

# UN NOUVEAU TEST STATISTIQUE POUR LA COMPARAISON DE PROPORTIONS

*Éric Taillard, Ph. Wälti, J. Zuber*

*EIVD*

*Haute École spécialisée de Suisse occidentale,*

*Yverdon-les-Bains, Suisse*

FRANCORO04, Fribourg, Suisse, 8.2004

1

## EXEMPLE TYPIQUE DE RÉSULTATS NUMÉRIQUES :

Repris de Kim<sup>3</sup>, JoH 9 (3), Juin 2003

Exemple de problème	Nombre d'exécutions	TCC	RSC	FSC	SSC	SHC	TMC
Sorting network design, $n = 7$	10	7	5	<b>8</b>	<b>8</b>	<b>8</b>	5
Sorting network design, $n = 7$	10	3	2	3	4	3	2
Sorting network design, $n = 13$	10	0	0	0	0	0	0
<b>2DTTTgame</b>	<b>10</b>	6	8	<b>4</b>	<b>9</b>	6	6
Nim(3,4,5,4)	10	3	2	<b>6</b>	<b>6</b>	4	3
Nim(5,7,11,6)	10	0	0	<b>1</b>	<b>1</b>	0	0

### Conditions de l'expérience :

Un certain nombre d'exécutions de **méthodes non-déterministes** sur le **même exemple**, ou

Des méthodes (non-) déterministes exécutées sur des **exemples de problèmes choisis aléatoirement**

### Question typique:

Est-ce que SSC est significativement meilleure que FSC pour **2DTTT game** ?

i. e. **est-ce qu'un taux de succès de 9/10 est significativement meilleur qu'un taux de 4/10 ?**

FRANCORO04, Fribourg, Suisse, 8.2004

2

# TEST STANDARD, COMPARAISON DE PROPORTIONS

## Conditions de l'expérience :

$n_a$  exécutions de la méthode  $A$ ,  $a$  succès, probabilité de succès de  $A$  (inconnue) :  $p_a (= 1 - q_a)$

$n_b$  exécutions de la méthode  $B$ ,  $b$  succès, probabilité de succès de  $B$  (inconnue) :  $p_b (= 1 - q_b)$

Les exécutions sont toutes supposées indépendantes

Soient  $X_A$  (resp.  $X_B$ ) la variable aléatoire associée au succès ( $X_A = 1$ ) de  $A$  (resp.  $B$ )

## Si $n_a$ et $n_b$ sont suffisamment grand alors :

$D = X_A/n_a - X_B/n_b$  est approximativement **normalement distribué**

Moyenne :  $d = p_a - p_b$

Variance :  $\sigma_D^2 = \frac{p_a \cdot q_a}{n_a} + \frac{p_b \cdot q_b}{n_b}$

# TEST STANDARD UNILATÉRAL

## Hypothèse nulle :

$$p_a \leq p_b$$

## Hypothèse alternative :

$$p_a > p_b$$

Le paramètre  $p$  peut être approché par l'estimateur groupé :  $\hat{p} = 1 - \hat{q} = \frac{a + b}{n_a + n_b}$

Calculer :  $\hat{d} = \frac{a}{n_a} - \frac{b}{n_b}$  et  $\hat{s} = \sqrt{\frac{\hat{p} \cdot \hat{q}}{n_a} + \frac{\hat{p} \cdot \hat{q}}{n_b}}$

## Rejeter l'hypothèse nulle (et accepter l'hypothèse alternative) au seuil $\alpha$ si :

$\Phi\left(\frac{\hat{d}}{\hat{s}}\right) > 1 - \alpha$  ( $\Phi$  : fonction de répartition d'une var. aléatoire normale centrée réduite)

$\left(\frac{\hat{d}}{\hat{s}} > 1.645 \text{ pour } \alpha = 5\% \text{ et } \frac{\hat{d}}{\hat{s}} > 2.326 \text{ pour } \alpha = 1\%\right)$

# TEST STANDARD BILATÉRAL

(Test du  $\chi^2$  pour comparer des proportions dans une table de contingence  $2 \times 2$ )

