

# Tests Estadísticos para Comparar Recomendaciones

**IIC 3633 - Sistemas Recomendadores**

Denis Parra

Profesor Asistente, DCC, PUC CHile

# TOC

## En esta clase

1. Significancia Estadística de los Resultados
  - T-test -- Tails -- Comparación Múltiple: correcciones
  - Signed test
  - Wilcoxon
2. Tests a grupos
  - ANOVA
  - Kruskal–Wallis
3. ¿Cómo reproducir resultados de papers?
4. Demostraciones interactivas

## Antes de empezar

### 1. Métricas de predicción vistas la clase anterior

- RMSE, MSE, MAE
- Precision, Recall, F-1
- MRR
- AP, MAP
- nDCG
- [Pending] Se mencionó Kendall-Tau y Spearman Rank Correlation

### 2. Otras métricas [Pending]

- Diversity (Ziegler)
- Lathia's Diversity (over time)
- MPR (for implicit feedback)

# Rendimiento de una lista: Kendall-Tau

Se compara el resultado de ranking como lista, respecto a una lista que representa el "ground truth". En el contexto RecSys, se ha usado una modificación llamada AP correlation:

$$\tau_{ap} = \frac{2}{N-1} \cdot \left[ \sum_{i \in I} \frac{C(i)}{\text{index}(i) - 1} \right] - 1$$

$N$  es el número de items rankeados en la lista,  $C(i)$  el número de items reanqueados bajo  $\text{index}(i)$  de forma correcta. Valores de *APcorrelation* van entre +1 to -1. Un problema que tiene es que asume un orden total, con un orden parcial de los elementos no es útil.

# Diversity (Ziegler)

Esta métrica se calcula sobre una lista de recomendaciones. Se compara la similaridad entre los pares de elementos recomendados, obteniendo la **Intra-list Similarity**

$$ILS(P_{w_i}) = \frac{\sum_{b_k \in P_{w_i}} \sum_{b_c \in P_{w_i}, b_k \neq b_c} c_o(b_k, b_c)}{2}$$

Valores altos de ILS denotan menor diversidad en la lista. Basado en esta métrica, los autores proponen un algoritmo de diversificación. Los resultados de un estudio off-line y online muestran que la satisfacción del usuario va más allá de la precisión de la recomendación, incluyendo la diversidad percibida de las recomendaciones.

Ref: Ziegler, C. N., McNee, S. M., Konstan, J. A., & Lausen, G. (2005, May). Improving recommendation lists through topic diversification. In Proceedings of the 14th international conference on World Wide Web (pp. 22-32). ACM.

# Diversidad (Lathia) en el tiempo

Lathia compara diversidad y novedad a lo largo del tiempo. La razón  $L2/L1$  corresponde a la fracción de elementos de  $L2$  que no están en la lista  $L1$ .

$$diversity(L1, L2, N) = \frac{|\frac{L2}{L1}|}{N}$$

Por otro lado, "novelty" compara la última lista recomendada  $L2$  con respecto al conjunto de todos los ítems recomendados a la fecha  $A_t$ .

$$novelty(L2, N) = \frac{|\frac{L2}{A_t}|}{N}$$

Ref: Lathia, N., Hailles, S., Capra, L., & Amatriain, X. (2010, July). Temporal diversity in recommender systems. In Proceedings of the 33rd international ACM SIGIR conference on Research and development in information retrieval (pp. 210-217). ACM.

# Mean Percentage Ranking (Implicit Feedback)

$$MPR = \frac{\sum_{ui} r_{ui}^t \cdot \overline{rank_{ui}}}{\sum_{ui} r_{ui}^t}$$

Donde  $r_{ui}$  indica si el usuario  $u$  consumió el ítem  $i$  y  $\overline{rank_{ui}}$  denota el percentile-ranking de  $i$  dentro de una lista ordenada. De esta forma,  $\overline{rank_{ui}} = 0\%$  significa que  $i$  está al tope de la lista.

