



STATISTIQUE INFÉRENTIELLE



Tests d'ajustement

Test χ^2 d'ajustement de Pearson


- on dispose d'une distribution observée (n observations réparties en p classes) que l'on veut comparer à une distribution théorique
- $\chi_{obs}^2 = \sum_{i=1}^p \frac{(n_i - nP_i)^2}{nP_i}$ suit une loi du χ^2 à $(p - 1)$ ddl (si H_0 vraie)
- on rejète l'hypothèse d'adéquation si $\mathbb{P}(\chi^2 > \chi_{obs}^2) < \alpha$
 - le test est toujours unilatéral
 - condition d'utilisation : $nP_i > 5$
- nb : si la distribution théorique n'est pas complètement définie (cas le plus fréquent) alors les valeurs des P_i doivent être déterminées à partir des observations. Dans ce cas le nombre ddl doit être diminué du nombre de paramètres estimés




Analyse de la variance (ANOVA)


analyse de variance à un facteur : variable quantitative = longueur de la tige,
facteur = lignée (3 niveaux)

ratio variation inter-groupes/intra-groupe ($S^2_{\text{between}}/S^2_{\text{within}}$) fort



ratio variation inter-groupes/intra-groupe ($S^2_{\text{between}}/S^2_{\text{within}}$) faible





Analyse de la variance (ANOVA)

le tableau de l'ANOVA à un facteur

source de variation	degré de liberté	somme des carrés des écarts (SCE)	variances (carrés moyens)	F_{obs}	p-value
inter-groupes (facteur)	p-1	SCE_b	s_b^2	$\frac{s_b^2}{s_w^2}$	$\mathbb{P}_{H_0}(F > F_{obs})$
intra-groupes (résidus)	n-p	SCE_w	s_w^2		
total	n-1	SCE_t	s_t^2		

- $s_b^2 = \frac{SCE_b}{p-1} = \frac{1}{p-1} \sum_{i=1}^p n_i (\bar{x}_i - \bar{x})^2$, p= nombre de niveaux de facteurs (i.e. nb de groupes)
- $s_w^2 = \frac{SCE_w}{n-p} = \frac{1}{n-p} \sum_{i=1}^p \sum_{k=1}^{n_i} (x_{ik} - \bar{x}_i)^2$
- si H_0 est vraie, F_{obs} suit une loi $F_{(p-1, n-p)}$ ddl
- on rejète H_0 si $\mathbb{P}_{H_0}(F > F_{obs}) < \alpha$
- ATTENTION : $SCE_t = SCE_b + SCE_w$ mais $s_t^2 \neq s_b^2 + s_w^2$



Analyse de la variance (ANOVA)

ANOVA à un facteur : modèle théorique

l'ANOVA est un modèle linéaire de régression sur une variable catégorielle

- **le modèle fixe :**

- **modèle théorique :** $X_{ik} = \mu_i + \epsilon_{ik} = \mu + \alpha_i + \epsilon_{ik}$
- où α_i : **non aléatoires**, $\epsilon_{ik} \sim \mathcal{N}(0, \sigma)$
- $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_p = 0$

- le modèle aléatoire :

- modèle théorique : $X_{ik} = \mu + A_i + \epsilon_{ik}$
- où $A_i \sim \mathcal{N}(0, \sigma_a)$, $\epsilon_{ik} \sim \mathcal{N}(0, \sigma)$
- $H_0 : \sigma_a^2 = 0$

le modèle fixe

- modèle théorique : $X_{ik} = \bar{x} + a_i + \epsilon_{ik}$
 - où a_i : non aléatoires, $\epsilon_{ik} \sim \mathcal{N}(0, \sigma)$
 - $\bar{x} = \frac{1}{n} \sum_{i=1}^n n_i m_i$, $\sum_{i=1}^p n_i a_i = 0$
- $H_0 : a_1 = a_2 = \dots = a_p = 0$
 - $\mathbb{E}(s_b^2) = \sigma^2 + \frac{1}{p-1} \sum_{i=1}^p n_i a_i^2$
 - $\mathbb{E}(s_w^2) = \sigma^2$
- si H_0 est vraie, alors $\mathbb{E}(s_b^2) = \mathbb{E}(s_w^2) = s_t^2$