Hypothèse nulle :

$$p_a = p_b = p \text{ (i.e. } d = 0)$$

Hypothèse alternative :

$$p_a \neq p_b$$

$$\text{Calculer : } T = \frac{(n_a + n_b) \cdot (a \cdot n_b + b \cdot n_a)^2}{n_a \cdot n_b \cdot (a + b) \cdot (n_a + n_b - a - b)} \text{ (i.e. } \left(\frac{\hat{d}}{s}\right)^2)$$

Sous l'hypothèse nulle, la statistique de test  $T$  suit approximativement un loi du  $\chi^2$  à 1 degré de liberté

Rejeter l'hypothèse nulle (et accepter l'hypothèse alternative) au seuil  $\alpha$  si :  $T > \chi_{1-\alpha}^2 [1]$

$$T > 3,841 \text{ pour } \alpha = 5\%$$

$$T > 6,635 \text{ pour } \alpha = 1\%$$

# NOUVEAU TEST UNILATÉRAL

Problème : Comparer les proportions (inconnues)  $p_a$  et  $p_b$  de succès dans deux échantillons

Échantillons :  $n_a$  exécutions de la méthode A,  $a$  succès,

$n_b$  exécutions de la méthode B,  $b$  succès, sans être restrictif, on suppose  $a/n_a > b/n_b$

Hypothèse nulle :  $p_a \leq p_b$

Hypothèse alternative :  $p_a > p_b$

Méthode :

La probabilité  $S(a, n_a, b, n_b, p_a, p_b)$  d'observer :

$a$  succès ou plus pour la méthode A

$b$  succès ou moins pour la méthode B

$$\text{est donnée par } S(a, n_a, b, n_b, p_a, p_b) = \sum_{i=a}^{n_a} \sum_{j=0}^b \binom{n_a}{i} \cdot p_a^i \cdot (1-p_a)^{n_a-i} \cdot \binom{n_b}{j} \cdot p_b^j \cdot (1-p_b)^{n_b-j}$$

Rejeter l'hypothèse nulle au seuil  $\alpha$  si :

le maximum de  $S(a, n_a, b, n_b, p_a, p_b) < \alpha$ , sous contrainte  $p_a \leq p_b$

# MAXIMUM DE $S(A, N_A, B, N_B, P_A, P_B)$ AVEC $P_A \leq P_B$

## 1) Le maximum aura lieu pour

$p_a = p_b = p$  car on a supposé  $a/n_a > b/n_b$  (sinon, on ne peut refuser l'hypothèse nulle  $p_a \leq p_b$ )

## 2) Le calcul algébrique du maximum n'est que rarement possible

Poser  $\hat{p} = \frac{a+b}{n_a+n_b}$ , effectuer quelques pas de la méthode de Newton sur la fonction  $S(\dots, p, p)$

## 3) Calcul de $S$ malcommode

Tabulation de valeurs de  $a$  et  $b$  pour  $n_a \leq 15$  et  $n_b \leq 13$  respectant le seuil  $\alpha = 5\%$  dans les actes

Le lecteur d'un article n'a qu'à compter  $n_a, a, n_b, b$  et consulter la table (pas de calculs !)

Le calcul de  $S$  est disponible sur le web <http://ina.eivd.ch/projects/stamp>

Les codes sources sont disponibles

# EXEMPLES DE CALCULS ALGÈBRIQUES DE $S$

## 1) Tous les $n_a$ exécutions de $A$ sont des succès, tous les $n_b$ exécutions de $B$ sont des échecs.

$$S(n_a, n_a, 0, n_b, p, p) = 1 \cdot p^{n_a} \cdot (1-p)^0 \cdot 1 \cdot p^0 \cdot (1-p)^{n_b} = p^{n_a} \cdot (1-p)^{n_b}$$

$$\text{Maximum de } S \text{ sur } p : \frac{dS}{dp} = 0 = n_a \cdot p^{n_a-1} \cdot (1-p)^{n_b} - n_b \cdot p^{n_a} \cdot (1-p)^{n_b-1} \Rightarrow p = \frac{n_a}{n_a+n_b} = \frac{a+b}{n_a+n_b}$$

Pour  $n_a = 3, n_b = 2, \max S(n_a, n_a, 0, n_b, p, p) = 108/3125 < 5\%$

On peut supposer, au seuil de confiance de 95% qu'un taux de succès de 3/3 soit significativement plus élevé qu'un taux de succès de 0/2.

