés, sont conditionnés aux modélisations statistiques sous-jacentes. Ces modèles ne **correspondent pas exactement** à la réalité.

« Tous les modèles sont faux, mais certains sont utiles » (George Box)

# Pourquoi le risque d'erreur existe ?

- Considérons un gène différentiellement exprimé (point de vue statistique). Son expression suit deux lois de probabilité distinctes (décrivent des populations).



- Considérons que des mesures de l'expression du gène ont été réalisées (décrivent des échantillons).

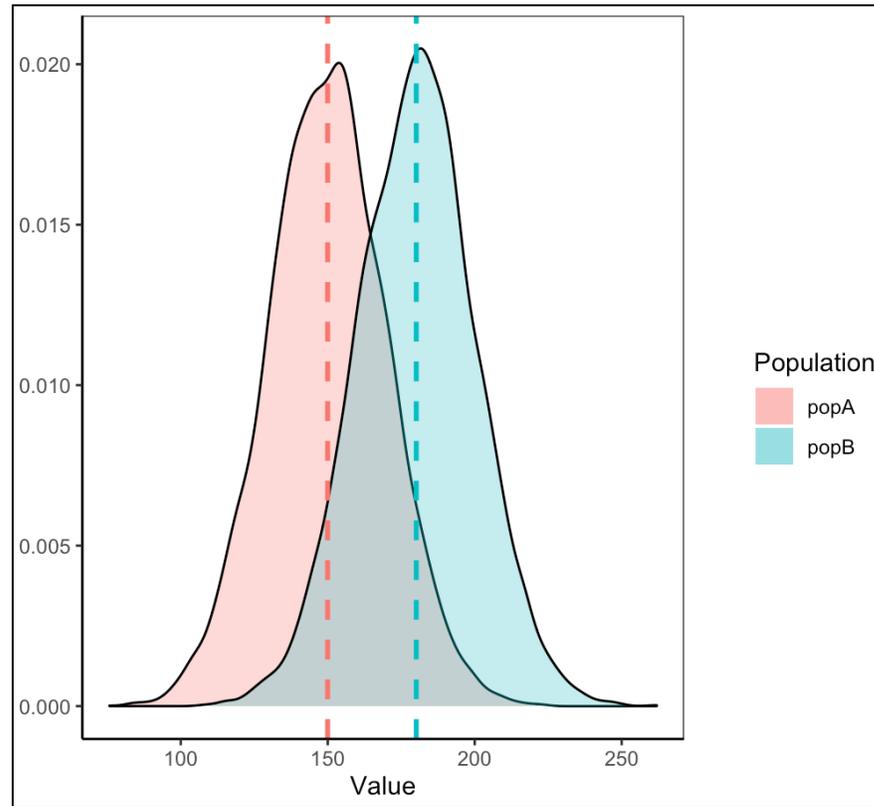
- **Possibilité 1** : Echantillons A et B très différents. Ce que nous observons est conforme à la réalité, le risque de se tromper est assez faible.
- **Possibilité 2** : Echantillons A et B peu différents. Pourtant le différentiel d'expression existe (!). Le risque de se tromper est alors élevé.

Inférence statistique consiste à « imaginer » comment sont les populations à partir des observations des échantillons.

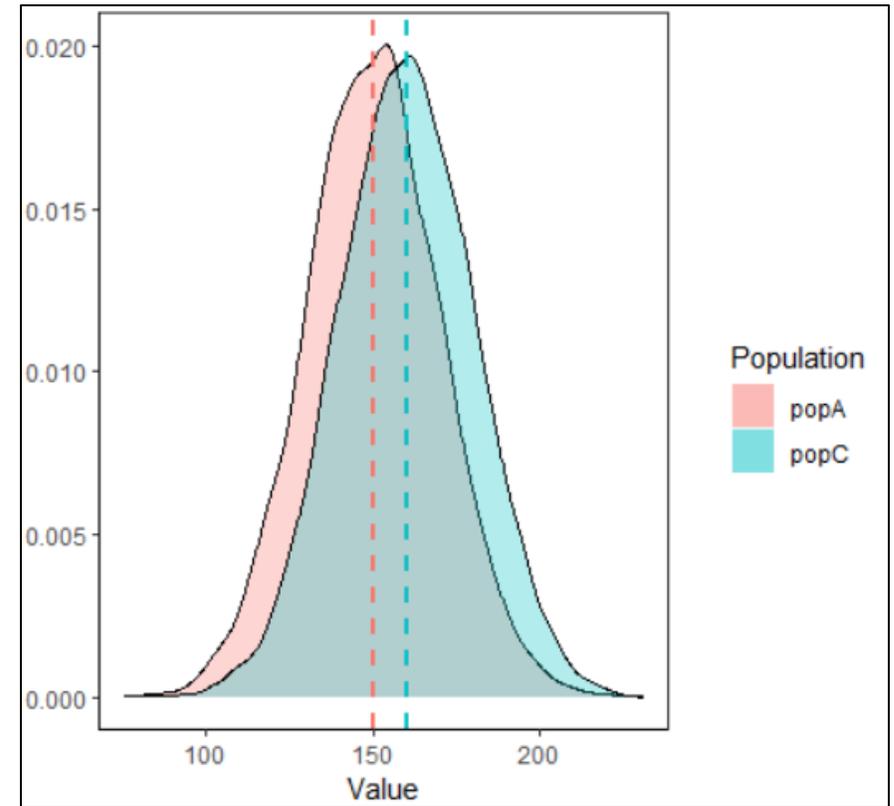
\* Simulations réalisées pour la formation du DU « Création, analyse et valorisation des données omiques »