Ref: Hu, Y., Koren, Y., & Volinsky, C. (2008, December). Collaborative filtering for implicit feedback datasets. In Data Mining, 2008. ICDM'08. Eighth IEEE International Conference on (pp. 263-272). IEEE.

# Comparando Métricas de Performance entre Recomendadores

- Hipótesis nula ( $H_0$ ): No existe diferencia entre la media métrica de performance (RMSE, MAP, nDCG, etc.) del recomendador  $R_1$  versus el recomendador  $R_2$ .

$$H_0 : \bar{métrica}_{R_1} = \bar{métrica}_{R_2}$$

- Hipótesis alternativa ( $H_1$ ): Si existe diferencia

$$H_1 : \bar{métrica}_{R_1} \neq \bar{métrica}_{R_2}$$

- Opciones de Test para chequear si *rechazamos* o *fallamos en rechazar* la hipótesis nula  $H_0$ 
  - T-test (paired y not paired): test paramétrico, válido bajo ciertos supuestos
  - Signed y Wilcoxon: No paramétrico, no requiere los supuestos del T-test pero tiene menos poder (en el sentido estadístico)
- Debemos definir un nivel de significancia estadística  $\alpha$ , por lo general se rechaza la hipótesis nula con *p-value*  $< 0,05$ .

# Supuestos del T-test

- Variable Bivariada independiente (grupos A, B)
- Variable dependiente continua (MAP, precision, recall, etc.)
- Cada observación de la variable es independiente de las otras observaciones:
  - El MAP de un usuario es independiente del MAP de otro usuario
  - En el t-test pareado, requerimos sólo las diferencias de pares ( $A_i - B_i$ ) que sean independientes
- La variable dependiente tiene una distribución normal, con la misma varianza  $\sigma^2$  en cada grupo (como si la distribución del grupo A y del grupo B fueran la misma, pero una desplazada respecto de la otra, sin cambiar de forma)

\*\* REF: <http://www.csic.cornell.edu/Elrod/t-test/t-test-assumptions.html>

# Ejemplo 1: T-Test

```
# Datasets de prueba
# lista de MAP para recomendador 1, con 30 usuarios, media de 0.2 y desv. st. de 0.1
rec1_map <- rnorm(30, mean = 0.2, sd = 0.1)

# lista de MAP para recomendador 2, con 30 usuarios, media de 0.4 y desv. st. de 0.15
rec2_map <- rnorm(30, mean = 0.4, sd = 0.15)

summary(rec1_map)
```

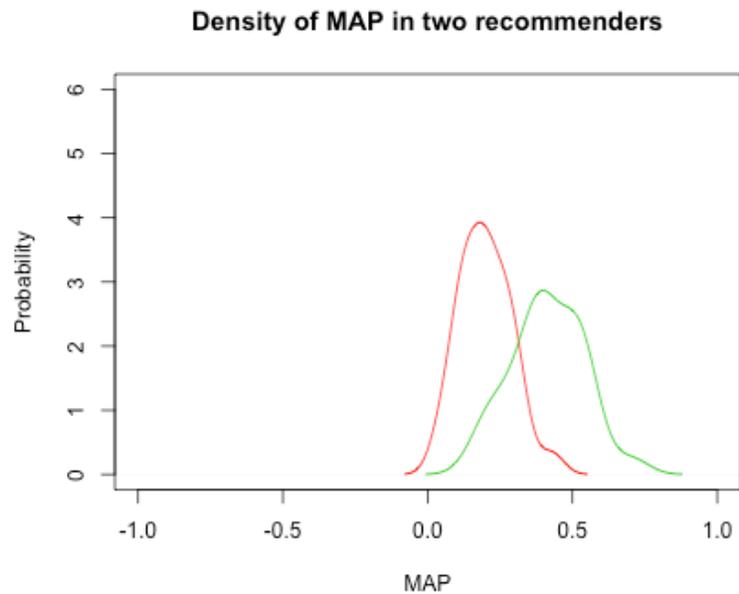
```
##      Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
## 0.04154 0.13350 0.19230 0.19930 0.26460 0.43020
```

```
summary(rec2_map)
```

```
##      Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
## 0.1644 0.3395 0.4010 0.4137 0.5246 0.7084
```

