

Modelos politómicos con el paquete **eRm** de R

José Ant. López Pina

Índice

1	Introducción	2
2	Lectura de la base de datos	3
3	Análisis clásico de ítems	5
4	Modelo de crédito parcial	8
4.1	Estimación de parámetros	8
4.2	Gráficos en el modelo de crédito parcial	11
4.3	Estadísticos LR de Andersen y de Wald	13
4.4	Estadísticos de ajuste de medias de cuadrados	14
4.5	Fiabilidad de la separación	15
4.6	Cumplimiento de los principios	16
4.6.1	Unidimensionalidad	16
4.6.2	Independencia local de los ítems	16
5	Modelo de escalas de valoración	18
5.1	Estimación de parámetros	18
5.2	Gráficos	20
5.3	Estadísticos LR de Andersen y de Wald	23
5.4	Estadísticos de ajuste de medias de cuadrados	24
5.5	Fiabilidad de la separación	25
5.6	Cumplimiento de los principios del modelo	25
5.6.1	Unidimensionalidad	25
5.6.2	Independencia local de los ítems	26

Capítulo 1

Introducción

En este documento se presenta un ejemplo de cómo estimar parámetros con los modelos tipo Rasch y empleando R o RStudio con el paquete `eRm`. No obstante, para invertir los ítems se necesita otro paquete de R (`psych`). Antes de realizar cualquier análisis, recuerde instalar ambos paquetes con la función `install.packages("eRm")` e `install.packages("psych")` y cargar las librerías correspondientes con las funciones `library(eRm)` y `library(psych)`.

Capítulo 2

Lectura de la base de datos

El primer paso consiste en abrir una carpeta donde se encontrarán los datos de los tests que se desean analizar. Por ejemplo, en el disco principal (C:) abrimos una carpeta C:datos para alojar los archivos de datos. Para ello, utilizaremos la función `setwd("C:/datos")`. Esta carpeta permanecerá activa en tanto no se cambie de denominación o se borre del disco duro. A continuación, se asigna la matriz de datos `rse.dat` a un objeto. El objeto puede tener cualquier nombre, por ejemplo, `rse0`. Para ello utilizamos la función siguiente: `rse0 <- read.table("rse.dat", header=T, sep=",")`. La función `read.table` permite leer el archivo `rse.dat` que contiene los nombres de las variables en la primera fila y los ítems de la escala están separados (`sep`) por comas. La lectura del archivo se asigna al objeto `rse0` que contiene la matriz de datos que se desea analizar. Para estimar los parámetros de localización y los umbrales de las categorías, se deben eliminar de la matriz de datos las columnas que no forman parte del análisis, asignando el resultado a un nuevo objeto `rse1 <- rse0[, -c(1,12)]`. En este caso, se han eliminado las columnas que contienen el número de identificación y el género

La base de datos contiene las respuestas de 500 personas a 10 ítems en una escala de autoestima. Sin embargo, dado que algunos ítems (Q2, Q5, Q8, Q9 y Q10) están invertidos, el primer paso consistirá en reordenar las categorías para que el paquete `eRm` realicen las estimaciones apropiadamente. Para ello, debemos realizar la recodificación de los ítems invertidos con el paquete `psych`¹. Se asigna, entonces, a la función `clave` el orden directo (1) o inverso (-1) de los ítems del cuestionario. Debe haber tantos 1's y -1's como ítems haya en el cuestionario. Finalmente se crea un nuevo objeto (`rse`) donde se almacena la matriz de datos para el análisis con `eRm` una vez recodificados los ítems con la función `reverse.code()`. Estos pasos se resumen en las funciones siguientes:

```
library(psych)
setwd("c:/datos/")
rse0 <- read.table("rse.dat", header=T, sep=",")
rse1 <- rse0[, -c(1,12)]
clave <- c(1,-1,1,1,-1,1,1,-1,-1,-1)
rse <- reverse.code(clave, rse1)
```

Para comprobar que todo el proceso ha sido correcto se pueden obtener los seis primeros casos de cada objeto. Por ejemplo, los valores originales de la matriz de datos aparecen con:

```
head(rse1)
```

```
Q1 Q2 Q3 Q4 Q5 Q6 Q7 Q8 Q9 Q10
```

¹Recuerde instalar el paquete `psych` antes de cargar la librería correspondiente.

```

1 2 1 1 2 3 1 1 2 2 2
2 3 3 3 3 0 3 3 0 0 0
3 3 1 2 2 1 1 1 2 2 2
4 3 0 2 2 1 2 3 0 1 1
5 0 1 1 3 2 1 2 0 1 2
6 3 0 3 3 2 2 2 2 0 0

```

y con:

```
head(rse)
```

```

      Q1 Q2- Q3 Q4 Q5- Q6 Q7 Q8- Q9- Q10-
[1,]  2   2  1  2   0  1  1   1   1   1
[2,]  3   0  3  3   3  3  3   3   3   3
[3,]  3   2  2  2   2  1  1   1   1   1
[4,]  3   3  2  2   2  2  3   3   2   2
[5,]  0   2  1  3   1  1  2   3   2   1
[6,]  3   3  3  3   1  2  2   1   3   3

```

aparecen los valores recodificados de los ítems Q2, Q5, Q8, Q9 y Q10. Nótese que en este caso se ha añadido un signo - al lado del ítem invertido.

Antes de iniciar los análisis conviene evaluar la dimensionalidad de la matriz de datos con:

```
dim(rse)
```

```
[1] 500 10
```

y se pueden obtener los estadísticos básicos de los ítems con:

```
summary(rse)
```

```

      Q1          Q2-          Q3          Q4          Q5-
Min.   :0.000  Min.   :0.000  Min.   :0.000  Min.   :0.000  Min.   :0.00
1st Qu.:2.000  1st Qu.:2.000  1st Qu.:1.000  1st Qu.:1.000  1st Qu.:1.00
Median :2.000  Median :2.000  Median :2.000  Median :2.000  Median :2.00
Mean   :1.982  Mean   :2.064  Mean   :1.648  Mean   :1.902  Mean   :1.55
3rd Qu.:3.000  3rd Qu.:3.000  3rd Qu.:2.000  3rd Qu.:2.000  3rd Qu.:2.00
Max.   :3.000  Max.   :3.000  Max.   :3.000  Max.   :3.000  Max.   :3.00

      Q6          Q7          Q8-          Q9-          Q10-
Min.   :0.00  Min.   :0.000  Min.   :0.000  Min.   :0.000  Min.   :0.000
1st Qu.:1.00  1st Qu.:1.000  1st Qu.:1.000  1st Qu.:0.000  1st Qu.:0.000
Median :2.00  Median :1.000  Median :1.000  Median :1.000  Median :1.000
Mean   :1.48  Mean   :1.394  Mean   :1.342  Mean   :1.084  Mean   :1.272
3rd Qu.:2.00  3rd Qu.:2.000  3rd Qu.:2.000  3rd Qu.:2.000  3rd Qu.:2.000
Max.   :3.00  Max.   :3.000  Max.   :3.000  Max.   :3.000  Max.   :3.000

```

La distribución de frecuencias en todos los ítems se obtiene con:

```
apply(rse, 2, table)
```

```

      Q1 Q2-  Q3  Q4 Q5-  Q6  Q7 Q8-  Q9-  Q10-
0  32  19  61  23  74  71  93  85  136  130
1  85  66 141 107 159 178 174 225 234  184
2 243 279 211 266 185 191 176 124  82  106
3 140 136  87 104  82  60  57  66  48  80

