

El análisis de la varianza es un procedimiento estadístico que pretende contrastar si existen diferencias en el comportamiento de una variable, Y , entre los distintos grupos determinados por un cierto factor. (Tenemos 1 vble. cuantitativa y 1 factor o vble. cualitativa)

p.ej. : Los salarios entre las comunidades autónomas

Viene a ser una generalización del test t de student de igualdad de (dos) medias a un número cualquiera de grupos.

El problema que afronta se puede plantear de formas (equivalentes) alternativas:

- El comportamiento de la variables Y es diferente (o no) entre los grupos (que forma el factor)
- La media de Y es diferente (o no) en los distintos grupos
- El factor afecta, produce efecto (o no) al comportamiento de la variable Y
- El factor discrimina , marca diferencias (o no) el comportamiento de Y

El contraste (ANOVA) se lleva a cabo asumiendo algunas hipótesis (“MODELO de ANOVA”) pero, es un método bastante **robusto** ya que (en el fondo) se basa en una idea general de cumplimiento universal : Cuando mezclamos dos (o más) conjuntos de datos muy **diferentes** entre sí la varianza total **crece más** que si mezclamos dos (o más) conjuntos de datos parecidos.

Veamos un ejemplo trivial.

X1	X2
6	4
4	6

X1 U X2

media 5 5 5
var 1 1 1
SCI 2 2
SCT 4

SCE
S.C.entre
grupos= 0

X1	X2
2	8
2	8

X1 U X2

media 2 8 5
var 0 0 9
SCI 0 0
SCT 36

SCE
S.C.entre
grupos= 36

$$\text{Suma de cuadrados externa (entre-grupos)} = SCE = \sum_{\forall \text{ grupos}} n_g (\bar{X}_g - \bar{X})^2$$

$$SCT = SCE + SCI$$

En el primer caso la SCT es 4 (La SCI=2+2=4 y La SCE=0) Los dos conjuntos son idénticos

En el segundo caso SCT es 36 (La SCI=0 pero la SCE= 36 Los dos conjuntos son muy diferentes

EJEMPLO PARA LA COMPRESIÓN DE LA SITUACIÓN:

Supongamos una población de las notas $y_{i,j}$ de un universo de 9 alumnos de tres grupos distintos, así:

grupo 1	grupo 2	grupo 3
5	5	5
5	5	5
5	5	5

evidentemente en este caso la media global es 5 y la de cada grupo también $y_{i,j} = \mu$ cada valor es igual a la media general. **NO HAY DIFERENCIAS ENTRE GRUPOS NI DENTRO DE LOS GRUPOS**

Supongamos que aplicamos un método de enseñanza (factor) que afecta: subiendo las notas del grupo 1 en 1 punto, las del grupo dos en 2 puntos y no modificando las del grupo 3. Así.

grupo 1	grupo 2	grupo 3
5+1=6	5+2=7	5
5+1=6	5+2=7	5
5+1=6	5+2=7	5

ahora la nota de un alumno sería $y_{i,j} = \mu + \alpha_j$
en el que los α_j son 1, 2, 0 los **EFFECTOS QUE PRODUCEN EL FACTOR (MÉTODO) EN CADA NIVEL. PARECE CLARO QUE EL FACTOR INFLUYE EN ESTABLECER DIFERENCIAS ENTRE GRUPOS; PERO NO DENTRO**



EJEMPLO PARA LA COMPRESIÓN DE LA SITUACIÓN II

Lo más habitual es que haya alumnos que rindan más que otros (por diversas razones aleatorias o que en principio no dependan de un factor) ,son por tanto, comportamientos aleatorios individuales que denominamos $\epsilon_{i,j}$ implantando algunos en el ejemplo ,sería:

grupo 1	grupo 2	grupo 3
5+1-1=5	5+2+2=9	5+0+3=8
5+1-2=4	5+2+0=7	5+0+4=9
5+1+0=6	5+2+1=8	5+0+0=5

en el que los efectos aleatorios

$\epsilon_{i,j}$ serían -1,-2,0,2,0,1,3,4,0 que fomentan la

variabilidad **dentro** de los grupos **INTRA-GRUPOS**

Entonces para cada valor tendremos el modelo

$$y_{i,j} = \mu + \alpha_i + \epsilon_{i,j}$$

TENEMOS DOS TIPOS DE VARIABILIDAD : LA ENTRE GRUPOS (DEBIDA AL FACTOR) Y LA INTRA GRUPOS (DEBIDA A LA ALEATORIEDAD....) .