# Gráfico de las distribuciones

```
# Graficos
plot(density(rec1_map), col=2, main="Density of MAP in two recommenders",
     xlab="MAP", ylab="Probability",
     xlim=c(-1, 1), ylim=c(0, 6))
lines(density(rec2_map), col=3)
```



# T-test de Muestras Independientes

- Revisamos si el p-value es menor de 0.05 (nuestro  $\alpha$  level)

```
# Independent samples T-test  
t.test(rec1_map,rec2_map,paired = TRUE)
```

```
##  
## Paired t-test  
##  
## data:  rec1_map and rec2_map  
## t = -8.2521, df = 29, p-value = 4.251e-09  
## alternative hypothesis: true difference in means is not equal to 0  
## 95 percent confidence interval:  
##  -0.2675232 -0.1612540  
## sample estimates:  
## mean of the differences  
##           -0.2143886
```

# T-test de Múltiples Pares

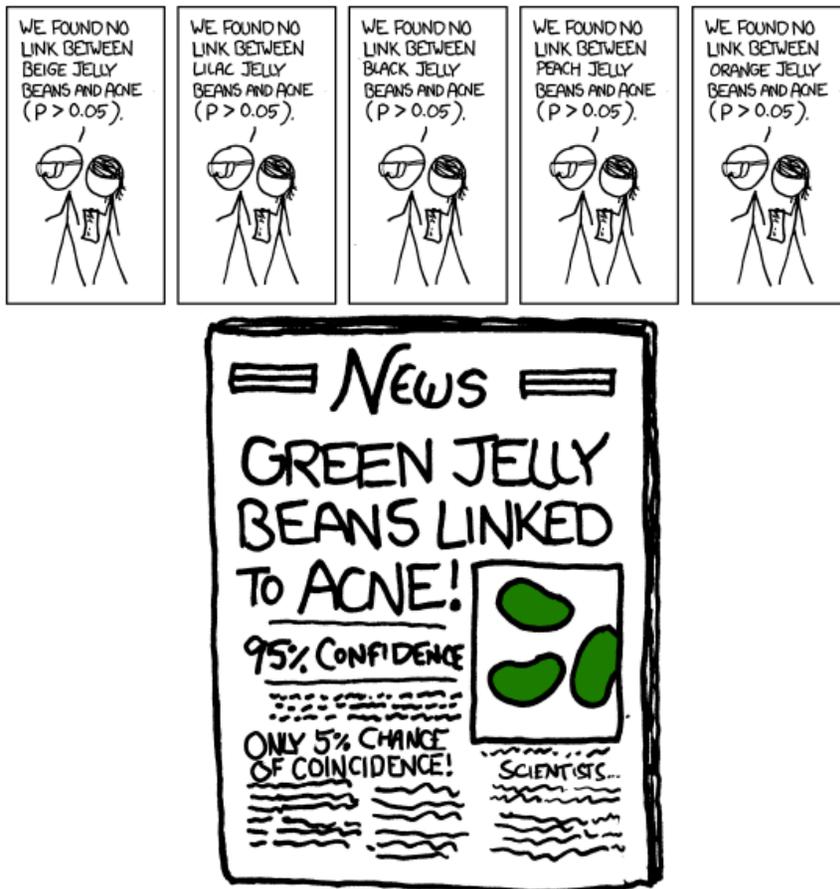
- En este caso es importante hacer alguna corrección, ya que al momento de

```
# multiple pair-wise t-test  
t.test(rec1_map,rec2_map,paired=TRUE )
```

```
##  
## Paired t-test  
##  
## data:  rec1_map and rec2_map  
## t = -8.2521, df = 29, p-value = 4.251e-09  
## alternative hypothesis: true difference in means is not equal to 0  
## 95 percent confidence interval:  
##  -0.2675232 -0.1612540  
## sample estimates:  
## mean of the differences  
##           -0.2143886
```