# Des situations plus ou moins complexes

- La problématique de la taille d'effet existe également au niveau des populations. Dans les deux cas, le gène est différentiellement exprimé (point de vue statistique).



Inférence statistique difficile



Inférence statistique très difficile

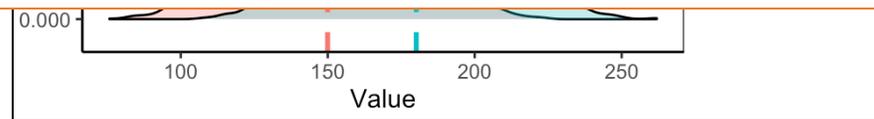
# Des situations plus ou moins complexes

- La problématique de la taille d'effet existe également au niveau des populations. Dans les deux cas, le gène est différentiellement exprimé (point de vue statistique).

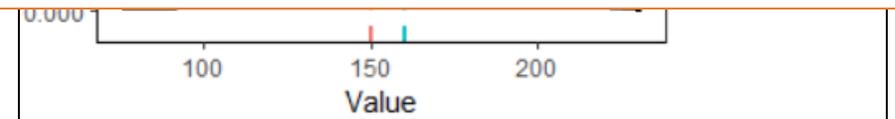
Lors d'une analyse différentielle, les inconnues sont très nombreuses :

Existe-t-il une régulation différenciée du gène ? (problématique biologique). Cette régulation a-t-elle un effet visible sur les mesures expérimentales réalisées ? Les modélisations statistiques de l'expression du gène sont-elles pertinentes pour cette régulation ? Les données sont-elles suffisantes pour estimer les paramètres des modèles ? (problématique statistique). Et bien d'autres...

Une grande vigilance est nécessaire lors de l'interprétation des résultats.