PARA PODER AFIRMAR QUE EL FACTOR PRODUCE EFECTOS. LA VARIABILIDAD **ENTRE LOS GRUPOS** HA DE SER *SIGNIFICATIVAMENTE GRANDE RESPECTO A LA INTRA GRUPOS*



MODELO E HIPÓTESIS

EL MODELO SERÍA EL SIGUIENTE : $Y_{ij} = \mu + \alpha_i + \varepsilon_{ij}$

donde :

Y_{ij} = observación j-ésima del nivel i

μ = media general

α_i = efecto el i-ésimo nivel del factor ε_{ij} = error aleatorio independiente $N(0, \sigma)$

PANTEAMOS LA SIGUIENTE HIPÓTESIS NULA

$$H_0 = \alpha_1 = \alpha_2 = \alpha_3 = \dots = \alpha_k$$

o bien si consideramos $\mu_i = \mu + \alpha_i$

$$\text{entonces } H_0 = \mu_1 = \mu_2 = \mu_3 = \dots = \mu_k$$

en definitiva se quiere comprobar la **no influencia** del factor α

DE OTRA FORMA : SI TODAS LAS MUESTRAS PROCEDEN DE LA MISMA POBLACIÓN

CONDICIONES GENERALES DE APLICACIÓN.

A- **INDEPENDENCIA DE LOS ERRORES** . Los errores experimentales han de ser independientes . Se consigue si los sujetos son asignados aleatoriamente. Es decir , se consigue esta condición si las elementos de los diversos grupos han sido elegidos *por muestreo aleatorio* .

B- **NORMALIDAD** . Se supone que los errores experimentales se distribuyen normalmente. Lo que supone que cada una de las puntuaciones $y_{i,j}$ se distribuirá normalmente . Para comprobarlo se puede aplicar un test de ajuste a la distribución **Normal** como el de **Kolmogov-Smirnov**

C- **HOMOGENEIDAD DE VARIANZAS (HOMOSCEDASTICIDAD)**. La varianza de los subgrupos ha de ser homogénea $\sigma^2_1 = \sigma^2_2 = = \sigma^2_k$ ya que están debidas al error. Se comprobarán mediante los test de : Razón de varianzas (máx/mín) , C de Cochran , Barlett-Box,

Sea Y una variable aleatoria sobre la que se han tomado N muestras ;de manera que obtenemos k muestras correspondientes a las k categorías(niveles) del factor. Si el tamaño de la muestra para cada categoría es el mismo (n) para todas, estaremos ante un modelo **BALANCEADO** en el que $N = nk$ Y sigue una $N(\mu_i, \sigma)$ para $i = 1, 2, 3, \dots, k$.

	1	2	NIVELES DEL FACTOR				k
1	$Y_{1.1}$	$Y_{2.1}$					$Y_{k.1}$
2	$Y_{1.2}$	$Y_{2.2}$					$Y_{k.2}$
j	$Y_{1.i}$	$Y_{2.i}$		$Y_{i.i}$			$Y_{k.i}$
n	$Y_{1.n}$	$Y_{2.n}$					$Y_{k.n}$

$i = 1, 2, 3, \dots, k$ $j = 1, 2, 3, \dots, n$ (en el caso de balanceado)

media muestral correspondiente al nivel i del factor $= \frac{1}{n} \sum_{j=1}^n Y_{ij} = \bar{Y}_i$.

media general $= \frac{1}{N} \sum_{i=1}^k \sum_{j=1}^n Y_{ij} = \bar{Y}$



DESCOMPOSICIÓN DE LA VARIABILIDAD TOTAL

que quedaría establecida de la siguiente forma:

$$\begin{array}{rcl} \sum \sum (Y_{ij} - \bar{y})^2 & = & \sum \sum (Y_{ij} - \bar{y}_{i.})^2 + n \sum_{i=1}^k (\bar{y}_{i.} - \bar{y})^2 \\ \text{S.C.T.} & = & \text{S.C.I.} \qquad \qquad \qquad \text{S.C.E.} \end{array}$$

