

# Éléments de statistiques pour les data sciences

## Cours 12: inférence non paramétrique - test de Wilcoxon

Dr. Ph. Müllhaupt

IGM - EPFL

—

rappel sur les  
tests para-  
métriques de  
centrage et  
d'étalement

statistique  
d'ordre de  
rang (ou  
statistique de  
rang)

propriété des  
statistiques  
d'ordre

test de  
Wilcoxon

- 1 rappel sur les tests paramétriques de centrage et d'étalement
- 2 statistique d'ordre de rang (ou statistique de rang)
- 3 propriété des statistiques d'ordre
- 4 test de Wilcoxon

# rappel sur les inférences paramétriques

centrage et étalement

- $\chi^2$  pour l'adéquation statistique (Pearson)
- $\chi^2$  pour  $D = -2 \log r$  avec  $r$  le rapport de vraisemblance
- $Z \sim \mathcal{N}(0, 1)$  pour le comportement asymptotique (grands échantillons)
- $Z \sim \mathcal{N}(0, 1)$  pour comparer deux moyennes  $\mu_0$  et  $\mu_1$  lorsque les variance sont connues (avec changement de variables).
- la loi de Student  $t$  pour comparer deux moyennes lorsque la variance n'est pas connue et que l'on l'estime avec  $s$ .
- plusieurs cas divers en fonction du nombre de lots et variances des lots  $s_1$  et  $s_2$

Toutes nécessitent que les données proviennent de distributions connues, même en quelque sorte celle de Pearson car elle suppose de pouvoir attribuer des fréquences  $e_k$  attendues.

# inférence non paramétrique

## considérations générales

On aimerait avoir des tests qui suppose uniquement que les échantillons proviennent de population homogène, de distribution constante pour les échantillons mais dont la connaissance de la distribution n'est pas nécessaire.

Des estimations du centrage et l'étalement peuvent être, par exemple, obtenues par des statistiques d'ordre. Les deux statistiques d'ordre les plus élémentaire sont la valeur minimum de l'échantillon noté  $\underline{X}$  et l'échantillon le plus grand  $\overline{X}$

- centrage : la médiane

$$\frac{\underline{X} + \overline{X}}{2}$$

- étalement :

$$\overline{X} - \underline{X}$$

## statistique de d'ordre ou de rang

- Il est possible de classer les échantillons  $x_1, x_2, x_3$  pour obtenir

$$x_{(1)} \leq x_{(2)} \leq x_{(3)} < \dots$$

- Il est donc possible d'introduire les variables aléatoires (statistique d'ordre)

$X_{(1)}$  = plus petite valeur des variables aléatoires  $(X_1, X_2, \dots, X_n)$

$X_{(2)}$  = seconde plus petite valeur des variables aléatoires  $(X_1, X_2, \dots, X_n)$

$\vdots$        $\vdots$

## statistique d'ordre

distribution exacte

On a les deux résultats dans le cas d'une distribution uniforme sur  $[0; 1]$  (on omet la démonstration)

- espérance mathématique :

$$\mathbb{E}[X_{(r)}] = \frac{r}{n+1} \quad r = 1, \dots, n$$

- variance :

$$\text{var}[X_{(r)}] = \frac{r(n-r+1)}{(n+1)^2(n+2)} \quad r = 1, \dots, n$$

- covariance :

$$\text{cov}[X_{(r)}, X_{(s)}] = \frac{r(n-s+1)}{(n+1)^2(n+2)} \quad 1 \leq r < s \leq n$$

## transformation intégrale de probabilité

### théorème

Soit  $X$  une variable aléatoire de fonction de répartition  $F_X$ . Si  $F_X$  est continue, la variable aléatoire  $Y = F_X(X)$  a la distribution continue uniforme sur l'intervalle  $]0; 1[$ .

Comme  $0 \leq F_X(x) \leq 1$  pour tout  $x$ , en laissant  $F_Y$  dénoter la fonction de répartition de  $Y$ , on a  $F_Y(y) = 0$  pour  $y \leq 0$  et  $F_Y(y) = 1$  pour  $y \geq 1$ .