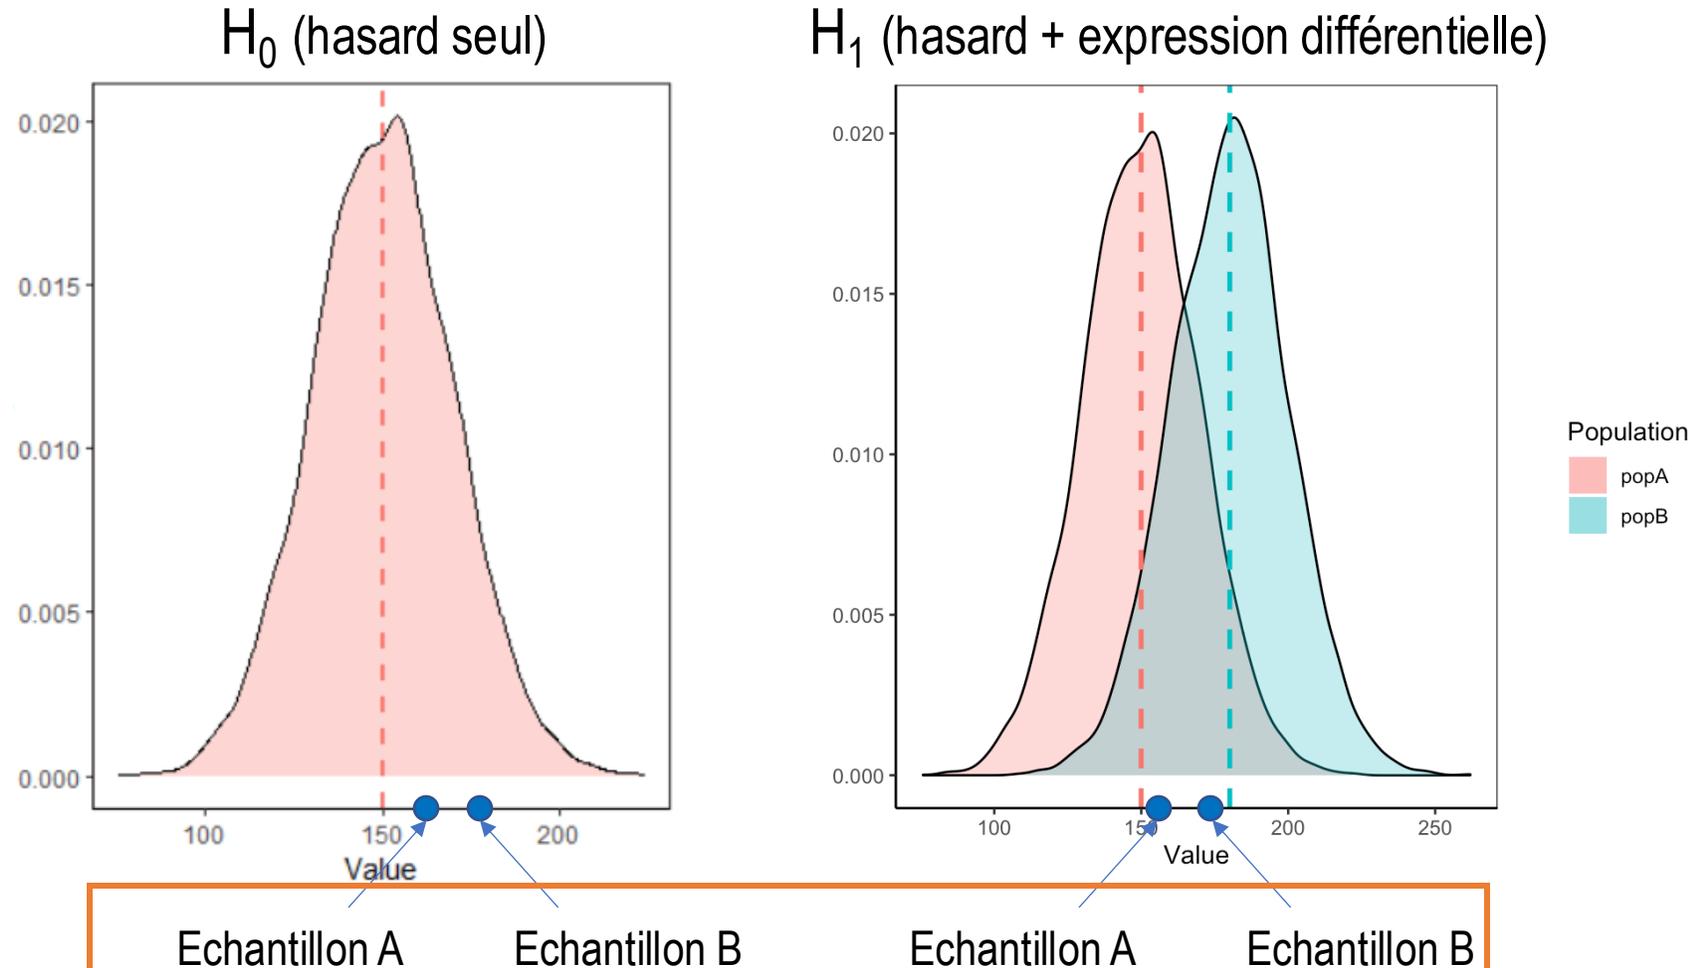
Inférence statistique difficile



Inférence statistique très difficile

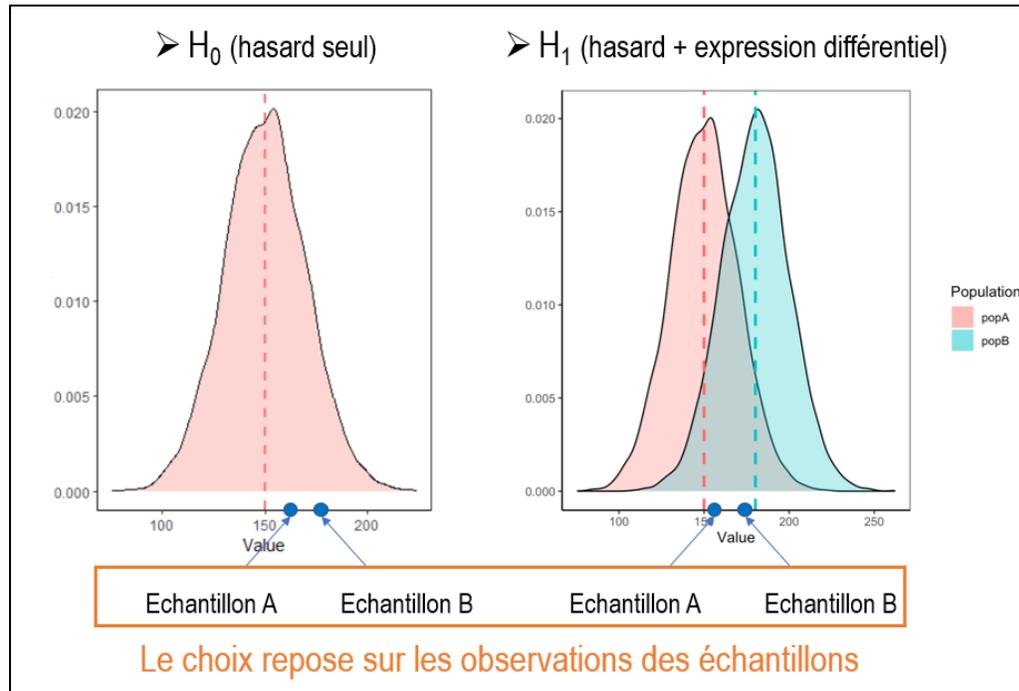
# Hypothèses statistiques (rappels)

- Quelle est la source des différences observées entre les échantillons A et B ?



Le choix repose sur les observations des échantillons

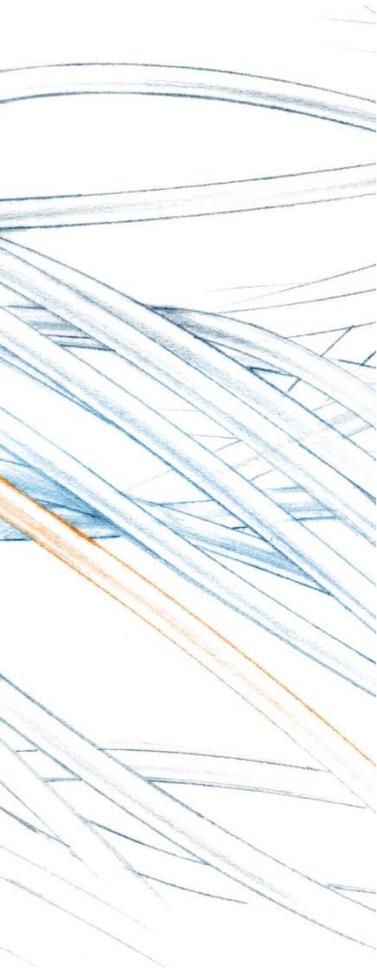