## 2) 3 succès de $A$ sur 4 exécutions, 0 succès de $B$ sur 3 exécutions

a) Estimateur groupé  $\hat{p} = \frac{3}{7}, S(3, 4, 0, 3, 3/7, 3/7) < 4\%$

Au seuil de confiance de 96% on peut supposer que  $A$  soit meilleur que  $B$

b)  $S\left(3, 4, 0, 3, \frac{6-2\sqrt{2}}{7}, \frac{6-2\sqrt{2}}{7}\right) > 4\%$  On ne peut pas supposer  $A$  meilleur que  $B$  (4%)

# NOUVEAU TEST NON PARAMÉTRIQUE

Problème : Comparer les proportions  $p_a$  et  $p_b$  de succès dans deux échantillons

Échantillons :  $n_a$  exécutions de la méthode A,  $a$  succès,  
 $n_b$  exécutions de la méthode B,  $b$  succès

Hypothèse nulle :  $p_a = p_b = p$

Hypothèse alternative :  $p_a \neq p_b$

## Calcul direct :

La probabilité  $P$  d'observer  $a/n_a$  et  $b/n_b$  succès sous l'hypothèse nulle est donnée par :

$$P = \frac{\binom{n_a}{a} \cdot p^a \cdot (1-p)^{n_a-a} \cdot \binom{n_b}{b} \cdot p^b \cdot (1-p)^{n_b-b}}{\binom{n_a+n_b}{a+b} \cdot p^{a+b} \cdot (1-p)^{n_a+n_b-a-b}} = \frac{\binom{n_a}{a} \cdot \binom{n_b}{b}}{\binom{n_a+n_b}{a+b}}$$

Rejeter l'hypothèse nulle au seuil  $\alpha$  si  $P < \alpha$

# TEST DE MCNEMAR

## Variante du test de signes

Comparaison de données **appariées** (typiquement : avant-après) :

Les méthodes A et B sont exécutées sur les **mêmes** exemples de problèmes.

**Les égalités** (succès, succès) ou (échec, échec) sont **éliminées**.

$a$  succès pour la méthode A,  $b$  succès pour B sur  $a + b$  exemples de problèmes

Hypothèse nulle :  $P(X_a = 0, X_b = 1) = P(X_a = 1, X_b = 0) = 0,5$

Hypothèse alternative :  $P(X_a = 0, X_b = 1) \neq P(X_a = 1, X_b = 0)$  (**Test bilatéral**)

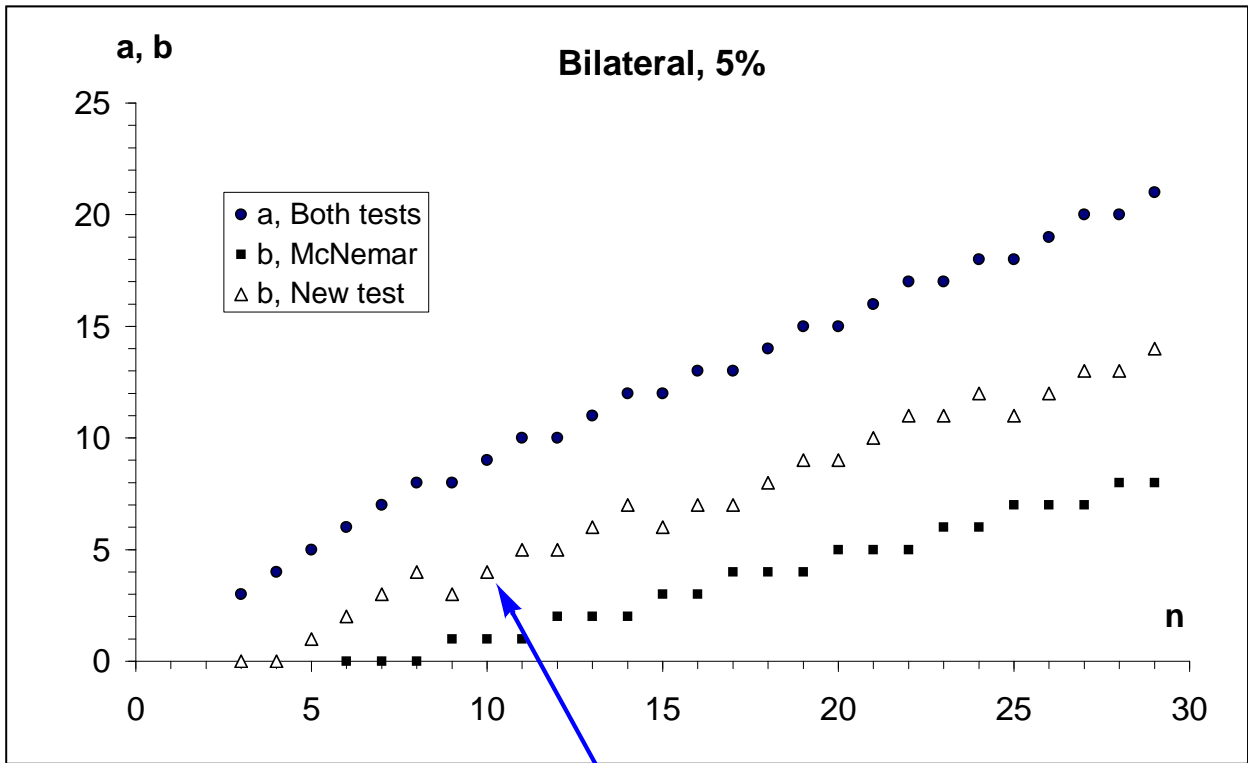
## Calcul direct :