Donde : S.C.T. = SUMA DE CUADRADOS TOTAL

S.C.I. = SUMA DE CUADRADOS INTRA-GRUPOS (within-groups)

S.C.E. = SUMA DE CUADRADOS ENTRE-GRUPOS (between-groups)

En el caso de NO ser BALANCEADO , no habría una solo n sino k distintos valores.

la descomposición quedaría entonces así:

$$\begin{array}{rcl} \sum \sum (Y_{ij} - \bar{y})^2 & = & \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{y}_{i.})^2 + \sum_{i=1}^k n_i (\bar{y}_{i.} - \bar{y})^2 \\ \text{S.C.T.} & = & \text{S.C.I.} \qquad \qquad \qquad \text{S.C.E.} \end{array}$$

S.C.T. será la suma de las desviaciones de cada Y_{ij} respecto a la media general $\bar{y}$

S.C.I. será la variación total de las observaciones alrededor de cada una de las medias muestrales

S.C.E. será la variación de las medias muestrales de cada grupo alrededor de la media general

SI DIVIDIMOS LA DESCOMPOSICIÓN DE LA VARIABILIDAD POR LA VARIANZA

$$\frac{S.C.T.}{\sigma^2} = \frac{S.C.I.}{\sigma^2} + \frac{S.C.E.}{\sigma^2}$$

Dado que las observaciones de las k muestras son independientes, cada uno de los tres sumatorios desde $i = 1$ hasta $i = k$ es la suma de k variables aleatorias que tienen distribuciones χ^2 de tal manera que

$S.C.T. / \sigma^2 \longrightarrow \chi^2$ con $(N-1)$ grados de libertad

$S.C.I. / \sigma^2 \longrightarrow \chi^2$ con $k(n-1)$ grados de libertad

$S.C.E. / \sigma^2 \longrightarrow \chi^2$ con $(k-1)$ grados de libertad

en el caso de diseño NO BALANCEADO $S.C.I. / \sigma^2 \longrightarrow \chi^2$ con $(n_1-1) + (n_2-1) \dots (n_k-1)$ grados de libertad



Bajo la hipótesis nula; la variabilidad entre grupos no deberá superar significativamente a la variabilidad intra grupo luego el cociente **S.C.E / S.C.I. no deberá ser significativamente grande** . Esa **Significabilidad** nos la dará una distribución de probabilidad asociada. Así:

$$\frac{\text{S.C.E.}}{\text{S.C.I.}} \rightarrow \frac{\chi^2_{(k-1)}}{\chi^2_{k(n-1)}} \quad \text{ó bien} \quad \chi^2_{(N-k)} \quad \text{si multiplicamos el cociente por } N-k / k-1$$

$$\frac{\text{S.C.E.} \cdot (N-k)}{\text{S.C.I.} \cdot (k-1)} \xrightarrow{=} \frac{\chi^2_{(k-1)} / (k-1)}{\chi^2_{(N-k)} / (N-k)} \longrightarrow F_{(k-1),(N-k)} \Rightarrow \mathbf{F}$$

Así para un nivel de significación **α**

Si **$\mathbf{F} > F_{\alpha}$** se rechaza la H_0 medias de los grupos no son iguales .

Si **$\mathbf{F} < F_{\alpha}$** no se puede rechazar la H_0 ; luego medias de los grupos son iguales

no influye el factor

no hay diferencias significativa entre los niveles



TABLA " ANOVA " DE UN FACTOR .

FUENTE DE VARIACIÓN	G.L	SUMA DE CUADRADOS	F (k-1)(N-k)
ENTRE-GRUPOS	k-1	S . C . E.	$F = \frac{S.C.E(N-k)}{S.C.I. (k-1)}$
INTRA-GRUPOS	N-1 $(n_1-1)+(n_2-1)+\dots+(n_k-1)$ no balanceado	S. C. I.	
TOTAL		S. C. T.	