Comparaisons multiples de moyennes


- **localiser les inégalités entre moyennes suite à une analyse de variance** : quels sont les groupes qui possèdent des moyennes significativement différentes ?
- **conditions d'utilisation** :
 - populations normales, de même variance
 - échantillons aléatoires, simples et indépendants
- comparaison avec un témoin :
 - test de Dunnett : $LSD_{i1} = t_{dunnett(1-\frac{\alpha}{2})} \sqrt{s_w^2 (\frac{1}{n_i} + \frac{1}{n_1})}$
 - si la différence de moyenne entre groupe i et 1 est supérieur à LSD_{i1} , on rejète H_0 (égalité de moyennes entre i et 1)
 - test LSD (Least Significant Difference) de Fisher :
 - $LSD_{ij} = t_{student(\nu; 1-\frac{\alpha}{2})} \sqrt{s_w^2 (\frac{1}{n_i} + \frac{1}{n_j})}$, avec $\nu = n - p$
 - si la différence de moyenne entre groupe i et j est supérieur à LSD_{ij} , on rejète H_0 (égalité de moyennes entre i et j)
 - = test de student (t-test), en utilisant s_w^2 comme estimateur de σ^2
 - ne contrôle pas le risque global d'erreur α (voir plus loin)

Analyse de la variance (ANOVA)

le tableau de l'ANOVA à deux facteurs (effets fixes)





source de variation	degré de liberté	somme des carrés des écarts (SCE)	variances (carrés moyens)	F_{obs}
facteur A	$p-1$	SCE_a	s_a^2	$\frac{s_a^2}{s_w^2}$
facteur B	$q-1$	SCE_b	s_b^2	$\frac{s_b^2}{s_w^2}$
interaction AxB	$(p-1)(q-1)$	SCE_{ab}	s_{ab}^2	$\frac{s_{ab}^2}{s_w^2}$
variation résiduelle	$n-pq$	SCE_w	s_w^2	
total	$n-1$	SCE_t	s_t^2	

- tester l'interaction (F_{AB})
- en l'absence d'interaction ($\mathbb{P}(F > F_{AB}) < \alpha$) on peut tester les effets principaux (F_A et F_B)



Analyse de la variance (ANOVA)

ANOVA à 2 facteurs : effet du type d'engrais (A et B) et des températures (L =low et H =high) sur la hauteur de plantes



Analyse de la variance (ANOVA)

ANOVA à 2 facteurs : effet du type d'engrais (*A* et *B*) et des températures (*L*=low et *H*=high) sur la hauteur de plantes

source de variation	degré de liberté	somme des carrés des écarts (SCE)	variances (carrés moyens)	F_{obs}	p-value
température	1	370.56	370.56	41.85	3.07×10^{-5}
engrais	1	0.56	0.56	0.06	0.80
interaction	1	60.06	60.06	6.78	0.023
intra-groupes (résidus)	12	106.25	8.85		

- p-valeurs tests de Student comparaison 2 à 2 : 0.00056, 0.03833, 0.1790, 0.06529 pour "AL vs AH", "BL vs BH", "BH vs AH", "BL vs AL"
- p-valeurs corrigées pour comparaisons multiples de moyenne : 0.0002, 0.0545, 0.1326, 0.1326
- il n'y a pas d'effet global du facteur "engrais", il y a un effet "température" mais essentiellement en présence de l'engrais "A" (interaction)



Analyse de la variance (ANOVA)

ANOVA à deux facteurs : le modèle aléatoire (random effect model)

- 2 facteurs aléatoires A et B (ex : différents appareils de mesure et différents opérateurs)
- modèle théorique : $X_{ijk} = \mu + A_i + B_j + C_{ij} + \epsilon_{ijk}$
- où $A_i \sim \mathcal{N}(0, \sigma_a)$, $B_j \sim \mathcal{N}(0, \sigma_b)$, $C_{ij} \sim \mathcal{N}(0, \sigma_{ab})$, et $\epsilon_{ijk} \sim \mathcal{N}(0, \sigma)$

source de variation	degré de liberté	somme des carrés des écarts (SCE)	variances (carrés moyens)	F_{obs}
facteur A	p-1	SCE_a	s_a^2	$\frac{s_a^2}{s_w^2}$
facteur B	q-1	SCE_b	s_b^2	$\frac{s_b^2}{s_w^2}$
interaction AxB	(p-1)(q-1)	SCE_{ab}	s_{ab}^2	$\frac{s_{ab}^2}{s_w^2}$
variation résiduelle	n-pq	SCE_w	s_w^2	
total	n-1	SCE_t	s_t^2	