```

Capítulo 3

Análisis clásico de ítems

Previamente a la aplicación de los modelos politómicos, se puede realizar un análisis descriptivo básico de todos los ítems. Para ello, empleamos el paquete `psych` con:

```
describe(rse)
```

	vars	n	mean	sd	median	trimmed	mad	min	max	range	skew	kurtosis	se
Q1	1	500	1.98	0.84	2	2.06	1.48	0	3	3	-0.61	-0.11	0.04
Q2-	2	500	2.06	0.74	2	2.13	0.00	0	3	3	-0.66	0.49	0.03
Q3	3	500	1.65	0.91	2	1.69	1.48	0	3	3	-0.23	-0.72	0.04
Q4	4	500	1.90	0.77	2	1.94	0.00	0	3	3	-0.43	-0.07	0.03
Q5-	5	500	1.55	0.93	2	1.56	1.48	0	3	3	-0.09	-0.87	0.04
Q6	6	500	1.48	0.88	2	1.48	1.48	0	3	3	-0.04	-0.72	0.04
Q7	7	500	1.39	0.92	1	1.37	1.48	0	3	3	0.03	-0.85	0.04
Q8-	8	500	1.34	0.91	1	1.30	1.48	0	3	3	0.32	-0.68	0.04
Q9-	9	500	1.08	0.90	1	0.98	1.48	0	3	3	0.62	-0.31	0.04
Q10-	10	500	1.27	1.02	1	1.22	1.48	0	3	3	0.34	-1.00	0.05

Ahora conviene examinar las medias y los índices de discriminación de los ítems de esta escala con:

```
alpha(rse)
```

Reliability analysis

Call: `alpha(x = rse)`

raw_alpha	std.alpha	G6(smc)	average_r	S/N	ase	mean	sd	median_r
0.91	0.91	0.91	0.49	9.7	0.0062	1.6	0.65	0.49

95% confidence boundaries

lower alpha upper

Feldt 0.89 0.91 0.92

Duhachek 0.89 0.91 0.92

Reliability if an item is dropped:

	raw_alpha	std.alpha	G6(smc)	average_r	S/N	alpha	se	var.r	med.r
Q1	0.90	0.90	0.90	0.49	8.5	0.0069	0.0105	0.48	
Q2-	0.90	0.90	0.90	0.50	8.9	0.0067	0.0100	0.49	
Q3	0.89	0.89	0.90	0.48	8.4	0.0071	0.0105	0.48	

Q4	0.90	0.90	0.91	0.51	9.2	0.0065	0.0108	0.51
Q5-	0.89	0.89	0.90	0.49	8.5	0.0070	0.0112	0.48
Q6	0.89	0.89	0.89	0.48	8.3	0.0072	0.0098	0.48
Q7	0.89	0.89	0.89	0.47	8.1	0.0073	0.0091	0.48
Q8-	0.91	0.91	0.91	0.52	9.7	0.0062	0.0074	0.51
Q9-	0.90	0.90	0.90	0.50	8.9	0.0067	0.0101	0.51
Q10-	0.89	0.89	0.89	0.48	8.4	0.0071	0.0105	0.48

Item statistics

	n	raw.r	std.r	r.cor	r.drop	mean	sd
Q1	500	0.75	0.76	0.73	0.68	2.0	0.84
Q2-	500	0.69	0.71	0.67	0.62	2.1	0.74
Q3	500	0.79	0.78	0.76	0.73	1.6	0.91
Q4	500	0.65	0.67	0.61	0.58	1.9	0.77
Q5-	500	0.76	0.76	0.73	0.69	1.6	0.93
Q6	500	0.80	0.80	0.78	0.74	1.5	0.88
Q7	500	0.82	0.82	0.80	0.76	1.4	0.92
Q8-	500	0.60	0.60	0.52	0.50	1.3	0.91
Q9-	500	0.71	0.70	0.67	0.63	1.1	0.90
Q10-	500	0.79	0.77	0.75	0.71	1.3	1.02

Non missing response frequency for each item

	0	1	2	3	miss
Q1	0.06	0.17	0.49	0.28	0
Q2-	0.04	0.13	0.56	0.27	0
Q3	0.12	0.28	0.42	0.17	0
Q4	0.05	0.21	0.53	0.21	0
Q5-	0.15	0.32	0.37	0.16	0
Q6	0.14	0.36	0.38	0.12	0
Q7	0.19	0.35	0.35	0.11	0
Q8-	0.17	0.45	0.25	0.13	0
Q9-	0.27	0.47	0.16	0.10	0
Q10-	0.26	0.37	0.21	0.16	0

que produce una pléyade de estadísticos para todos los ítems. En este caso, la media de cada ítem se encuentra en la columna `mean` y el índice de discriminación en la columna `r.drop`.

Finalmente, se pueden obtener diferentes coeficientes de fiabilidad en este paquete con:

```
splitHalf(rse)
```

Split half reliabilities

Call: splitHalf(r = rse)

```
Maximum split half reliability (lambda 4) = 0.94
Guttman lambda 6 = 0.91
Average split half reliability = 0.91
Guttman lambda 3 (alpha) = 0.91
Guttman lambda 2 = 0.91
Minimum split half reliability (beta) = 0.86
Average interitem r = 0.49 with median = 0.49
```

que produce los coeficientes de consistencia interna alfa (`alpha`), omega(`omega.tot`), una medida de mitades τ -equivalentes (`tau`), una medida de tests congénéricos (`con`) y una

medida experimental de la unidimensionalidad de la escala (Uni), y los coeficientes `lambda_2`, `lambda_3` y `lambda_6` de Guttman. Una estimación del mayor límite menor de Guttman se obtiene con:

```
glb.algebraic(rse)
```

```
Loading required namespace: Rcsdp
```

```
$glb
```

```
[1] 0.9416232
```

```
$solution
```

```
      Q1      Q2-      Q3      Q4      Q5-      Q6      Q7      Q8-  
0.4288371 0.4913827 0.5705609 0.2954630 0.5598519 0.6784633 0.6592813 0.3214192  
      Q9-      Q10-  
0.5666536 0.8000429
```

```
$status
```

```
[1] 0
```

```
$Call
```

```
glb.algebraic(Cov = rse)
```

```
detach(package:psych)
```

Capítulo 4

Modelo de crédito parcial

4.1 Estimación de parámetros

La estimación de parámetros en este modelo y la convergencia del proceso iterativo se realiza con las siguientes acciones:

```
library(eRm)
m.mcp <- PCM(rse, sum0=F, se=TRUE)
m.mcp$convergence
```

```
[1] 1
```

Los parámetros de localización (`Location`) y los umbrales de las categorías (`Threshold 1`, `Threshold 2`, `Threshold 3`) para cada uno de los 10 ítems se obtienen con:

```
thresholds(m.mcp)$threshtable$'1'
```

	Location	Threshold 1	Threshold 2	Threshold 3
Q1	1.687993	0.0000000	1.0813481	3.982632
Q2-	1.382051	-0.4849361	0.5291021	4.101987
Q3	2.494968	0.5844973	2.1611232	4.739283
Q4	1.761365	-0.5672655	1.3004441	4.550915
Q5-	2.698881	0.7947426	2.5370357	4.764865
Q6	2.887196	0.6672721	2.7047986	5.289517
Q7	3.099117	1.0988209	2.8659859	5.332545
Q8-	3.074486	0.7944636	3.5641121	4.864882
Q9-	3.667315	1.5433731	4.3488825	5.109689
Q10-	3.210997	1.5976854	3.5807510	4.454555