Ejemplo (simple de las notas de antes)

grupo 1	grupo 2	grupo 3
$5+1-1=5$	$5+2+2=9$	$5+0+3=8$
$5+1-2=4$	$5+2+0=7$	$5+0+4=9$
$5+1+0=6$	$5+2+1=8$	$5+0+0=5$

```
nota<-c(5,4,6,9,7,8,8,9,5)
```

```
grupo<-as.factor(c("1","1","1","2","2","2","3","3","3"))
```

```
notas<-as.data.frame(cbind(grupo,nota))
```

```
anova<-aov(nota~grupo,data=notas)
```

```
summary(anova)
```

```
Console Terminal x Jobs x
~/
> anova<-aov(nota~grupo,data=notas)
> summary(anova)
              Df Sum Sq Mean Sq F value Pr(>F)
grupo          1  3.068    3.068   0.877   0.38
Residuals      7 24.487    3.498
>
>
```

En este caso no habría diferencias significativas en las notas entre los diferentes grupos.

No podríamos descartar que la nota media es la misma en todos los grupos.

No podemos considerar que el factor grupo tiene efecto en las notas.

COMPARACIONES MULTIPLES ENTRE MEDIAS.

Si se ha **rechazado la hipótesis nula** de igualdad de medias esto supone : EXISTE AL MENOS UNA DIFERENCIA . PERO NO SABEMOS CUÁNTAS, NI ENTRE QUE MEDIAS.

Para ello se establecen pruebas de comparación múltiple (a posteriori) ;

Hay muchas . Entre ellas destacan la LSD (Mínimas diferencias significativas), HSD de Tukey (Diferencia “honestas” significativas) , SNK, y Scheffé.

La más “conservadora “ (con las hipótesis nulas de medias iguales) es la de Scheffé.
Y La que tiende a detectar más “liberalmente” las diferencias entre medias es la LSD.
HSD y SNK son intermedias.

HSD está incorporada a los paquetes básicos de R. En cambio LSD y Scheffe requieren del paquete agricolae

Ejemplo ANOVA un factor

Se trata de comprobar si el factor día de la semana influye en el tiempo de elaboración de un componente.

Estaremos ante un ANOVA de un factor (día de la semana) con cinco niveles y no balanceado pues los valores por día son distintos

#los datos están en esta dirección:

```
data<-read.table("http://www.uv.es/lejarza/eaa/tareas/t3r/avo.txt" ,header=T, sep="", )
names(data) #Comprobamos que hay dos variables al y día
```

DATOS DE LOS TIEMPOS , EN MINUTOS, QUE SE TARDA EN ELABORAR UN COMPONENTE ASÍ COMO EL DÍA QUE SE REALIZÓ LA PRUEBA				
MINUTOS DIA	MINUTOS DIA	MINUTOS DIA	MINUTOS DIA	MINUTOS DIA
215 MARTES	209 VIERNES	220 JUEVES	204 MIERCOLES	201 MARTES
215 VIERNES	221 MARTES	219 MIERCOLES	212 MIERCOLES	220 MARTES
219 MIERCOLES	208 VIERNES	219 JUEVES	219 MIERCOLES	222 LUNES
204 MARTES	214 VIERNES	207 JUEVES	204 JUEVES	215 MIERCOLES
209 MARTES	212 MARTES	219 MIERCOLES	203 MIERCOLES	205 VIERNES
216 MIERCOLES	208 JUEVES	213 JUEVES	221 LUNES	207 MARTES
207 MARTES	223 JUEVES	216 JUEVES	204 MIERCOLES	206 MIERCOLES
206 MARTES	209 LUNES	225 LUNES	224 JUEVES	216 MARTES
220 LUNES	204 MIERCOLES	208 JUEVES	221 JUEVES	211 MARTES
228 LUNES	202 MIERCOLES	224 VIERNES	206 VIERNES	217 MIERCOLES
220 MARTES	205 LUNES	220 MIERCOLES	200 JUEVES	212 VIERNES
202 MIERCOLES	223 MIERCOLES	222 VIERNES	211 MIERCOLES	216 MARTES
210 MARTES	206 LUNES	228 LUNES	212 MARTES	223 MIERCOLES
200 MARTES	200 MARTES	203 VIERNES	208 JUEVES	216 VIERNES
205 MIERCOLES	208 VIERNES	200 VIERNES	223 JUEVES	206 MIERCOLES
205 LUNES	204 JUEVES	218 LUNES	228 LUNES	203 VIERNES
205 MARTES	210 JUEVES	203 VIERNES	209 LUNES	200 MIERCOLES
221 MARTES	218 LUNES	210 JUEVES	211 JUEVES	219 MIERCOLES
213 LUNES	222 LUNES	210 VIERNES	204 JUEVES	210 MIERCOLES
200 MARTES	225 LUNES	203 VIERNES	222 JUEVES	215 MARTES

```

> summary(data)
      al      dia
Min.   :200.0  Min.   :1.00
1st Qu.:205.0  1st Qu.:2.00
Median :211.0  Median :3.00
Mean   :212.2  Mean   :2.98
3rd Qu.:219.0  3rd Qu.:4.00
Max.   :228.0  Max.   :5.00
> medal<-mean(data$al);sda1<-sd(data$al)
> medal;sda1
[1] 212.24
[1] 7.85361
>