# Risques d'erreurs (associés à la prise de décision)



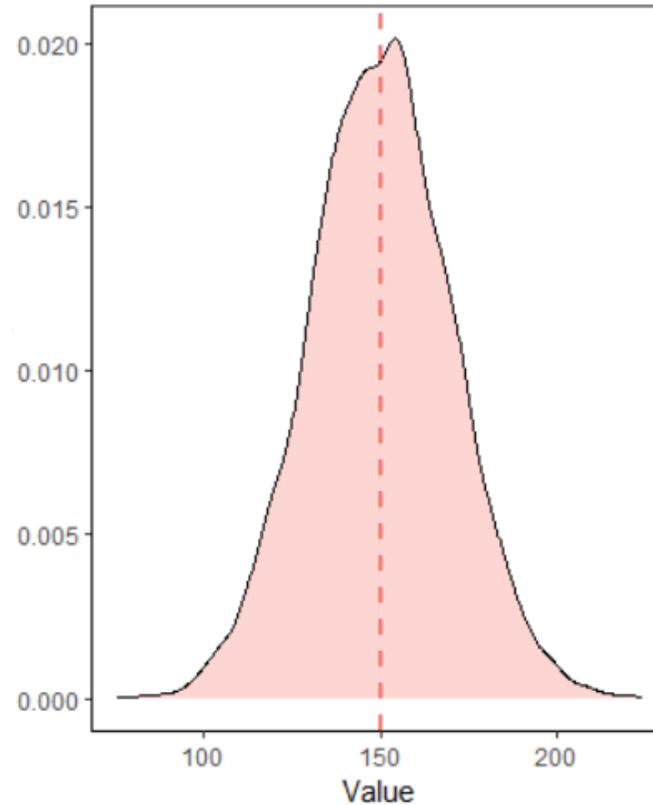
- **Faux positif** : Considérer que la différence est significative (choisir  $H_1$ ) alors qu'elle ne l'est pas ( $H_0$  est vraie).
- **Faux négatif** : Considérer que la différence n'est pas significative (choisir  $H_0$ ) alors qu'elle l'est ( $H_1$  est vraie).