El argumento `sum0=F` fija el umbral del primer ítem a 0 para que se pueda resolver la arbitrariedad de la estimación de parámetros en el modelo. El parámetro de localización (`Location`) de un ítem se define como el promedio de los parámetros de umbral en ese ítem. Por ejemplo, el parámetro de localización del ítem 1 es el resultado del promedio de los tres umbrales $(0 + 1.0813481 + 3.982632)/3 = (1.687993)$. Los errores típicos de los parámetros se pueden obtener:

```
cbind(thresholds(m.mcp)$threshtar, thresholds(m.mcp)$se.thresh)
```

```
          [,1]      [,2]
thresh beta Q1.c1  0.0000000 0.0000000
thresh beta Q1.c2  1.0813481 0.3062390
```

```

thresh beta Q1.c3      3.9826319 0.2768275
thresh beta Q2-.c1    -0.4849361 0.3587669
thresh beta Q2-.c2     0.5291021 0.2804167
thresh beta Q2-.c3     4.1019866 0.2778013
thresh beta Q3.c1      0.5844973 0.2871478
thresh beta Q3.c2      2.1611232 0.2721941
thresh beta Q3.c3      4.7392831 0.2929903
thresh beta Q4.c1     -0.5672655 0.3355826
thresh beta Q4.c2      1.3004441 0.2716356
thresh beta Q4.c3      4.5509151 0.2851817
thresh beta Q5-.c1     0.7947426 0.2808368
thresh beta Q5-.c2     2.5370357 0.2729741
thresh beta Q5-.c3     4.7648646 0.2965596
thresh beta Q6.c1      0.6672721 0.2805814
thresh beta Q6.c2      2.7047986 0.2719500
thresh beta Q6.c3      5.2895167 0.3082963
thresh beta Q7.c1      1.0988209 0.2754446
thresh beta Q7.c2      2.8659859 0.2739618
thresh beta Q7.c3      5.3325453 0.3116823
thresh beta Q8-.c1     0.7944636 0.2746575
thresh beta Q8-.c2     3.5641121 0.2769069
thresh beta Q8-.c3     4.8648825 0.3107244
thresh beta Q9-.c1     1.5433731 0.2679499
thresh beta Q9-.c2     4.3488825 0.2870488
thresh beta Q9-.c3     5.1096886 0.3344739
thresh beta Q10-.c1    1.5976854 0.2702315
thresh beta Q10-.c2    3.5807510 0.2818654
thresh beta Q10-.c3    4.4545549 0.3059900

```

Los umbrales de las categorías aparece en la primera columna [,1], y los errores típicos en la segunda columna [,2].

Los parámetros de localización del modelo de crédito parcial en `eRm` no suman 0. Sin embargo, en algunos contextos de investigación puede ser interesante que esta suma sea 0. En ese caso, sólo es preciso reescalar los parámetros de localización (`Location`) creando un objeto que contenga la media de los parámetros de localización y se resten a cada uno de los parámetros de la salida anterior. Para ello, realizamos la siguiente operación:

```

rse2 <- thresholds(m.mcp)$threshtable$'1'
media <- mean(rse2[,1])
rse2-media

```

	Location	Threshold 1	Threshold 2	Threshold 3
Q1	-0.9084435	-2.5964369	-1.51508879	1.386195
Q2-	-1.2143860	-3.0813729	-2.06733479	1.505550
Q3	-0.1014690	-2.0119396	-0.43531369	2.142846
Q4	-0.8350723	-3.1637023	-1.29599277	1.954478
Q5-	0.1024441	-1.8016943	-0.05940114	2.168428
Q6	0.2907590	-1.9291647	0.10836174	2.693080
Q7	0.5026805	-1.4976159	0.26954906	2.736108
Q8-	0.4780492	-1.8019733	0.96767523	2.268446
Q9-	1.0708779	-1.0530637	1.75244562	2.513252
Q10-	0.6145602	-0.9987514	0.98431416	1.858118

Ahora se puede obtener los parámetros de habilidad (autoestima) en esta escala y guardarlos en un objeto con:

```
autoest <- person.parameter(m.mcp)
```

Si escribimos el nombre del objeto tendremos la estimación de los parámetros de habilidad (autoestima) para todas las puntuaciones posibles¹.

```
autoest
```

Person Parameters:

Raw Score	Estimate	Std.Error
0	-2.7274119	NA
1	-1.8803983	1.0406325
2	-1.1020788	0.7664541
3	-0.6065863	0.6526710
4	-0.2234108	0.5902368
5	0.1011818	0.5518745
6	0.3913393	0.5270932
7	0.6601206	0.5108922
8	0.9154691	0.5005286
9	1.1626137	0.4943144
10	1.4051663	0.4910942
11	1.6456520	0.4899782
12	1.8857621	0.4902068
13	2.1264639	0.4910717
14	2.3680559	0.4919181
15	2.6102458	0.4922125
16	2.8523176	0.4916514
17	3.0934185	0.4902726
18	3.3329211	0.4884865
19	3.5707617	0.4870089
20	3.8076710	0.4867374
21	4.0452965	0.4886578
22	4.2863010	0.4938449
23	4.5345659	0.5035829
24	4.7956694	0.5196366
25	5.0779507	0.5447893
26	5.3948961	0.5840360
27	5.7710809	0.6477911
28	6.2606471	0.7631900
29	7.0343803	1.0391209
30	7.8771014	NA

En este caso, se está empleando el método de máxima verosimilitud condicional, por lo que no se dispone de una estimación de los parámetros de habilidad para las puntuaciones extremas (0 y 30). Si se desea obtener estimaciones de la habilidad para puntuaciones extremas, entonces se debe emplear el método de máxima verosimilitud marginal implementado en los paquetes `ltm` y `mirt`.

¹Recuerda que en una escala con ítems politómicos, la puntuación posible es igual al número de categorías (k) por el número de ítems (n). Así, en esta escala con cuatro categorías (0,1,2,3) y 10 ítems, las puntuaciones posibles varían entre $k*n = 0*10 = 0$ y $k*n = 3*10 = 30$.

Las estimaciones de los parámetros de habilidad (autoestima) para cada una de las 500 personas del grupo, incluyendo aquéllas que tienen puntuaciones 0 o la puntuación 30, se pueden obtener con:

```
head(coef(autoest))
```

```

      P1      P2      P3      P4      P5      P6
1.885762 5.771081 2.852318 4.795669 2.852318 4.795669

```

Para visualizar los parámetros de habilidad (autoestima) [,1] y sus correspondientes errores típicos [,2] para todo el grupo se pueden obtener con:

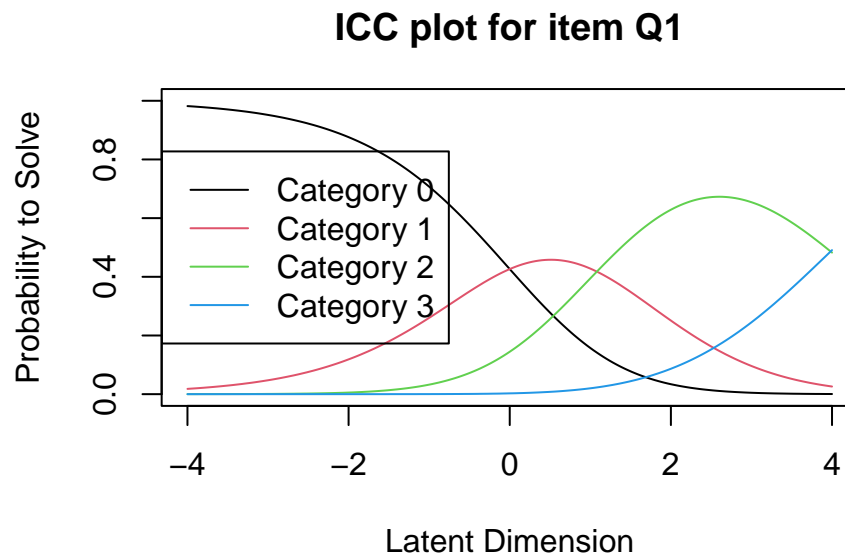
```
summary(round(cbind(autoest$thetapar$NAGroup1, autoest$se.theta $NAGroup1), 3))
```