```

Análisis exploratorio

#gráfico conjunto: Gráfico de cajas de al en función del día

boxplot(al~dia, ylab="valores de al", xlab="dia",col="red" ,data=data)

Parece que los lunes....



```
#recodificamos el factor "dia" como factor ( si no la función aov no funciona )
data$Factordia <-factor(data$dia,
                        labels=c("lunes","martes","miercoles","jueves","viernes"))
fix(data) # editamos los datos para comprobarlo
```

#medias y varianzas de al por día




```
tapply(data$al,data$Factordia,mean)
tapply(data$al, data$Factordia, var)
```

```
~/
> #medias y varianzas de al por día
> tapply(data$al,data$Factordia,mean)
      lunes      martes miercoles      jueves      viernes
217.7647  210.3636  211.5833  212.7500  209.4706
> tapply(data$al, data$Factordia, var)
      lunes      martes miercoles      jueves      viernes
69.44118  49.86147  58.25362  58.09211  47.63971
>
>
```


#Comparación con normal. Visualización en gráficos

```
hist(data$al,freq = FALSE)
curve(dnorm(x,medal,sdal), 185, 240, add=T, col="red",lwd=2 )
plot(ecdf(data$al), main="Función de Distribución Empírica")
curve(pnorm(x,medal,sdal),185,240,add=T,col="red",lwd=2)
```

```
qqnorm((data$al-medal)/sdal) # Grafico Q-Q
abline(0,1) # se añade la recta y=x
```



Normalidad

Cumplimiento de hipótesis del modelo

Contraste de Kolmogorov-Smirnov

```
ks.test(data$a1, pnorm, mean=212.24, sd=7.85361)
```

```
>
```

```
>
```

```
> ks.test(data$a1, pnorm, mean=212.24, sd=7.85361)
```

```
one-sample kolmogorov-smirnov test
```

```
data: data$a1
```

```
D = 0.10531, p-value = 0.2173
```

```
alternative hypothesis: two-sided
```

Homoscedasticidad

#test de levene de igualdad de varianzas (Homoscedasticidad) se requiere paquete car

```
library(car)
```

```
leveneTest(data$a1, data$Factordia)
```

#test de Bartlett de Igualdad de varianzas

```
bartlett.test(a1 ~ Factordia, data=data)
```

```
> leveneTest(data$a1, data$Factordia)
```

```
Levene's Test for Homogeneity of Variance (center = median)
```

```
      Df F value Pr(>F)
```

```
group  4  0.4568 0.7672
```

```
      95
```

```
>
```

```
>
```

```
> bartlett.test(a1 ~ Factordia, data=data)
```

```
Bartlett test of homogeneity of variances
```

```
data: a1 by Factordia
```

```
Bartlett's K-squared = 0.74463, df = 4, p-value = 0.9457
```

```
> Anova <- aov(al ~ Factordia, data=data)
>
> summary(Anova)

          Df Sum Sq Mean Sq F value Pr(>F)
Factordia   4    742   185.57    3.287 0.0144 *
Residuals  95   5364    56.46

---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

>
\
```

Al 5 % de significación descartamos la Hip. Nula (medias iguales) . // al 1 % no podríamos.
Existen diferencias significativas (al 5 %) en el tiempo de fabricación entre los distintos días
El día de fabricación influye significativamente (al 5%) en el tiempo de fabricación