	$H_0$ est vraie	$H_1$ est vraie
$H_0$ est choisie	Vrai négatif ✓	Faux négatif (risque de 2 <sup>nd</sup> espèce) ✗
$H_1$ est choisie	Faux positif (risque de 1 <sup>ère</sup> espèce) ✗	Vrai positif ✓

# Hypothèse nulle (seule modélisation possible)

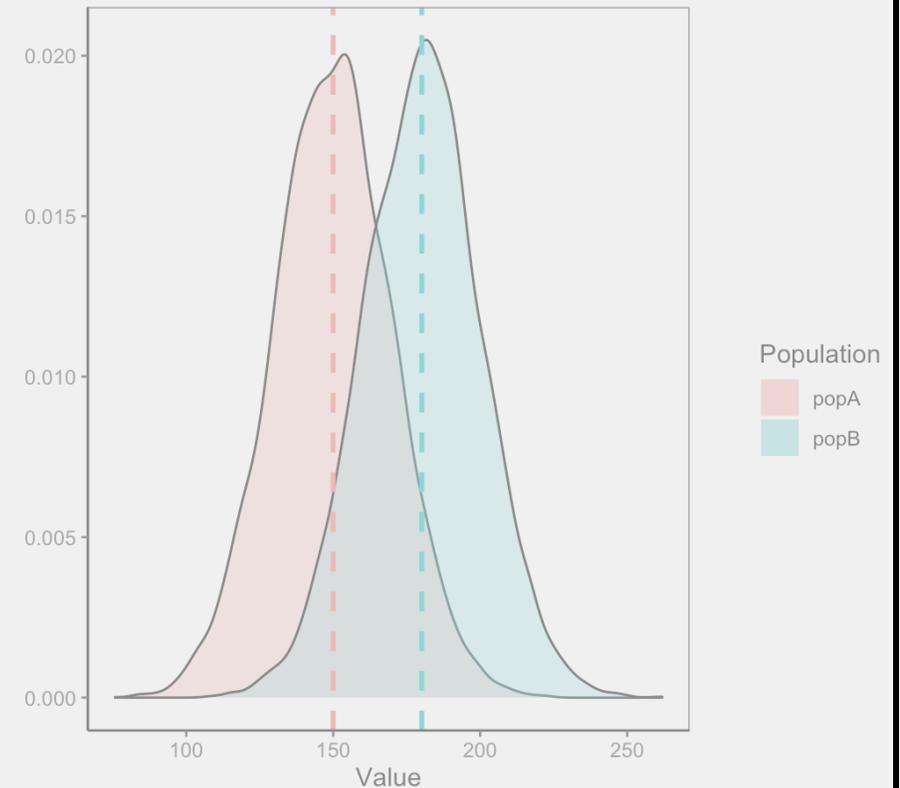


➤  $H_0$  (hasard seul)



Hypothèse considérée comme VRAIE pour la modélisation et les tests statistiques

➤  $H_1$  (hasard + expression différentiel)

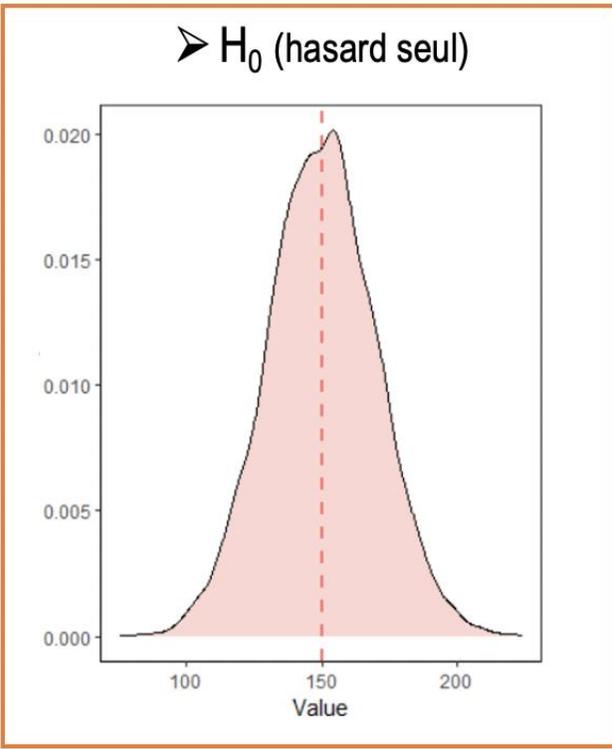


Hypothèse qui ne peut être modélisée car dépendante de paramètres inconnus

# Interpréter le résultat d'un test statistique

(point de vigilance 1/2)

➤ Une règle de décision (valable pour tous les gènes) a été construite, sur la base d'une valeur de risque de 1<sup>ère</sup> espèce (0.05 ou 0.01 généralement, risque *a priori*).