La probabilité  $P$  d'observer  $b$  succès ou moins sur  $a + b$  observations sous l'hypothèse nulle est :


$$P = \sum_{i=0}^b \binom{a+b}{i} \cdot 0.5^i \cdot (1-0.5)^{a+b-i}$$

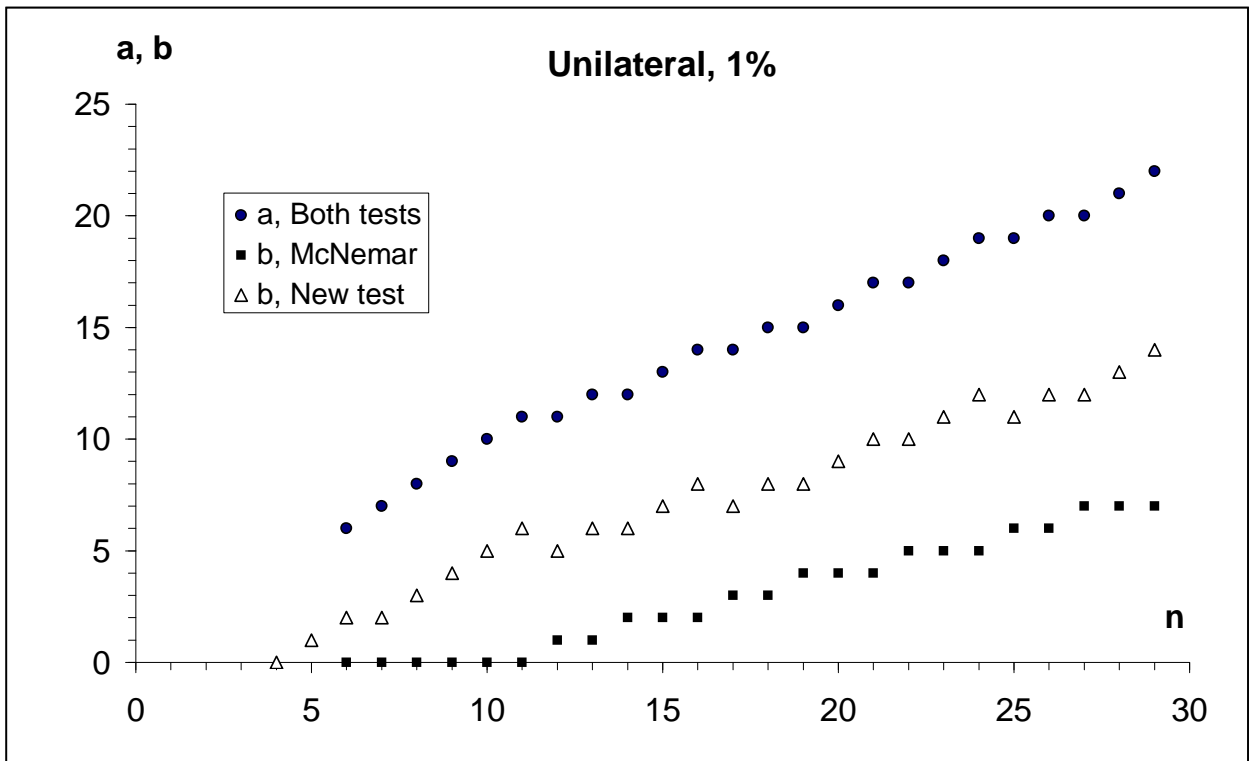
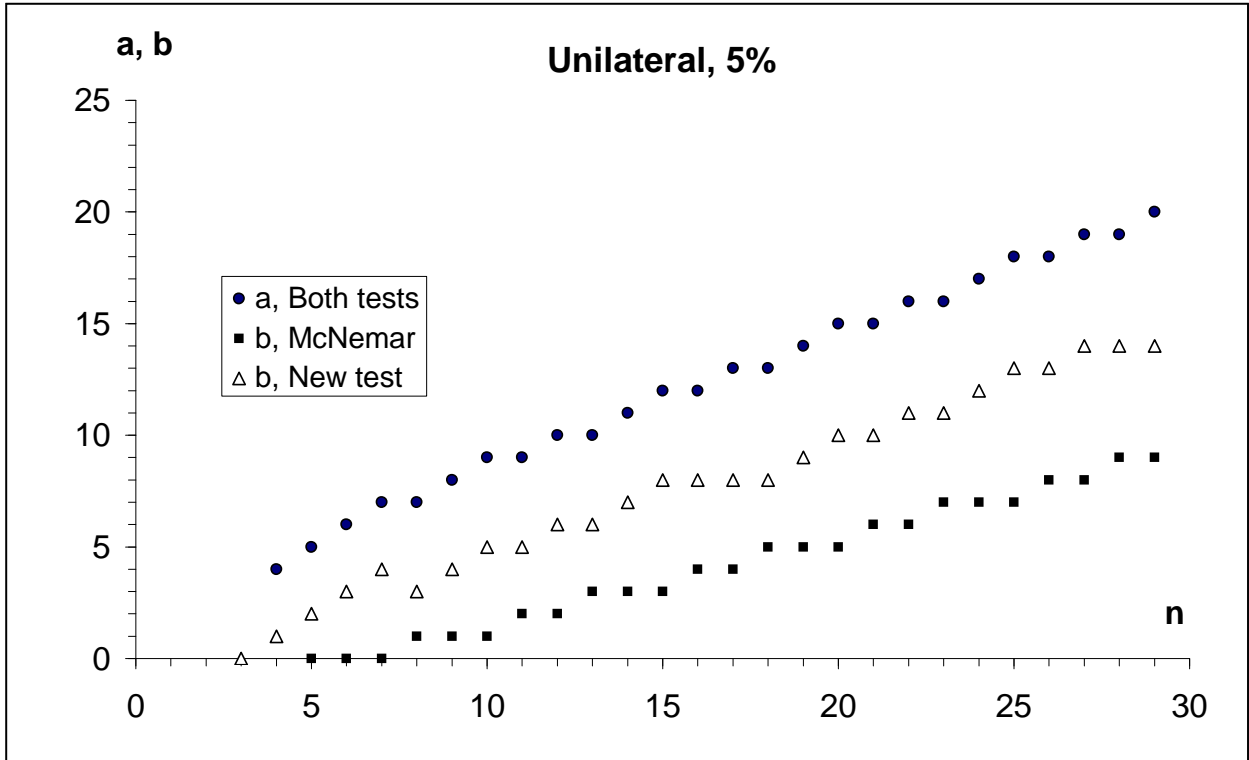
Rejeter l'hypothèse nulle au seuil  $\alpha$  si  $2P < \alpha$  ou si  $2P > 1 - \alpha$

# COMPARAISON MCNEMAR, NOUVEAU TEST



9/10 significativement  $\neq$  4/10







# CONCLUSIONS

Un nouveau **test non paramétrique puissant** a été développé

Permet de **comparer des taux de succès** de deux méthodes lorsque

Les méthodes sont non déterministes (un ou plusieurs exemples de problèmes)

Les méthodes sont déterministes, les problèmes choisis aléatoirement

Peut être appliqué à de **très petits échantillons**, pas nécessairement de la même taille

Permet de réduire l'effort de calcul pour **l'ajustement de paramètres**

**Disponible en ligne.**

**Nettement plus puissant que le test de McNemar**