Comparaciones múltiples

```
> TukeyHSD(Anova)
Tukey multiple comparisons of means
 95% family-wise confidence level

Fit: aov(formula = al ~ Factordia, data = data)

$Factordia
              diff            lwr            upr      p adj
martes-lunes   -7.4010695 -14.148799 -0.6533403 0.0241638
miercoles-lunes -6.1813725 -12.805413  0.4426681 0.0793852
jueves-lunes   -5.0147059 -11.907932  1.8785206 0.2630799
viernes-lunes  -8.2941176 -15.461353 -1.1268821 0.0148644
miercoles-martes  1.2196970  -4.948001  7.3873949 0.9817005
jueves-martes   2.3863636  -4.069576  8.8423031 0.8418536
viernes-martes  -0.8930481  -7.640777  5.8546811 0.9960246
jueves-miercoles  1.1666667  -5.159882  7.4932154 0.9859016
viernes-miercoles -2.1127451  -8.736786  4.5112955 0.9010641
viernes-jueves  -3.2794118 -10.172638  3.6138147 0.6776695
```

Según el test de HSD de Tukey
Hay diferencias “honestamente”
significativas (5 %) entre el tiempo
de fabricación de los lunes y el de
los martes y, también entre los de
los lunes y los viernes

¿Otros test?

```

> library(agricolae)
> lsd<-LSD.test(Anova,"Factordia")
> lsd
$statistics
  MSerror Df   Mean    CV
56.46282 95 212.24 3.540414

$parameters
  test p.adjusted name.t ntr alpha
Fisher-LSD      none Factordia  5 0.05

$means
      al      std  r      LCL      UCL Min Max   Q25   Q50   Q75
jueves 212.7500 7.621818 20 209.4143 216.0857 200 224 207.75 210.5 220.25
lunes  217.7647 8.333137 17 214.1467 221.3827 205 228 209.00 220.0 225.00
martes 210.3636 7.061266 22 207.1832 213.5441 200 221 205.25 210.5 215.75
miercoles 211.5833 7.632406 24 208.5383 214.6284 200 223 204.00 211.5 219.00
viernes 209.4706 6.902152 17 205.8526 213.0886 200 224 203.00 208.0 214.00

```

```

$comparison
NULL


```

```

$groups
      al groups
lunes 217.7647 a
jueves 212.7500 b
miercoles 211.5833 b
martes 210.3636 b
viernes 209.4706 b

```

casi tampoco se solapa



```
> scheffe<-scheffe.test(Anova,"Factordia")
```

```
> scheffe
```

```
$statistics
```

MSerror	Df	F	Mean	CV
56.46282	95	2.467494	212.24	3.540414

```
$parameters
```

test	name.t	ntr	alpha
Scheffe	Factordia	5	0.05

```
$means
```

	al	std	r	Min	Max	Q25	Q50	Q75
jueves	212.7500	7.621818	20	200	224	207.75	210.5	220.25
lunes	217.7647	8.333137	17	205	228	209.00	220.0	225.00
martes	210.3636	7.061266	22	200	221	205.25	210.5	215.75
miercoles	211.5833	7.632406	24	200	223	204.00	211.5	219.00
viernes	209.4706	6.902152	17	200	224	203.00	208.0	214.00

```
$comparison
```

```
NULL
```

```
$groups
```

	al	groups
lunes	217.7647	a
jueves	212.7500	ab
miercoles	211.5833	ab
martes	210.3636	ab
viernes	209.4706	b

Basándonos en el criterio de Scheffé, que es el que exige más evidencia para detectar diferencias:

El tiempo de fabricación es significativamente superior el lunes y significativamente inferior el viernes . Siendo el resto de los días intermedio.