V1		V2	
Min.	:-1.880	Min.	:0.4870
1st Qu.:	1.646	1st Qu.:	0.4900
Median :	2.610	Median :	0.4920
Mean :	2.742	Mean :	0.5194
3rd Qu.:	3.808	3rd Qu.:	0.5040
Max. :	7.034	Max. :	1.0410

4.2 Gráficos en el modelo de crédito parcial

Para construir un gráfico de la Función de Respuesta de las Categorías del ítem 1 emplearemos:

```
plotICC(m.mcp, 1)
```




En el modelo de crédito parcial cada categoría tiene una curva diferente. La curva para la categoría más baja siempre es monótonica decreciente, mientras que la curva para la categoría más alta siempre es monótonica creciente. Las curvas de las categorías centrales son unimodales. Los parámetros de umbral se corresponden con los puntos en los que se cruzan las categorías adyacentes.

Para construir un gráfico de las Funciones de Información de los Ítems se emplea:

```
plotINFO(m.mcp, type="item")
```


Item Information



y para construir un gráfico de la Función de Información test completo se emplea:

```
plotINFO(m.mcp, type="test")
```


Scale Information



El mapa de ítems-personas se obtiene con:

```
plotPimap(m.mcp)
```

Person-Item Map



En este caso, se aprecia que las categorías de los ítems están bien ordenadas, aunque el intervalo de separación de una categoría a otra varía en cada uno de los ítems. Los puntos blancos indican los parámetros de umbral, mientras que el punto negro indica el parámetro de localización para cada ítem.

4.3 Estadísticos LR de Andersen y de Wald

El estadístico de razón de verosimilitud (`LRtest`) de Andersen también se puede utilizar para verificar si las respuestas a los ítems siguen el modelo de crédito parcial. El resultado se obtiene con:

```
LRtest(m.mcp)
```

```
Warning in LRtest.Rm(m.mcp):
```

```
The following items were excluded due to inappropriate response patterns within subgroups:
```

```
Q6 Q3
```

```
Full and subgroup models are estimated without these items!
```

```
Andersen LR-test:
```

```
LR-value: 146.565
```

```
Chi-square df: 23
```

```
p-value: 0
```

que determina que los ítems Q3 y Q6 tienen patrones de respuesta no apropiados, aunque el estadístico χ^2 es altamente significativo (`p-value: 0`) e indica que los ítems de esta escala no siguen el modelo de crédito parcial.

El estadístico de Wald informa de que muchos umbrales no siguen el modelo especificado (`p-value < 0.05`),

```
Waldtest(m.mcp)
```

```
Warning in Waldtest.Rm(m.mcp):
```

```
The following items were excluded due to inappropriate response patterns within
```

subgroups:
Q6 Q3

Subgroup models are estimated without these items!

Wald test on item level (z-values):

	z-statistic	p-value
beta Q1.c1	3.129	0.002
beta Q1.c2	1.525	0.127
beta Q1.c3	0.155	0.877
beta Q2-.c1	4.571	0.000
beta Q2-.c2	4.173	0.000
beta Q2-.c3	2.694	0.007
beta Q4.c1	2.917	0.004
beta Q4.c2	1.582	0.114
beta Q4.c3	2.034	0.042
beta Q5-.c1	-1.448	0.148
beta Q5-.c2	-2.390	0.017
beta Q5-.c3	-2.157	0.031
beta Q7.c1	-1.974	0.048
beta Q7.c2	-3.420	0.001
beta Q7.c3	-2.558	0.011
beta Q8-.c1	0.272	0.786
beta Q8-.c2	0.729	0.466
beta Q8-.c3	2.148	0.032
beta Q9-.c1	-2.951	0.003
beta Q9-.c2	-3.550	0.000
beta Q9-.c3	2.169	0.030
beta Q10-.c1	-2.817	0.005
beta Q10-.c2	-4.020	0.000
beta Q10-.c3	-1.167	0.243

En ambos casos, los ítems Q3 y Q6 parecen que no siguen el modelo especificado, pero emplearemos a continuación los estadísticos basados en las medias de cuadrados de residuales.

4.4 Estadísticos de ajuste de medias de cuadrados

Para obtener los estadísticos de ajuste basados en las medias de cuadrados de residuales empleamos:

```
itemfit(autoest)
```

Itemfit Statistics:

	Chisq	df	p-value	Outfit MSQ	Infit MSQ	Outfit t	Infit t	Discrim
Q1	410.166	490	0.996	0.835	0.849	-2.505	-2.423	0.718
Q2-	484.192	490	0.566	0.986	0.912	-0.172	-1.327	0.655
Q3	381.757	490	1.000	0.778	0.791	-3.779	-3.643	0.747
Q4	550.378	490	0.030	1.121	1.037	1.794	0.597	0.585
Q5-	439.665	490	0.950	0.895	0.885	-1.691	-1.934	0.711
Q6	369.902	490	1.000	0.753	0.741	-4.343	-4.651	0.770

Q7	353.535	490	1.000	0.720	0.707	-4.884	-5.346	0.792
Q8-	714.116	490	0.000	1.454	1.346	6.163	5.011	0.488
Q9-	546.715	490	0.039	1.113	1.017	1.610	0.283	0.643
Q10-	416.979	490	0.993	0.849	0.867	-2.199	-2.198	0.741

En este caso también se emplean los estadísticos de medias de cuadrados INFIT y OUTFIT para determinar si el ítem sigue el modelo de crédito parcial. Sin embargo, el intervalo aconsejable suele ser [0.6–1.4]. Un ítem que obtiene una media de cuadrados INFIT u OUTFIT, por debajo de 0.6 se puede mantener en la escala. Sin embargo, si el ítem obtiene una media de cuadrados por encima de 1.4, entonces se debe revisar o eliminar si no se encuentra una explicación clara del desajuste. En este caso, una inspección de la tabla interior determina que el ítem Q8 obtiene una media de cuadrados no ponderada por encima de 1.4, por lo que se podría rechazar y volver a estudiar si el resto de ítems sigue el modelo de crédito parcial.

El ajuste de los patrones de respuesta de las personas al modelo se obtiene con la función²,

```
pfit <- personfit(autoest)
head(pfit$p.infitMSQ, 5)
```

	P1	P2	P3	P4	P5
	0.4289187	3.7958476	0.4035121	0.6008941	2.6354436

```
head(pfit$p.outfitMSQ, 5)
```

	P1	P2	P3	P4	P5
	0.3857096	6.2869783	0.4263520	0.6361129	2.8841665

La interpretación de las medias de cuadrados OUTFIT e INFIT es similar a las medias de cuadrados de los ítems, aunque en este caso se suele utilizar el intervalo [0.5–1.5] para determinar el ajuste del patrón de respuestas a los ítems. Si el valor de la media de cuadrados OUTFIT y/o INFIT es mayor que 1.5, entonces se debe revisar el patrón de respuestas de esas persona. En este caso, los patrones de respuesta de las personas P2 y P5 son claramente aberrantes y se debe reexaminar.