Pour  $0 < y < 1$  on définit  $u$  comme le plus grand nombre qui satisfait  $F_X(u) = y$ . Ainsi,  $F_X(x) \leq y$  si et seulement si  $X \leq u$  et on a

$$F_Y(y) = P[F_X(X) \leq y] = P(X \leq u) = F_X(u) = y \quad \text{CQFD}$$



# distribution asymptotique des statistiques d'ordre $X_{(r)}$

## théorème

Lorsque  $r/n \rightarrow p$  lorsque  $n \rightarrow \infty$  avec  $0 < p < 1$  alors en dénotant  $\theta \triangleq F^{-1}(p)$

$$\sqrt{\frac{n}{p(1-p)}} f_X(\theta) [X_{(r)} - \theta] \rightarrow \mathcal{N}(0, 1)$$

# statistique de la somme des rangs de Wilcoxon

## introduction

- Lors de comparaison de deux populations, si une s'écarte de l'autre les rangs petits (resp. grands) auront tendance à se regrouper selon les populations.
- En effectuant la somme des rangs et en comparant avec les possibilités générées par le hasard, il est possible d'établir une valeur maximale de cette somme pour garantir un seuil de signification de 5 %, par exemple.
- On va présenter la comparaison de deux populations  $A$  et  $B$  que l'on suppose de distribution identique et de centrage identique sous l'hypothèse  $H_0$ .

## Exemple

introductif et théorique

Pourcentage d'efficacité d'un insecticide (Wilcoxon "Individual Comparisons by Ranking Methods", Biometrics Bulletin, Vol. 1, No. 6, pp. 80-83, 1945)

% A	Rang A	% B	Rang B
68		60	
68		67	
59		61	
72		62	
64		67	
67		63	
70		56	
74		58	

Table – Comparaison de deux séries d'échantillons *A* et *B*, huit répliques, une associée à la préparation *A* et l'autre à la préparation *B*. Résultat en pourcentage d'efficacité.

## Exemple

introductif et théorique

- Les résultats sont classés en attribuant 1 au moins bon et en classant successivement par ordre croissant d'efficacité.
- En examinant les données, il y a des ex-aequo, trois fois 67 et deux fois 68.
- On attribue le classement médian aux séries de mesures identiques.
- Comme 67 arrive en position 9, 10 et 11, on attribue le classement médian 10 aux trois 67.
- Le 68 arrive en position 12 et 13 (avant traitement des ex-aequo), on attribue donc 12.5 au deux 68.
- Une fois le classement effectué et les rangs attribués à chaque mesure individuelle, la somme des rangs par échantillon est effectuées. Tous les rangs sont additionnés pour  $A$  et tous les rangs pour  $B$ .

## Exemple

introductif et théorique

% A	Rang A	% B	Rang B
68	12.5	60	4
68	12.5	67	10
59	3	61	5
72	15	62	6
64	8	67	10
67	10	63	7
70	14	56	1
74	16	58	2
542	91	494	45

Table – Comparaison de deux séries d'échantillons  $A$  et  $B$ , huit répliques, une associée à la préparation  $A$  et l'autre à la préparation  $B$ . Résultat en pourcentage d'efficacité, rangs associés et totaux.

## table de probabilités

détermination du NS 5 % pour la différence entre deux expériences

nb. mesures/éch.	plus petit total des rangs	probabilité de ce total
5	16	0.016
5	18	0.055
6	23	0.0087
6	24	0.015
6	26	0.041
7	33	0.0105
7	34	0.017
7	36	0.038
8	44	0.0104
8	46	0.021
8	49	0.05

## table de probabilités

détermination du NS 5 % pour la différence entre deux expériences

nb. mesures/éch.	plus petit total des rangs	probabilité de ce total
9	57	0.0104
9	59	0.019
9	63	0.05
10	72	0.0115
10	74	0.0185
10	79	0.052

## détermination du niveau de signification (NS 5 %)

exemple introductif

- 91 est la somme des rangs pour les 8 mesures de l'échantillon  $A$
- 45 est la somme des rangs pour les 8 mesures de l'échantillon  $B$
- La plus petite somme des rangs, 45, est examinée dans la table des probabilités, associée à 8 mesures/éch.
- La table indique que la probabilité pour un total aussi petit que 45 se situe entre 0.0104 et 0.021.
- La conclusion est que les deux traitements diffèrent de manière significative (car  $< 5\%$ ; en effet, si les rangs étaient tiré au sord, au hasard, le total de 45 apparaîtrait que  $5 \times$  sur 100 en moyenne).