Dados estos resultados que parecen indicar claramente que el lunes tiene un comportamiento bien diferente (mayor tiempo de fabricación) podríamos plantearnos qué pasaría si sólo consideráramos el resto de los días (eliminando los datos de los lunes). Caso de no haber diferencias significativas la conclusión resultaría meridiana.

```
> # hacemos el ANOVA sin el lunes que parece tener un comportamiento "especial"
>
> datos2<-subset(data, data$Factordia != "lunes")
> fix(datos2)
>
> Anova2<-aov(a1~Factordia,data=datos2)
> summary(Anova2)
```

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
Factordia	3	117	39.04	0.725	0.54
Residuals	79	4253	53.83		

```
>
>
```

Ahora NO PODEMOS DESCARTAR la hipótesis nula. No podemos descartar que el tiempo medio de fabricación es el mismo los martes, miércoles jueves y viernes. Como, sin embargo, cuando considerábamos el lunes sí lo hicimos, la conclusión ...



Interacción de factores : Anova de dos factores o más

Si queremos investigar el posible efecto de 2 o más factores sobre una variable, el uso de una anova (de un factor) para cada factor nos puede llevar a conclusiones erróneas debido al fenómeno de la interacción: Podría ocurrir que los factores por separado no causarían efecto en la variable pero que la interacción de ambos (o más) factores sí, en según que combinaciones de niveles de ambos factores

X	FactorA	FactorB					
3	1	1					
4	1	1					
5	1	1					
6	1	1					
7	1	1					
11	1	2	Factor A				
10	1	2					
9	1	2					
8	1	2					
12	1	2					
9	2	1					
8	2	1					
10	2	1					
12	2	1					
11	2	1					
7	2	2					
5	2	2					
3	2	2					
4	2	2					
6	2	2					

MEDIAS EN INTERACCIÓN		B1	B2
	A1	5	10
	A2	10	5

	gl	F	
SCE_GRUPOS A	0 1 (grupos-1)	0	No hay diferencias según A
SCE_GRUPOS B	0 1 (grupos-1)	0	No hay diferencias según B
SCE INTERACCIÓN AxB	125 1 (grupos-f-1)	50	Sí hay diferencias si se combina A y B
SCI (residuo)	40 16 (n-grupos)		
SCT	165 19 (n-1)		



Introducimos los datos anteriores

```
nota <- c(3,4,5,6,7,11,10,9,8,12,9,8,10,12,11,7,
          5,3,4,6)
grupo <- c(rep(c("grupo a", "grupo b"), c(10,10)))
profesor <- rep(c(1,2), each = 5, times = 2)
datos <- data.frame(grupo = grupo,
                    profesor = as.factor( profesor), nota= nota)
```

Anovas por separado

```
> summary(aov(nota~grupo,data=datos))
              Df Sum Sq Mean Sq F value Pr(>F)
grupo          1      0    0.000      0     1
Residuals     18    165    9.167
> summary(aov(nota~profesor,data=datos))
              Df Sum Sq Mean Sq F value Pr(>F)
profesor       1      0    0.000      0     1
Residuals     18    165    9.167
```



```

> anova2F<-aov(nota~profesor*grupo,data=datos)
> summary(anova2F)

```


	Df	Sum Sq	Mean Sq	F value	Pr(>F)
profesor	1	0	0.0	0	1
grupo	1	0	0.0	0	1
profesor:grupo	1	125	125.0	50	2.65e-06 ***
Residuals	16	40	2.5		

```

---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
>
>
>

```

Anova de (los) dos factores



Ejemplo: con los datos de las base datos [bankdata](#) estudiar si la edad y el lugar de residencia afecta al saldo medio ponderado de los clientes.

```
> anova<-aov(saldomedio~region, data=bankdata)
> summary(anova)
              Df      Sum Sq   Mean Sq F value Pr(>F)
region          2  9.333e+06   4666404    0.404   0.668
Residuals      597  6.891e+09  11543135
> anovab<-aov(saldomedio~edad,data=bankdata)
> summary(anovab)
              Df      Sum Sq   Mean Sq F value Pr(>F)
edad            2  1.028e+07   5140026    0.445   0.641
Residuals      597  6.890e+09  11541548
> summary(anovac)
Error in summary(anovac) : object 'anovac' not found
> anovac<-aov(saldomedio~edad*region, data=bankdata)
> summary(anovac)
              Df      Sum Sq   Mean Sq F value Pr(>F)
edad            2  1.028e+07   5140026    0.446   0.641
region          2  9.533e+06   4766559    0.413   0.662
edad:region      4  6.372e+07  15930433    1.381   0.239
Residuals      591  6.817e+09  11534771
> |
```