4.5 Fiabilidad de la separación

En este modelo también es posible determinar la fiabilidad de la separación de parámetros con:

```
summary(SepRel(autoest))
```

Separation Reliability: 0.8941

Observed Variance: 2.6135 (Squared Standard Deviation)

Mean Square Measurement Error: 0.2768 (Model Error Variance)

que indica que los parámetros de habilidad están suficientemente separados.

²La salida se ha abreviado a los cinco primeros casos, dado que la función `personfit()` devuelve todos los estadísticos de ajuste para la matriz completa.

4.6 Cumplimiento de los principios

4.6.1 Unidimensionalidad

Para probar la unidimensionalidad, el paquete `eRm` permite calcular los residuales de la matriz de respuestas una vez ajustado el modelo de crédito parcial. Un análisis de componentes principales de esa matriz de residuales permite determinar si el primer eigenvalor es mayor que 2.0. Para realizar el análisis de la unidimensionalidad se debe calcular la matriz de residuales y después realizar el análisis de componentes principales de esa matriz de residuales con:

```
residual <- residuals(autoest)
prcomp(residual, scale=T)
```

Standard deviations (1, .., p=10):

```
[1] 1.3769579 1.2536971 1.1480136 1.1104841 1.0178167 0.9656149 0.8720122
[8] 0.7933727 0.7756415 0.1459174
```

Rotation (n x k) = (10 x 10):

	PC1	PC2	PC3	PC4	PC5	PC6
Q1	-0.28323701	-0.44627396	-0.221945377	-0.15621252	-0.22568045	-0.34267905
Q2-	-0.27316198	-0.52583463	-0.009317527	-0.07047074	-0.25885950	0.10679100
Q3	-0.06414340	0.30440400	0.443338095	-0.24897218	0.10347548	-0.70577173
Q4	-0.03844997	-0.34092014	0.243191823	0.32910272	0.72226134	0.09728847
Q5-	-0.04831142	0.12801186	0.621457404	-0.19068353	-0.32257836	0.51978042
Q6	-0.32648477	0.40184048	-0.369163970	-0.01911390	-0.08437924	0.08860790
Q7	-0.33624664	0.29676485	-0.295836144	-0.23768807	0.38995577	0.25598171
Q8-	0.09633013	0.21372431	-0.068013999	0.77970890	-0.29016388	-0.10578934
Q9-	0.56824797	-0.05364658	-0.139412703	-0.16602129	-0.01476470	0.09168566
Q10-	0.53422206	-0.03099893	-0.246759665	-0.26759216	0.04512480	-0.02099136
	PC7	PC8	PC9	PC10		
Q1	-0.48226074	-0.37887581	-0.11892788	0.2971994		
Q2-	0.47485235	0.50485210	0.08241112	0.2797552		
Q3	0.15337069	0.15537859	-0.03154613	0.2953081		
Q4	0.10320178	-0.25890619	0.04580709	0.3223917		
Q5-	-0.19878489	-0.18678565	0.05751772	0.3267543		
Q6	0.51267681	-0.48088550	0.05991903	0.2874625		
Q7	-0.37431672	0.44803846	-0.12186033	0.2855882		
Q8-	-0.18655847	0.20750622	0.01835299	0.3986030		
Q9-	0.16178353	-0.01861966	-0.69813374	0.3235456		
Q10-	-0.06574751	0.01090100	0.68300443	0.3282323		

Si se eleva al cuadrado la desviación típica del primer eigenvalor (1.3485804) tenemos la varianza asociada a esta dimensión (1.818669) que no debe ser mayor de 2.0 para aceptar la unidimensionalidad de la escala, como ocurre en este caso.

4.6.2 Independencia local de los ítems

La independencia local se puede probar a través del examen de las correlaciones a partir de los residuales una vez ajustado el modelo de crédito parcial con:

```
cor(residual)
```

	Q1	Q2-	Q3	Q4	Q5-	Q6
Q1	1.00000000	0.25957292	-0.14864929	-0.05203672	-0.18416552	-0.07924606
Q2-	0.25957292	1.00000000	-0.19524692	0.04527616	-0.05991311	-0.08838975

Q3	-0.14864929	-0.19524692	1.00000000	-0.11611253	0.07166034	-0.03179050
Q4	-0.05203672	0.04527616	-0.11611253	1.00000000	-0.11881862	-0.25047273
Q5-	-0.18416552	-0.05991311	0.07166034	-0.11881862	1.00000000	-0.13285051
Q6	-0.07924606	-0.08838975	-0.03179050	-0.25047273	-0.13285051	1.00000000
Q7	-0.02728180	-0.12304227	-0.03937722	-0.11458008	-0.10047790	0.24799175
Q8-	-0.21017430	-0.22431454	-0.14938249	-0.09882632	-0.15196733	-0.02574318
Q9-	-0.22350286	-0.20092607	-0.15484772	-0.12876012	-0.13279355	-0.25951187
Q10-	-0.17054040	-0.22342734	-0.14067274	-0.16402521	-0.18503260	-0.23188748
	Q7	Q8-	Q9-	Q10-		
Q1	-0.02728180	-0.21017430	-0.22350286	-0.17054040		
Q2-	-0.12304227	-0.22431454	-0.20092607	-0.22342734		
Q3	-0.03937722	-0.14938249	-0.15484772	-0.14067274		
Q4	-0.11458008	-0.09882632	-0.12876012	-0.16402521		
Q5-	-0.10047790	-0.15196733	-0.13279355	-0.18503260		
Q6	0.24799175	-0.02574318	-0.25951187	-0.23188748		
Q7	1.00000000	-0.19351663	-0.26650906	-0.19346714		
Q8-	-0.19351663	1.00000000	-0.09632089	-0.13843260		
Q9-	-0.26650906	-0.09632089	1.00000000	0.38300240		
Q10-	-0.19346714	-0.13843260	0.38300240	1.00000000		

En este caso, algunas correlaciones entre los residuales han resultado por encima de 0.20, por lo que se puede sospechar de que las respuestas a los ítems no son totalmente independientes. Es trabajo del profesional determinar si las causas de esta falta de independencia local es un problema para la escala o es un simple efecto del atributo que se está evaluando.

Capítulo 5

Modelo de escalas de valoración

5.1 Estimación de parámetros

La aplicación del modelo de escalas de valoración en el paquete `eRm` supone prácticamente seguir los mismos pasos que para el modelo de crédito parcial. La diferencia más importante es que se debe crear un objeto que contenga los parámetros estimados con la función `RSM` tal como:

```
m.mev <- RSM(rse, sum0=T)
```

El examen de los resultados se obtiene con:

```
summary(m.mev)
```

Results of RSM estimation:

Call: RSM(X = rse, sum0 = T)

Conditional log-likelihood: -3538.066

Number of iterations: 23

Number of parameters: 11

Item (Category) Difficulty Parameters (eta): with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
Q2-	-1.262	0.075	-1.409	-1.114
Q3	-0.175	0.067	-0.307	-0.044
Q4	-0.823	0.071	-0.961	-0.684
Q5-	0.066	0.067	-0.064	0.197
Q6	0.238	0.067	0.107	0.369
Q7	0.448	0.067	0.317	0.580
Q8-	0.576	0.068	0.443	0.708
Q9-	1.219	0.072	1.078	1.361
Q10-	0.748	0.069	0.614	0.882
Cat 2	1.811	0.084	1.647	1.975
Cat 3	6.043	0.179	5.692	6.394

Item Easiness Parameters (beta) with 0.95 CI:

	Estimate	Std. Error	lower CI	upper CI
--	----------	------------	----------	----------

beta Q1.c1	1.036	0.073	0.893	1.179
beta Q1.c2	0.261	0.155	-0.042	0.564
beta Q1.c3	-2.935	0.244	-3.412	-2.457
beta Q2-.c1	1.262	0.075	1.114	1.409
beta Q2-.c2	0.712	0.157	0.404	1.020
beta Q2-.c3	-2.258	0.242	-2.733	-1.783
beta Q3.c1	0.175	0.067	0.044	0.307
beta Q3.c2	-1.460	0.154	-1.763	-1.157
beta Q3.c3	-5.516	0.262	-6.029	-5.004
beta Q4.c1	0.823	0.071	0.684	0.961
beta Q4.c2	-0.166	0.153	-0.466	0.134
beta Q4.c3	-3.575	0.246	-4.057	-3.092
beta Q5-.c1	-0.066	0.067	-0.197	0.064
beta Q5-.c2	-1.944	0.157	-2.252	-1.636
beta Q5-.c3	-6.242	0.270	-6.771	-5.713
beta Q6.c1	-0.238	0.067	-0.369	-0.107
beta Q6.c2	-2.287	0.160	-2.600	-1.974
beta Q6.c3	-6.757	0.276	-7.299	-6.215
beta Q7.c1	-0.448	0.067	-0.580	-0.317
beta Q7.c2	-2.708	0.164	-3.029	-2.387
beta Q7.c3	-7.388	0.285	-7.947	-6.829
beta Q8-.c1	-0.576	0.068	-0.708	-0.443
beta Q8-.c2	-2.962	0.167	-3.289	-2.636
beta Q8-.c3	-7.770	0.291	-8.340	-7.200
beta Q9-.c1	-1.219	0.072	-1.361	-1.078
beta Q9-.c2	-4.250	0.184	-4.610	-3.890
beta Q9-.c3	-9.701	0.323	-10.333	-9.068
beta Q10-.c1	-0.748	0.069	-0.882	-0.614
beta Q10-.c2	-3.307	0.171	-3.641	-2.972
beta Q10-.c3	-8.286	0.299	-8.872	-7.700

En este caso aparecen las estimaciones de los parámetros de localización (**eta**) de los ítems en este modelo y los parámetros de facilidad (**beta**) junto a sus intervalos confidenciales. Para obtener de forma resumida las estimaciones de los parámetros de localización y de los umbrales de los ítems empleamos:

```
thresholds(m.mev)
```

Design Matrix Block 1:

	Location	Threshold 1	Threshold 2	Threshold 3
Q1	0.97821	-1.03605	0.77492	3.19575
Q2-	0.75270	-1.26155	0.54942	2.97025
Q3	1.83877	-0.17548	1.63549	4.05631
Q4	1.19162	-0.82263	0.98834	3.40916
Q5-	2.08071	0.06646	1.87743	4.29825
Q6	2.25229	0.23803	2.04900	4.46983
Q7	2.46262	0.44836	2.25933	4.68016
Q8-	2.58997	0.57571	2.38668	4.80751
Q9-	3.23353	1.21927	3.03024	5.45107
Q10-	2.76213	0.74787	2.55884	4.97967

y podemos reescalar los parámetros con la función:

```
rse3 <- thresholds(m.mev)$threshtable$'1'
medial <- mean(rse3[,1])
rse3-medial
```

	Location	Threshold 1	Threshold 2	Threshold 3
Q1	-1.03604762	-3.050303	-1.23933382	1.1814942
Q2-	-1.26155185	-3.275807	-1.46483805	0.9559899
Q3	-0.17548284	-2.189738	-0.37876904	2.0420590
Q4	-0.82263251	-2.836888	-1.02591871	1.3949093
Q5-	0.06645578	-1.947800	-0.13683043	2.2839976
Q6	0.23803346	-1.776222	0.03474725	2.4555753
Q7	0.44836384	-1.565892	0.24507764	2.6659056
Q8-	0.57571342	-1.438542	0.37242722	2.7932552
Q9-	1.21927455	-0.794981	1.01598835	3.4368163
Q10-	0.74787377	-1.266382	0.54458757	2.9654156

Ahora se puede aplicar la función `anova()` para comparar el modelo de escalas de valoración versus el modelo de crédito parcial. Se debe realizar en este orden, dado que la función compara el modelo con menos parámetros contra el modelo con más parámetros. El modelo con menos parámetros es el modelo de escalas de valoración, ya que requiere que todos los ítems tengan el mismo número de categorías y los parámetros de umbral son iguales para todos los ítems. En este caso, emplearemos:

```
anova(m.mev, m.mcp)
```

Analysis of Deviances Table

Model 1: PCM(X = rse, se = TRUE, sum0 = F)

Model 2: RSM(X = rse, sum0 = T)

	cond.	LL	Deviance	npar	LR	df	p-value
Model 1	-3447.3	6894.5	29				
Model 2	-3538.1	7076.1	11	90.809	18	1.033e-11	***

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

Note: The models appear to be nested, please check this assumption.

que ha obtenido un estadístico de razón de verosimilitud (LR) de 90.809 que es altamente significativo ($1.033e(-11)$ ***), lo que indica que se rechaza la hipótesis nula de ambos modelos explican por igual las respuestas a los ítems. En este caso, el modelo de crédito parcial produce una desviación más baja que el modelo de escalas de valoración.


Generalmente, el modelo de crédito parcial siempre produce un mejor ajuste porque es un modelo que incluye más parámetros. La posición de emplear un modelo u otro depende del punto de partida del profesional. Por regla general, en tests de rendimiento se suele emplear el modelo de crédito parcial, mientras que el modelo de escalas de valoración se emplea en escalas de personalidad y actitudes, para las que fue diseñado específicamente. No obstante, a continuación replicamos todos los pasos realizados con el modelo de crédito parcial.

5.2 Gráficos

El mapa de ítems-personas en este modelo se obtiene con:

```
plotPImap(m.mev)
```

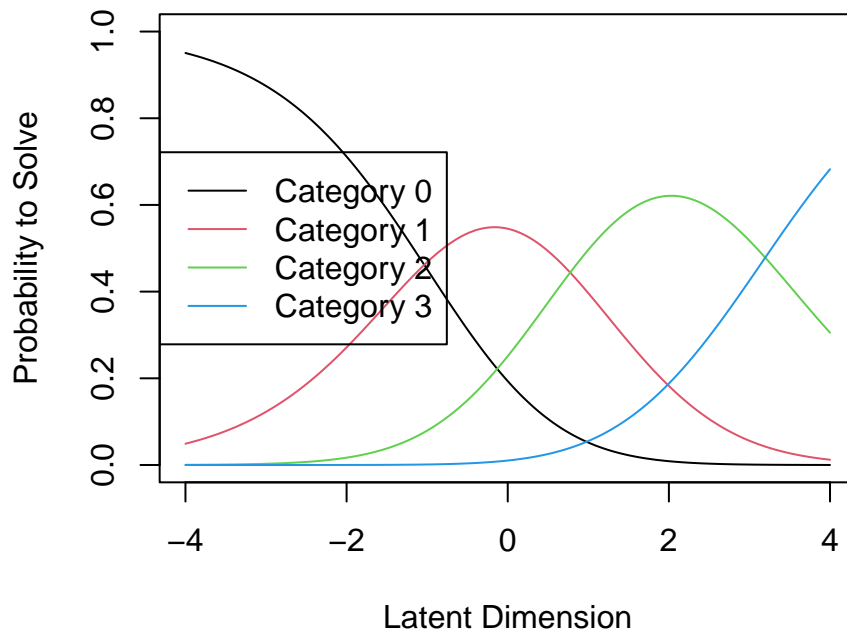
Person-Item Map



Este mapa es muy semejante al del modelo de crédito parcial, pero obviamente, los parámetros de los umbrales son ligeramente diferentes. La FRC del ítem 1 en este modelo se obtiene con:

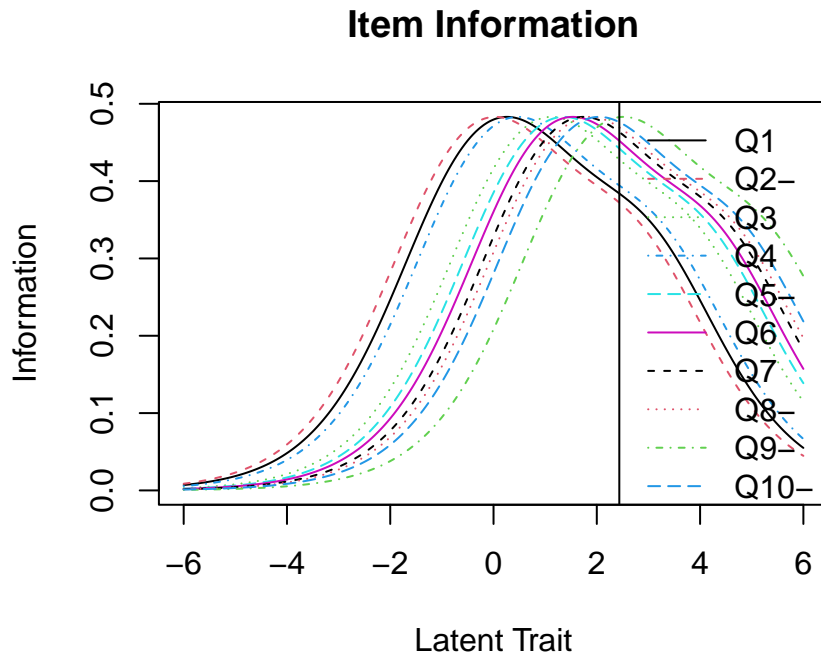
```
plotICC(m.mev, 1)
```

ICC plot for item Q1



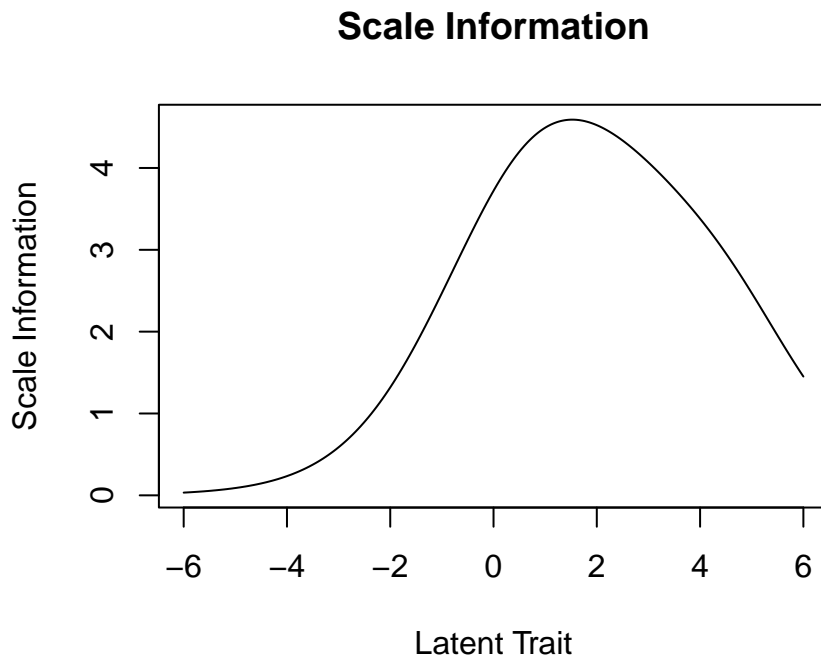
Para representar gráficamente las Funciones de Información de los Ítems en este modelo se emplea:

```
plotINFO(m.mev, type="item")
```



y para representar gráficamente la Función de Información test completo se emplea:

```
plotINFO(m.mev, type="test")
```



5.3 Estadísticos LR de Andersen y de Wald

El estadístico de razón de verosimilitud (`LRtest`) de Andersen también se puede utilizar para verificar si las respuestas a los ítems siguen el modelo de escalas de valoración. Este estadístico se obtiene con:

```
LRtest(m.mev)
```

```
Warning in LRtest.Rm(m.mev):
```

```
The following items were excluded due to inappropriate response patterns within subgroups:
```

```
Q6 Q3
```

```
Full and subgroup models are estimated without these items!
```

```
Andersen LR-test:
```

```
LR-value: 70.432
```

```
Chi-square df: 9
```

```
p-value: 0
```

que determina que dos ítems (Q3 y Q6) tienen patrones de respuestas no apropiados. Además, el estadístico χ^2 es altamente significativo (`p-value: 0`), indicando que los ítems de esta escala no siguen el modelo de escalas de valoración.

El estadístico de Wald informa de que muchos umbrales no siguen el modelo especificado:

```
Waldtest(m.mev)
```

```
Warning in Waldtest.Rm(m.mev):
```

```
The following items were excluded due to inappropriate response patterns within subgroups:
```

```
Q6 Q3
```

```
Subgroup models are estimated without these items!
```

```
Wald test on item level (z-values):
```

	z-statistic	p-value
beta Q1.c1	-1.178	0.239
beta Q1.c2	-0.228	0.820
beta Q1.c3	-0.080	0.937
beta Q2-.c1	2.448	0.014
beta Q2-.c2	2.833	0.005
beta Q2-.c3	2.771	0.006
beta Q4.c1	3.505	0.000
beta Q4.c2	3.671	0.000
beta Q4.c3	3.397	0.001
beta Q5-.c1	-2.441	0.015
beta Q5-.c2	-1.098	0.272
beta Q5-.c3	-0.807	0.420
beta Q7.c1	-3.288	0.001
beta Q7.c2	-1.706	0.088
beta Q7.c3	-1.316	0.188

beta Q8-.c1	4.074	0.000
beta Q8-.c2	3.662	0.000
beta Q8-.c3	3.142	0.002
beta Q9-.c1	1.163	0.245
beta Q9-.c2	1.450	0.147
beta Q9-.c3	1.315	0.189
beta Q10-.c1	-4.453	0.000
beta Q10-.c2	-2.562	0.010
beta Q10-.c3	-2.044	0.041

En ambos casos, los ítems Q3 y Q6 parecen que no se comportan de acuerdo con el modelo, pero emplearemos a continuación los estadísticos basados en las medias de cuadrados de residuales.

5.4 Estadísticos de ajuste de medias de cuadrados

Para obtener los estadísticos de ajuste basados en las medias de cuadrados de residuales se emplea:

```
autoest1 <- person.parameter(m.mev)
itemfit(autoest1)
```

Itemfit Statistics:

	Chisq	df	p-value	Outfit MSQ	Infit MSQ	Outfit t	Infit t	Discrim
Q1	401.005	490	0.999	0.817	0.831	-2.711	-2.814	0.718
Q2-	485.284	490	0.552	0.988	0.805	-0.130	-3.256	0.655
Q3	381.142	490	1.000	0.776	0.792	-3.773	-3.637	0.747
Q4	599.310	490	0.001	1.221	0.923	3.014	-1.238	0.585
Q5-	454.596	490	0.872	0.926	0.915	-1.181	-1.408	0.711
Q6	354.394	490	1.000	0.722	0.696	-4.875	-5.577	0.770
Q7	363.188	490	1.000	0.740	0.714	-4.513	-5.232	0.792
Q8-	731.332	490	0.000	1.489	1.337	6.720	5.036	0.488
Q9-	546.551	490	0.039	1.113	1.013	1.616	0.236	0.643
Q10-	485.386	490	0.550	0.989	1.024	-0.157	0.407	0.741

En este modelo se aplica el mismo criterio que en el modelo de crédito parcial. Un ítem sigue el modelo de escalas de valoración si las medias de cuadrados OUTFIT y/o INFIT se encuentra en el intervalo. Un ítem que obtiene una media de cuadrados, INFIT u OUTFIT, por debajo de 0.6 se puede mantener en la escala. Sin embargo, si el ítem obtiene una media de cuadrados por encima de 1.4, entonces se debe revisar o eliminar si no se encuentra una explicación clara del desajuste. En este caso, una inspección de la tabla anterior determina que el ítem Q8 obtiene una media de cuadrados no ponderada por encima de 1.4, por lo que se podría rechazar y volver a estudiar si el resto de ítems sigue el modelo de crédito parcial.