# Exemple

introductif et théorique

nb. mesures/éch.	plus petit total des rangs	probabilité de ce total
8	44	0.0104
8	46	0.021
8	49	0.05

## principe des partitions

détermination de la table des probabilités

- Il y  $2 \times 8 = 16$  nombres, les rangs, à répartir aux 16 mesures.
- Le total de 45 observé est une somme particulière des rangs

$$45 = 1 + 2 + 4 + 5 + 6 + 7 + 10 + 10$$

- Il existe d'autres façons de répartir 8 rangs (distincts si on ne compte pas les ex-aequos compris de 1 à 16) pour arriver au même total, par exemple

$$45 = 1 + 2 + 4 + 5 + 6 + 7 + 9 + 11$$

$$45 = 1 + 2 + 3 + 5 + 9 + 10 + 12 + 13$$

$$\vdots \quad \vdots \quad \vdots$$

- Il y a donc un lien étroit entre les partitions d'un entier, disons  $r$  (pour le rang), en  $q = 8$  entiers (distincts compris entre deux entiers)

## illustration des partitions

Pour simplifier l'exposé considérons

- $q = 5$  mesures différentes par échantillon
- Formons la somme des rangs la plus petit possible ( $q = 5$  additions des rangs les plus petit)

$$1 + 2 + 3 + 4 + 5 = 15$$

- Comme  $q = 5$  et que l'on compare deux échantillons le rang maximum est  $2q = 10$ . On doit donc assigner à chaque mesure un chiffre compris entre 1 et 10.

## illustration des partitions

$$q = 5 \text{ et } r = 20$$

- Supposons que la somme des rangs soit 20. Effectuons les partitions de 20 avec des entiers distincts avec au maximum 10 pour les entiers.

1	2	3	4	10		20
1	2	3	5	9		20
1	2	3	6	8		20
1	2	4	5	8		20
1	2	4	6	7		20
1	3	4	5	7		20
2	3	4	5	6		20

- Il y a 7 partitions de 20 en somme de 5 entiers différents compris entre 1 et 10.



## probabilités exactes

### et construction des tables

- La suite de rangs la plus rare de 5 rangs est 1, 2, 3, 4, et 5, ce qui donne comme total 15.
- La somme des rangs commence donc avec 15 et augmente jusqu'à  $10 + 9 + 8 + 7 + 6 = 40$ .
- Si un total de 20 est observé, il s'agit de compter les partitions de  $20 - 15 = 5$  avec répétition.

Dans la formule suivante,  $r$  est la somme des rangs observés,  $q$  est le nombre de mesures dans l'échantillon.

$$P = 2 \left\{ 1 + \sum_{i=1}^r \sum_{j=1}^q \Pi_j^i - \sum_{n=1}^{r-q} \left[ (r - q - n + 1) \Pi_{q-1}^{q-2+n} \right] \right\} / \frac{(2q)!}{q! \times q!}$$

avec  $\Pi_j^i$  désignant la partition de  $i$  en  $j$  parties (avec répétition).

## probabilités exactes

illustration du décompte des partitions

- Remarque  $(2q)!/(q! \times q!) = C_q^{2q}$ , on a  $C_5^{10} = 252$

$r$	différence	partitions	$2 \times \text{partitions} / C_q^{2q}$	cumulé = $P$
15	0	1	$\frac{2}{252}$	$\frac{2}{252} = 0.007936$
16	1	1	$\frac{2}{252}$	$\frac{4}{252} = 0.01587$
17	2	2	$\frac{2 \times 2}{252}$	$\frac{8}{252} = 0.031745$
18	3	3	$\frac{3 \times 2}{252}$	$\frac{14}{252} = 0.0555$

## table moderne de Wilcoxon

Gibbons, Chakraborti

- Jean Dickson Gibbons, Subhabrata Chakraborti, Nonparametric Statistical Inference, CRC Press, 2021, pp. 617 et 618