- tester l'interaction : $F_{AB} = \frac{s_{ab}^2}{s_w^2}$
- en l'absence d'interaction on peut tester les effets principaux $F_A = \frac{s_a^2}{s_{ab}^2}$ et $F_B = \frac{s_b^2}{s_{ab}^2}$
- $\mathbb{E}(s_a^2) = \sigma^2 + nq\sigma_a^2 + n\sigma_{ab}^2$
- $\mathbb{E}(s_b^2) = \sigma^2 + np\sigma_b^2 + n\sigma_{ab}^2$
- $\mathbb{E}(s_{ab}^2) = \sigma^2 + n\sigma_{ab}^2$, $\mathbb{E}(s_w^2) = \sigma^2$

Analyse de la variance (ANOVA)

ANOVA à deux facteurs : le modèle mixte (mixed effect model)

- un facteur fixe A , un facteur aléatoire B (ex : 4 traitements - effet fixe "traitement", 3 répétitions biologiques - effet aléatoire "individu", 2 analyses par échantillon)
- modèle théorique : $X_{ijk} = \mu + \alpha_i + B_j + C_{ij} + \epsilon_{ijk}$
- où α_i non aléatoire, $B_j \sim \mathcal{N}(0, \sigma_b)$, $C_{ij} \sim \mathcal{N}(0, \sigma_{ab})$, et $\epsilon_{ijk} \sim \mathcal{N}(0, \sigma)$

source de variation	degré de liberté	somme des carrés des écarts (SCE)	variances (carrés moyens)	F_{obs}
facteur A (fixe)	p-1	SCE_a	s_a^2	$\frac{s_a^2}{s_w^2}$
facteur B (aléatoire)	q-1	SCE_b	s_b^2	$\frac{s_b^2}{s_w^2}$
interaction AxB	(p-1)(q-1)	SCE_{ab}	s_{ab}^2	$\frac{s_{ab}^2}{s_w^2}$
variation résiduelle	n-pq	SCE_w	s_w^2	
total	n-1	SCE_t	s_t^2	

- tester l'interaction : $F_{AB} = \frac{s_{ab}^2}{s_w^2}$
 - en l'absence d'interaction on peut tester les effets principaux $F_A = \frac{s_a^2}{s_{ab}^2}$ (effet fixe vs interaction)
- et $F_B = \frac{s_b^2}{s_w^2}$ (effet aléatoire vs erreur résiduelle)



Analyse de la variance (ANOVA)

ANOVA à deux facteurs : modèle à facteurs imbriqués - hiérarchisé (nested model)

- un facteur fixe ou aléatoire A
- un facteur subordonné, généralement aléatoire, $B(A)$
- exemple : un facteur fixe "type de prairie", un facteur subordonné "la prairie"
- modèle théorique : $X_{ijk} = \mu + \alpha_i + B_{j(i)} + \epsilon_{ijk}$
- test des effets de chaque facteur :

- $F_A = \frac{s_a^2}{s_{b(a)}^2}$

- $F_B = \frac{s_{b(a)}^2}{s_w^2}$

Test du rapport de vraisemblance (likelihood ratio test)

- au lieu du test F on peut utiliser le LRT pour tester $H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_p = 0$
- ce test est utilisé pour comparer 2 modèles "emboîtés" (pas des facteurs emboîtés!)
- modèle 1 : $y_i = \alpha_0 + e_i$
- modèle 2 : $y_i = \alpha_0 + \alpha_1 x_{i1} + \alpha_2 x_{i2} + \dots + \alpha_p x_{ip} + e_i$
- la log-vraisemblance est définie par $l(\mu_j, y_j) = \log[f_Y(y_j, \theta)]$
- la déviance entre les modèles 1 et 2 est définie par $D(y, \mu) = -2[l(\mu, y) - l(y, y)]$ (i.e. la différence entre le modèle estimé et le modèle saturé - autant de paramètres que d'observations)
- si un modèle M_1 est imbriqué dans un autre modèle M_2 , alors la différence des déviances $D_1 - D_2$ suit un $\chi_{p-2-p_1}^2$
- pour tester un seul coefficient du modèle, on utilise $D = -2 \log \frac{\text{vraisemblance du modèle sans la variable}}{\text{vraisemblance du modèle avec la variable}}$ qui suit un χ_1^2
- pour comparer des modèles non emboîtés :
 - AIC (Akaike Information Criterion) : $AIC = 2k - 2\ln(L)$, avec k le nombre de paramètres du modèle théorique, et L la valeur maximum de la vraisemblance pour le modèle estimé ("fit" du modèle estimé par rapport au modèle théorique)
 - BIC (Bayesian Information Criterion) : $BIC = -2\ln(L) + k \ln(n)$