El ajuste de los patrones de respuesta de las personas al modelo se obtiene con:

```
pfit <- personfit(autoest1)
head(pfit$p.infitMSQ, 5)
```

	P1	P2	P3	P4	P5
	0.4204412	4.4993358	0.4006487	0.7057490	2.3419027

```
head(pfit$p.outfitMSQ, 5)
```

	P1	P2	P3	P4	P5
	0.4085573	10.7538641	0.4184896	0.7143529	2.4223291

La interpretación de las medias de cuadrados OUTFIT e INFIT es similar a las medias de cuadrados de los ítems, aunque en este caso se suele utilizar el intervalo [0.5-1.5] para determinar el ajuste del patrón de respuestas a los ítems. Si el valor de la media de cuadrados OUTFIT y/o INFIT es mayor que 1.5, entonces se debe revisar el patrón de respuestas de esa persona. De nuevo, los patrones de respuesta de las personas P2 y P5 son claramente aberrantes y se deben reexaminar.

5.5 Fiabilidad de la separación

En este modelo también es posible determinar la fiabilidad de la separación de parámetros con:

```
summary(SepRel(autoest1))
```

```
Separation Reliability: 0.8934
```

```
Observed Variance: 2.6038 (Squared Standard Deviation)
```

```
Mean Square Measurement Error: 0.2776 (Model Error Variance)
```

que indica que los parámetros de habilidad están suficientemente separados.

5.6 Cumplimiento de los principios del modelo

5.6.1 Unidimensionalidad

Un análisis de componentes principales de la matriz de residuales se puede obtener con:

```
prcomp(residuals(autoest1), scale=T)
```

```
Standard deviations (1, ..., p=10):
```

```
[1] 1.3484300 1.2516066 1.1449660 1.1313666 1.0095043 0.9590367 0.8838979
[8] 0.8034849 0.7998369 0.1372123
```

```
Rotation (n x k) = (10 x 10):
```

	PC1	PC2	PC3	PC4	PC5	PC6
Q1	-0.27657975	-0.43345208	-0.26583889	-0.21647595	-0.171236456	0.34313348
Q2-	-0.25836721	-0.52585258	-0.01378830	-0.07858764	-0.289062585	-0.08709986
Q3	-0.04575085	0.32629731	0.39143708	-0.30815019	0.132826520	0.69304959
Q4	-0.05804854	-0.35159208	0.30034922	0.25106338	0.726204714	-0.13300560
Q5-	-0.04986524	0.15174031	0.57392357	-0.30142624	-0.345967325	-0.50040014
Q6	-0.33645674	0.39583073	-0.34718392	0.12060651	-0.093830606	-0.08834411
Q7	-0.34882241	0.32464722	-0.32756360	-0.15477589	0.351612580	-0.27050928
Q8-	0.08427121	0.13275879	0.08124856	0.77150531	-0.296746255	0.16374884
Q9-	0.57745678	-0.04918745	-0.14879487	-0.08262778	0.003839156	-0.13424721
Q10-	0.52284083	0.01908502	-0.31582088	-0.23992853	0.043619589	0.02117901
	PC7	PC8	PC9	PC10		
Q1	0.46317102	-0.2641838	-0.3098483206	-0.3011674		
Q2-	-0.49284468	0.3864882	0.2998298775	-0.2775767		
Q3	-0.19939240	0.1500363	0.0117773086	-0.2879060		
Q4	-0.06402302	-0.2562395	-0.0004039057	-0.3239588		
Q5-	0.21169613	-0.1830468	-0.0247310782	-0.3243695		

```

Q6 -0.48759556 -0.4978374 -0.1165584366 -0.2815068
Q7 0.30518283 0.5184700 0.0433398096 -0.2846768
Q8- 0.24744908 0.1685726 0.0913448618 -0.4007343
Q9- -0.22804276 0.2349498 -0.6341248025 -0.3283303
Q10- 0.09891747 -0.2426659 0.6224332987 -0.3324437

```

Si se eleva al cuadrado la desviación típica del primer eigenvalor (1.3484300) tenemos la varianza asociada a este eigenvalor (1.8182635) que no debe ser mayor que 2.0 para aceptar la unidimensionalidad de la escala, como ocurre en este caso.

5.6.2 Independencia local de los ítems

La independencia local se puede probar a través del examen de las correlaciones a partir de los residuales una vez ajustado el modelo de escalas de valoración. En este caso se emplea:

```
cor(residuals(autoest1))
```

```

          Q1          Q2-          Q3          Q4          Q5-          Q6
Q1  1.00000000  0.23440809 -0.15248194 -0.05256315 -0.17743312 -0.09033742
Q2-  0.23440809  1.00000000 -0.20004928  0.04527286 -0.06985549 -0.09650171
Q3  -0.15248194 -0.20004928  1.00000000 -0.11936327  0.08017301 -0.03604171
Q4  -0.05256315  0.04527286 -0.11936327  1.00000000 -0.12235007 -0.23058775
Q5- -0.17743312 -0.06985549  0.08017301 -0.12235007  1.00000000 -0.12766028
Q6  -0.09033742 -0.09650171 -0.03604171 -0.23058775 -0.12766028  1.00000000
Q7  -0.01967544 -0.14232416 -0.03236915 -0.12670111 -0.08715105  0.24363940
Q8- -0.22619272 -0.18733028 -0.15691050 -0.07958297 -0.16134896 -0.02517277
Q9- -0.22032192 -0.18362141 -0.14671274 -0.12502740 -0.13713075 -0.25787643
Q10- -0.14458859 -0.22355216 -0.11418602 -0.20039825 -0.17582443 -0.21155186
          Q7          Q8-          Q9-          Q10-
Q1  -0.01967544 -0.22619272 -0.22032192 -0.1445886
Q2- -0.14232416 -0.18733028 -0.18362141 -0.2235522
Q3  -0.03236915 -0.15691050 -0.14671274 -0.1141860
Q4  -0.12670111 -0.07958297 -0.12502740 -0.2003983
Q5- -0.08715105 -0.16134896 -0.13713075 -0.1758244
Q6  0.24363940 -0.02517277 -0.25787643 -0.2115519
Q7  1.00000000 -0.20063522 -0.26777911 -0.1669937
Q8- -0.20063522  1.00000000 -0.09366863 -0.1648962
Q9- -0.26777911 -0.09366863  1.00000000  0.3271501
Q10- -0.16699371 -0.16489622  0.32715011  1.0000000

```

De nuevo, en este modelo algunas correlaciones entre los residuales han resultado por encima de 0.20, por lo que hace sospechar de que las respuestas a los ítems no son totalmente independientes.