$m = 5$				$m = 5$			
$n = 5$	queue g.	P	queue dr.	$n = 5$	queue g.	P	queue dr.
	15	0.004	40		22	0.155	33
	16	0.008	39		23	0.210	32
	17	0.016	38		24	0.274	31
	18	0.028	37		25	0.345	30
	19	0.048	36		26	0.421	29
	20	0.075	35		27	0.500	28



$m = 6$			
$n = 6$	queue gauche	P	queue droite
	21	0.001	57
	22	0.002	56
	23	0.004	55
	24	0.008	54
	25	0.013	53
	26	0.021	52
	27	0.031	51

## correspondances entre les tables

- La probabilité de la table de l'article de Wilcoxon est 2x celle de la probabilité de la table de Gibbons, Chakraborti.
- Cela rend possible de tester des hypothèses composites telle que  $\theta < 0$  au lieu de  $\theta \neq 0$ .
- Dans la table de Gibbons, Chakraborti, possibilité d'avoir  $m \neq n$ .



## valeurs asymptotiques

alternative	région de rejet	P
$\theta < 0$	$W_N \geq \frac{m(N+1)}{2} + 0.5 + z_\alpha \sqrt{\frac{mn(N+1)}{12}}$	$1 - \Phi \left( \frac{w_0 - 0.5 - m(N+1)/2}{\sqrt{mn(N+1)/12}} \right)$
$\theta > 0$	$W_N \leq \frac{m(N+1)}{2} - 0.5 - z_\alpha \sqrt{\frac{mn(N+1)}{12}}$	$\Phi \left( \frac{w_0 + 0.5 - m(N+1)/2}{\sqrt{mn(N+1)/12}} \right)$
$\theta \neq 0$	les deux du dessus avec $z_\alpha$ remplacé par $z_{\alpha/2}$	$2 \times$ le plus petit des deux

Table – distribution asymptotique des résultats de la statistique de Wilcoxon  $W_N$ , seuil  $w_0$  et signification  $P$ .

## exemple

- Le tableau suivant indique le temps de fabrication d'une pièce, opération qui a lieu soit le matin, soit l'après-midi. On suspecte une différence entre le matin et l'après-midi.

		matin	après-midi
12.6	11.2	16.4	15.4
11.4	9.4	14.1	14.0
13.2	12.0	13.4	11.3

- $m = n = 6$
- $X$  : matin,  $Y$  : après-midi
- $H_1 : \theta = \mu_Y - \mu_X > 0$  (alternative)
- $P$  est la queue de gauche pour  $W_N$

- Il faut arranger par colonne et trier chaque colonne par ordre croissant (c'est un peu plus systématique comme cela).

matin	après-midi
<u>9.4</u>	11.3
<u>11.2</u>	13.4
<u>11.4</u>	14.0
<u>12.0</u>	14.1
<u>12.6</u>	15.4
<u>13.2</u>	16.4

- On effectue un tri par insertion :

$$\underline{9.4} < \underline{11.2} < 11.3 < \underline{11.4} < \underline{12.0} < \underline{12.6} < \underline{13.2} < 13.4 < 14.0 < 14.1 < \dots$$

- On assigne les rangs aux éléments sous-lignés

$$1 < 2 < 4 < 5 < 6 < 7$$

- On calcule le total

$$r = W_N = 1 + 2 + 4 + 5 + 6 + 7 = 25$$

- On lit  $P$  dans la table  $m = 6, n = 6$

$$P(W_N \leq 25) = 0.013$$

- $H_0$  est rejetée en faveur de l'alternative  $H_1 : \theta > 0$  à tout niveau de signification (NS)  $\alpha \geq 0.013$



rappel sur les  
tests para-  
métriques de  
centrage et  
d'étalement

statistique  
d'ordre de  
rang (ou  
statistique de  
rang)

propriété des  
statistiques  
d'ordre

test de  
Wilcoxon

$m = 6$			
$n = 6$	queue gauche	P	queue droite
	21	0.001	57
	22	0.002	56
	23	0.004	55
	24	0.008	54
	25	0.013	53
	26	0.021	52
	27	0.031	51