Extension de l'analyse de la variance

Analyse de la covariance (ANCOVA)

- a pour but d'étudier l'effet d'une variable qualitative (facteur) et d'une variable continue (covariable) sur une variable réponse (comparaisons de moyennes en tenant compte des effets d'une variable auxiliaire -covariable- quantitative)
- modèle théorique : $Y_{ik} = \mu + \alpha_i + \beta(X_{ik} - \bar{x}) + \epsilon_{ijk}$
- où Y = variable étudiée et X la covariable

Modèle linéaire généralisé (GLM)

- les modèles linéaires généralisés permettent d'étudier la liaison entre une variable réponse Y et un ensemble de variables explicatives ou prédicteurs $X_1, X_2 \dots X_K$
- ils englobent :
 - le modèle linéaire général (régression multiple, ANOVA, ANCOVA)
 - le modèle log-linéaire
 - la régression logistique
 - la régression de Poisson
- formule générale : $y = X\beta + \epsilon$, où :
 - y = vecteur des observations
 - X = matrice des valeurs des variables explicatives (régression linéaire) ou indicatrices (analyse de variance)
 - β = vecteur des paramètres du modèle
 - ϵ = vecteur des termes d'erreurs



Notion de correction pour les tests multiples

comparer simultanément l'expression de milliers de gènes entre 2 conditions

- si chaque test est réalisé à un risque α
- si l'on réalise G test indépendants (pour les G gènes)
- ALORS nombre moyen de faux positifs = $G\alpha$
- $G = 10000$, $\alpha = 0.05$, alors 500 gènes sont déclarés différentiellement exprimés à tort
- d'où l'idée de contrôler les risques du test multiple dont H_0 ="tous les gènes n'ont pas de différence d'expression entre les traitements", et H_1 ="il existe au moins un gène différentiellement exprimé"
- après un test multiple : P gènes sont déclarés différentiellement exprimés (dont des faux positifs) et N gènes sont déclarés non différentiellement exprimés (dont des faux négatifs)



Notion de correction pour les tests multiples

	déclaré non diff. exp.	déclaré diff. exp.
m_0 gènes non diff. exp.	vrais négatifs	faux positifs
m_1 gènes diff. exp.	faux négatifs	vrais positifs
$G = m_0 + m_1$	N	P

- test simple d'hypothèse : on cherche à contrôler le risque α
- test multiple : on cherche à contrôler une fonction du nombre de faux positifs
- Contrôle du Family-wise error rate (FWER) :
 - FWER = probabilité d'avoir au moins un faux positif (sur l'ensemble des gènes testés)
 - procédure de Bonferroni la plus connue. Si $G = 10000$ et $FWER \leq 0.05$, alors chaque test est réalisé avec un risque $\alpha' = 5 * 10^{-6}$ ($\frac{\alpha}{G}$)
 - mais plus il y a de tests, moins on rejette H_0
 - et problème de non indépendance des tests (corégulation des gènes) : procédure de Westfall and Young
 - très conservatifs (peu de gènes sont déclarés différentiellement exprimés), plutôt recherche de candidats pour des analyses fonctionnelles
- False Discovery Rate (FDR) : proportion moyenne de faux positifs
 - l'idée est plutôt d'avoir une idée de l'espérance du nombre de faux-positifs, parmi les gènes déclarés différentiellement exprimés
 - si $\alpha = 0.05$, 5% des gènes significatifs après correction seront des faux positifs
 - moins conservatif (plus de faux-positifs), utile quand l'objectif de l'expérience transcriptomique est exploratoire



Régression linéaire simple

test de corrélation de Spearman

- coefficient de corrélation de Spearman : $\rho = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2-1)}$, où $d_i = x_i - y_i$
- question : à partir de quelles valeurs on va considérer qu'il y a dépendance ou indépendance entre x et y ?
- le test est non paramétrique, mais pour $n > 10$ on a $t = \rho \sqrt{\frac{n-2}{1-\rho^2}}$ qui suit une loi de Student $\mathcal{T}(n-2)$
- H_0 : il n'y a pas de corrélation des rangs
- H_1 : il existe une corrélation "monotone"