Hypothèse considérée comme VRAIE pour la modélisation et les tests statistiques

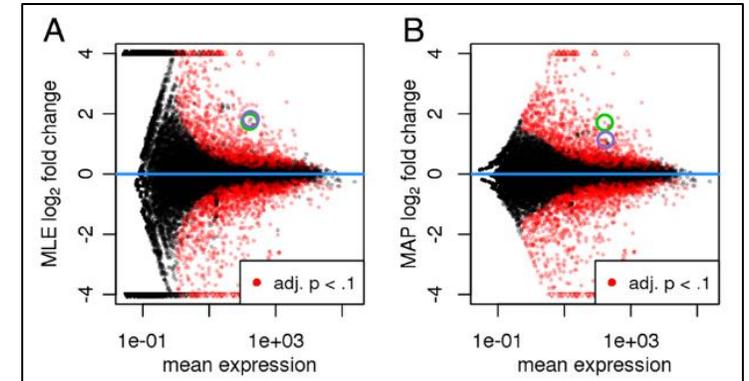
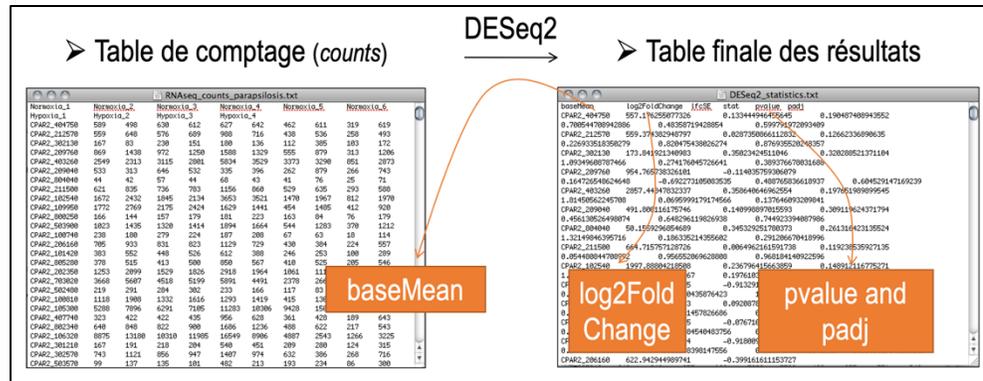
- ✔ Si la valeur P (pour un gène donné) est inférieure au risque *a priori*, la différence observée est « significative ». Un test statistique fournit une probabilité des observations (différences) conditionnellement à l'hypothèse nulle. C'est donc  $Pr(\text{Données} | H_0)$ .
- ✘ Un test statistique ne nous dit pas quelle hypothèse est la plus probable compte tenu des données, c'est-à-dire  $Pr(H_0 | \text{Données})$  et  $Pr(H_1 | \text{Données})$ .



Vigilance donc vis-à-vis des interprétations rapides telles que « plus la p-value est petite, plus j'ai de chance que le gène soit différentiellement exprimé » ou « plus la p-value est petite, plus le risque d'erreur est faible ».

# Interpréter le résultat d'un test statistique

(point de vigilance 2/2)



- ✓ Un **filtre sur la valeur P** est réalisé pour créer la **liste de gènes candidats** (différentiellement exprimés). La valeur P est ainsi le **seuil de signification observé**, permettant d'évoquer pour certains gènes un résultat de test « très significatif » ( $< 0.01$ ) ou seulement « significatif » ( $< 0.1$ )\*.
- ✗ Obtenir un résultat de test significatif ne démontre pas que **les hypothèses sont ou ne sont pas vraies**. Tous les calculs ont été réalisés en considérant que c'est l'hypothèse qui  $H_0$  est vraie.