# T-test

- xkcd: [Significant](#)



# T-test de Múltiples Pares

- En este caso es importante hacer alguna corrección, ya que al momento de

```
rec3_map <- rnorm(30, mean = 0.45, sd = 0.1)
library(reshape2)
df1 <- melt(cbind(rec1_map,rec2_map,rec3_map))
df1$Var2 <- factor(df1$Var2)
# Paired samples T-test
pairwise.t.test(df1$value,df1$Var2,p.adj="bonf")
```

```
##
## Pairwise comparisons using t tests with pooled SD
##
## data:  df1$value and df1$Var2
##
##          rec1_map rec2_map
## rec2_map 5.6e-12  -
## rec3_map 3.2e-15  0.35
##
## P value adjustment method: bonferroni
```

# Tests alternativos no-paramétricos

Cuando no se cumplen los supuestos (normalidad) y no se puede hacer alguna corrección o relajo de ellos, debemos usar alternativas (que usualmente tienen menos poder estadístico)

- Wilcoxon rank sum test (no es el mismo que signed rank test)
- Wilcoxon Signed Rank Test: Para datos pareados

# Wilcoxon Rank Sum Test

- También llamado Mann-Whitney U, Wilcoxin-Mann-Whitney test, o Wilcoxin rank sum test.
- Consiste en calcular la métrica  $U$  basada en rankear las observaciones luego de mezclar ambas muestras.

```
wilcox.test(rec1_map,rec2_map)
```

```
##  
## Wilcoxon rank sum test  
##  
## data:  rec1_map and rec2_map  
## W = 74, p-value = 8.315e-10  
## alternative hypothesis: true location shift is not equal to 0
```

# Wilcoxon Signed-Rank test

- Se basa en calcular diferencias entre pares
- La estadística de test corresponde al número de diferencias positivos o negativas
- $H_0$ : la mediana de las diferencias entre pares es igual a zero

```
wilcox.test(rec1_map,rec2_map, paired=TRUE)
```

```
##  
## Wilcoxon signed rank test  
##  
## data:  rec1_map and rec2_map  
## V = 9, p-value = 6.147e-08  
## alternative hypothesis: true location shift is not equal to 0
```

# ANOVA

- Técnica de análisis estadístico que permite identificar si en un grupo ( $n_{\text{grupos}} > 2$ ) hay diferencias significativas.
- ANOVA no indica quién produce las diferencias, para eso necesitamos comparaciones post-hoc (multiple t-tests, por ejemplo)
- Hay distintas versiones de ANOVA según el diseño del experimento (within o between subjects) y según las combinaciones de grupos a comparar (1-way, 2-way, etc.)
- Kruskal–Wallis es la alternativa no-paramétrica de ANOVA

# Referencias

- Ziegler, C. N., McNeel, S. M., Konstan, J. A., & Lausen, G. (2005, May). Improving recommendation lists through topic diversification. In Proceedings of the 14th international conference on World Wide Web (pp. 22-32). ACM.
- Lathia, N., Hailes, S., Capra, L., & Amatriain, X. (2010, July). Temporal diversity in recommender systems. In Proceedings of the 33rd international ACM SIGIR conference on Research and development in information retrieval (pp. 210-217). ACM.
- Hu, Y., Koren, Y., & Volinsky, C. (2008, December). Collaborative filtering for implicit feedback datasets. In Data Mining, 2008. ICDM'08. Eighth IEEE International Conference on (pp. 263-272). IEEE.