Régression linéaire simple

tests sur les paramètres

- rappel : la régression linéaire permet d'estimer les paramètres \hat{a} et \hat{b} de la droite de régression de manière à ce que $y_i = \hat{a}x_i + \hat{b} + \epsilon_i$
- on veut valider le modèle $\hat{y}_i = ax_i + b$, donc on veut tester si \hat{a} et \hat{b} sont significativement différents de 0 (hypothèse H_0)
- on dispose des variances de chaque estimateur :

$$\bullet s_a^2 = \frac{\sigma^2}{\sum_{x=1}^n (x_i - \bar{x})^2}, \text{ où } \sigma^2 = \frac{\sum_{i=0}^n (y_i - \hat{y}_i)^2}{n-2}$$

$$\bullet s_b^2 = \frac{\sigma^2 \sum_{i=0}^n x_i^2}{n^2 s_x^2}$$

- test de Student bilatéraux :

$$\bullet \text{ pour } \hat{a} : t = \frac{\hat{a}}{\frac{s_a}{\sqrt{n}}}$$

$$\bullet \text{ pour } \hat{b} : t = \frac{\hat{b}}{\frac{s_b}{\sqrt{n}}}$$



Régression linéaire multiple

- modèle théorique : $Y_i = \beta_0 + \sum_{j=1}^p \beta_j X_{ij} + \epsilon_i$ où ϵ_i indépendante $\sim \mathcal{N}(0, \sigma)$
- exemple : relation entre le poids des rejets de chicorée (endives) et le poids des feuilles et le poids des racines : $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon$
- les valeurs des paramètres β sont estimées par la méthode des moindres carrés : $\min \sum_{i=1}^n (y_i - b_0 - b_1 x_{i1} - \dots - b_p x_{ip})^2$
- Les coefficients b_i sont appelés coefficients de régression partielle
- distributions d'échantillonnage :
 - variance résiduelle : $\chi^2_{(n-p-1)}$
 - coefficients de régression : loi de Student $\mathcal{T}(n-p-1)$
 - coefficients de détermination (part de la variance expliquée par la régression) et de corrélation multiple (corrélation entre Y observées et Y estimées) : $F(p, n-p-1)$




Régression logistique sur données binaires (modèle linéaire !)

- un modèle permettant de prédire les valeurs prises par une variable catégorielle, le plus souvent binaire, à partir d'une série de variables explicatives continues et/ou binaires.
- exemple : trouver les facteurs qui caractérisent un groupe de plantes malades par rapport à plantes saines.
- Y prend les valeurs 0 ou 1
- $p(X|1)$ (resp. $p(X|0)$) est la distribution conditionnelle des X sachant la valeur prise par Y
- $p(1|X)$ est la probabilité a posteriori d'obtenir la modalité 1 de Y sachant la valeur prise par X
- hypothèse fondamentale : $\ln \frac{p(X|1)}{p(X|0)} = a_0 + a_1x_1 + \dots + a_jx_j$
- modèle LOGIT de $p(1|X)$: $\ln \frac{p(1|X)}{1-p(1|X)} = b_0 + b_1x_1 + \dots + b_jx_j$
- régression logistique car loi de probabilité logistique :
$$p(1|X) = \frac{e^{b_0 + b_1x_1 + \dots + b_jx_j}}{1 + e^{b_0 + b_1x_1 + \dots + b_jx_j}}$$
- estimation des b_j par maximum de vraisemblance



Régression curvilinéaire -polynomiale- (modèle linéaire!)

- régression polynomiale : $y_i = \beta_0 + \beta_1x + \beta_2x^2 + \dots + \beta_nx^n + \epsilon_i$







Analyse en Composantes Principales - ACP

exemple : expression de gènes dans différentes conditions expérimentales

représentation des distances entre individus



représentation des corrélations entre variables






Analyse en Composantes Principales - ACP


ACP normée et non normée

- la variance de l'expression diffère d'un gène à l'autre : faire une ACP normée





Analyse Factorielle des Correspondances - AFC



sur facteur 1 : forte corrélation positive pour AE, AP et AS, et forte corrélation négative pour AC, AO et FR



Références



Probability and statistical inference. Hogg RV, Tanis EA



Probabilités - Estimation statistique. Lethielleux M, Edition Express