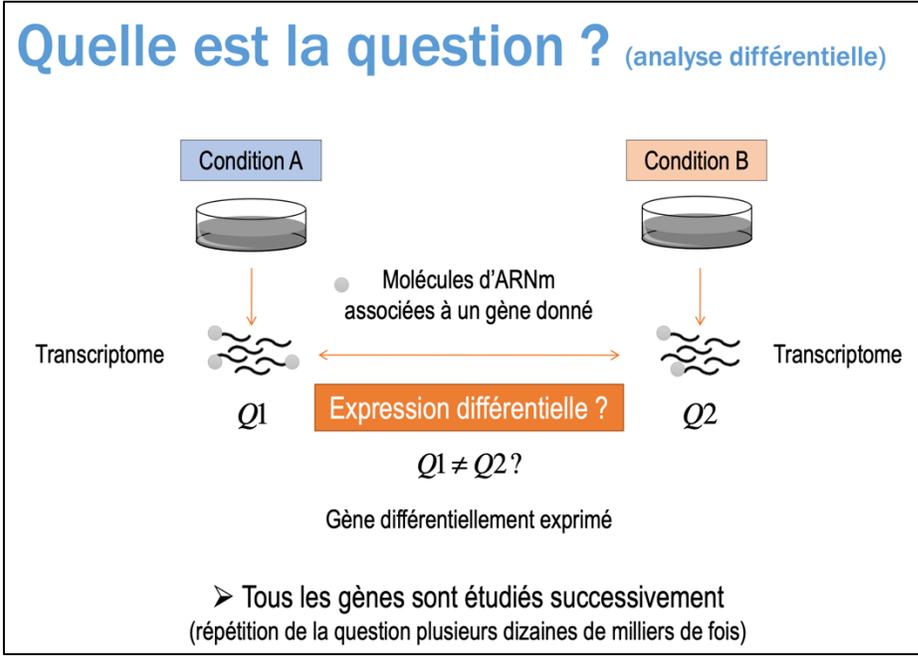
Vigilance donc vis-à-vis d'interprétations telles que « le test est significatif, le gène est différentiellement exprimé » ou bien « le test n'est pas significatif, le gène n'est pas différentiellement exprimé ».



\* Notez que si la valeur P est comparée à un risque *a priori*, le test sera juste « significatif » ou « non significatif ».

# Problématique des tests multiples

- Lors d'une analyse différentielle, la même question est posée plusieurs milliers de fois (nombre de gènes présents dans la table de comptage).



Dans le cas où les conditions A et B seraient identiques, aucun gène ne serait différentiellement exprimé (l'hypothèse  $H_0$  devrait être choisie pour tous les gènes).

Le risque de considérer que la différence est significative (choisir  $H_1$ ) alors qu'elle ne l'est pas ( $H_0$  est vraie) est égale au risque de 1<sup>ère</sup> espèce (souvent 0.05).

Si 10 000 tests statistiques sont réalisés, il est attendu (en moyenne\*) 500 gènes pour lesquels  $H_1$  est choisie alors que  $H_0$  est vraie.

	$H_0$ est vraie		$H_1$ est vraie
$H_0$ est choisie	Vrai négatif	✓	Faux négatif (risque de 2 <sup>nd</sup> espèce) ✗
$H_1$ est choisie	Faux positif (risque de 1 <sup>ère</sup> espèce)	✗	Vrai positif ✓

\* Espérance de la loi binomiale de paramètre  $p = 0.05$  et  $n = 10\ 000$ .

# Quelle valeur P utiliser ?

➤ Table de comptage (*counts*)

DESeq2  
→

➤ Table finale des résultats

Normoxia_1	Normoxia_2	Normoxia_3	Normoxia_4	Normoxia_5	Normoxia_6
Hypoxia_1	Hypoxia_2	Hypoxia_3	Hypoxia_4		
CPAR2_404750	589 498	630 612	627 642	462 611	319 619
CPAR2_212570	559 648	576 689	988 716	438 536	258 493
CPAR2_302130	167 83	230 151	180 136	112 385	103 172
CPAR2_209760	869 1438	972 1250	1588 1329	555 879	313 1206
CPAR2_403260	2549 2313	3115 2801	5834 3529	3373 3290	851 2873
CPAR2_209040	533 313	646 532	335 396	262 879	266 743
CPAR2_804040	44 42	57 44	68 43	41 76	25 71
CPAR2_211500	621 835	736 783	1156 860	529 635	293 588
CPAR2_102540	1672 2432	1845 2134	3653 3521	1470 1970	1967 812
CPAR2_109950	1772 2769	2175 2424	1629 1441	454 1485	412 920
CPAR2_800250	166 144	157 179	181 223	163 84	76 179
CPAR2_503900	1023 1435	1320 1414	1894 1664	544 1283	370 1212
CPAR2_100740	238 180	279 224	187 208	67 63	18 114
CPAR2_206160	705 933	831 823	1129 729	430 384	224 557
CPAR2_101420	383 552	448 526	612 388	246 253	100 289
CPAR2_805200	378 515	413 500	850 567	410 525	205 546
CPAR2_202350	1253 2099	1529 1826	2918 1964	1061 1111	
CPAR2_703020	3668 5607	4518 5199	5891 4491	2378 2666	
CPAR2_502480	219 291	284 302	233 166	117 83	
CPAR2_100010	1118 1908	1332 1616	1293 1419	415 130	
CPAR2_105300	5288 7896	6291 7105	11283 10306	9428 150	
CPAR2_407740	323 422	422 435	956 628	361 428	189 643
CPAR2_802340	640 848	822 900	1686 1236	488 622	217 543
CPAR2_106320	8875 13180	10310 11985	16549 8906	4887 2543	1266 3225
CPAR2_301210	167 191	218 204	540 451	209 280	124 315
CPAR2_302570	743 1121	856 947	1407 974	632 386	268 716
CPAR2_503570	99 137	135 101	482 213	193 234	86 300

baseMean

baseMean	log2FoldChange	lfcSE	stat	pvalue	padj
CPAR2_404750	557.176255877326	0.48358719428854	0.133444946455645	0.190487408943552	
CPAR2_212570	559.374382948797	0.8287350866112832	0.599791972093409	0.12662336890635	
CPAR2_302130	173.841921340983	0.820475438026274	0.876935520248357	0.320288521371104	
CPAR2_209760	173.841921340983	0.35023424511046	0.389376678031688		
CPAR2_403260	2857.44347832337	0.274176045726641	-0.114035759306079		
CPAR2_209040	954.765738326101	-0.692273105083535	0.488765836618937	0.604529147169239	
CPAR2_804040	2857.44347832337	0.358640646962554	0.197651989899545		
CPAR2_209040	491.800116175746	0.0695999179174566	0.137646093209841		
CPAR2_503900	1023.143513201414	0.140998897015593	0.309119624371794		
CPAR2_100740	238.180279224187	0.648296119826938	0.744923394087986		
CPAR2_206160	705.9338318231129	0.345329251780373	0.261316423135524		
CPAR2_101420	383.552448526612	0.186335214355602	0.291206670418996		
CPAR2_211500	621.835736715757128726	0.0064962161591738	0.119238535927135		
CPAR2_102540	1672.243218452134	0.956552069628808	0.968184140922596		
CPAR2_109950	1772.276921752424	0.236796415663859	0.148912116775271		
CPAR2_800250	166.144157179181	0.1976103			
CPAR2_502480	219.291284302233	0.0920878			
CPAR2_100010	1118.190813321616	0.1457826686			
CPAR2_105300	5288.789662917105	0.076710			
CPAR2_407740	323.422422435956	0.84540483756			
CPAR2_802340	640.8488229001686	0.918009			
CPAR2_106320	8875.1318010310	0.8398147556			
CPAR2_301210	167.191218204540				
CPAR2_302570	743.11218569471407				
CPAR2_503570	99.137135101482				

log2Fold Change

pvalue and padj

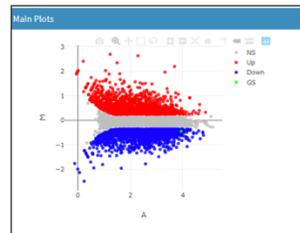
Il existe différentes stratégies pour « ajuster » la valeur P, et ainsi tenir compte de la problématique des tests multiples. Si les valeurs P ajustées sont plus élevées que les valeurs P initiales, elles ne changent pas l'ordre des gènes. Celui qui avait la plus petite valeur P aura toujours la plus petite valeur P ajustée.

# Bilan

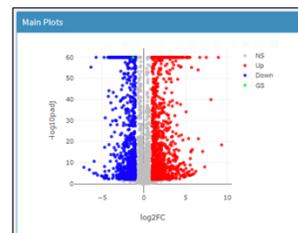
- La mise en application de méthodes statistiques est très utile pour identifier (sans *a priori*) des gènes intéressants, bons candidats pour être différentiellement exprimés.

## Bilan des représentations graphiques (application WEB)

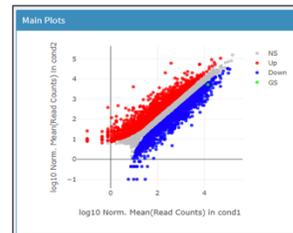
- Filtre de sélection par défaut :  $p_{adj} < 0.01$  ou  $FC > 2$



MA plot



Volcano plot



Scatter plot

- Données initiales, pour un gène donné



Vigilance vis-à-vis de la sur-interprétation des résultats (positivement ou négativement)

Les statistiques sont une aide précieuse à la prise de décision (mais vous seul(e) restez responsable)

# Ressource(s) complémentaire(s)

- Vidéo de présentation du cours (replay, 16 minutes)  
<https://youtu.be/CiP7tO0jOsM>

