

ΜΙΑ ΜΙΚΡΗ ΕΙΣΑΓΩΓΗ ΣΤΟ R

Βασίλειος Γιαγός
sas00012@sas.aegean.gr

Τμήμα Στατιστικής και Αναλογιστικής Επιστήμης
Πανεπιστήμιο Αιγαίου
Φεβρουάριος 2003, Καρλόβασι Σάμος

Περιεχόμενα

1 Εισαγωγή	3
1.1 Τι είναι το R	3
1.2 Αποκτώντας το R	3
1.3 Βασικές Έννοιες	3
2 Το περιβάλλον του R	5
2.1 Βασικές εντολές	5
2.2 Αποθήκευση και επανάκτηση αντικειμένων	7
2.3 Πακέτα	8
2.3.1 Το πακέτο foreign	9
2.3.2 Το πακέτο ctest	10
2.4 Κατανομές	10
2.5 Γραφήματα στο R	11
2.5.1 Η εντολή Plot	13
3 Έλεγχοι	15
3.1 Γενικά για τους έλεγχους - tests	15
3.2 Ένα παράδειγμα απλών ελέγχων	15
4 Γραμμικά μοντέλα	18
4.1 Ορισμός ενός γραμμικού μοντέλου	18
4.2 Συναρτήσεις για πιο λεπτομερειακές αναλύσεις	19
Βιβλιογραφία	22

Κεφάλαιο 1

Εισαγωγή

1.1 Τι είναι το R

Το R είναι μια γλώσσα προγραμματισμού συνοδευόμενη από ένα περιβάλλον για επεξεργασία δεδομένων, υπολογισμών και γραφημάτων. Αν και χρησιμοποιείται κυρίως στην στατιστική οι δημιουργοί του προτιμούν να το αποκαλούν εργαλείο για ανάλυση δεδομένων τονίζοντας ότι περιλαμβάνει και μοντέρνες και παλιές στατιστικές μεθοδολογίες.

Είναι ένα GNU¹ πρόγραμμα παρόμοιο με τη γλώσσα και το περιβάλλον S που αναπτύχθηκε στα εργαστήρια της Bell (στο παρελθόν AT&T, τώρα Lucent Technologies) από τον John Chambers και τους συνεργάτες του. Το R μπορεί να ψεωρηθεί ως μια διαφορετική υλοποίηση του S. Υπάρχουν μερικές σημαντικές διαφορές, αλλά ο περισσότερος κώδικας που γράφεται για το S τρέχει αμετάβλητος και στο R (όμως το R και το S δεν είναι 100% συμβατά). Μοιραία το R συγκρίνεται με το S+ ή S-plus το εμπορικό πακέτο βασισμένο και αυτό στην γλώσσα S. Η κύρια και η πιο αξιοσημείωτη διαφορά είναι ότι το R δεν έχει γραφικό περιβάλλον εργασίας και απαιτεί αρκετή ενασχόληση για να γίνει οικείο σε κάποιον.

1.2 Αποκτώντας το R

Το R μπορεί κάποιος να το αποκτήσει δωρεάν στην ιστοσελίδα του: <http://www.r-project.org> ή σε ένα από τα πολλά mirrors του CRAN (Comprehensive R Archive) <http://cran.r-project.org> το οποίο είναι ένα δίκτυο διανομής του R σε πολλά μέρη του κόσμου μέσω του Internet. Υποστηρίζει πολλές πλατφόρμες και λειτουργικά όπως Linux, Windows και πληθώρα Unix λειτουργικών.

1.3 Βασικές Έννοιες

Ο σκοπός ενός στατιστικού προγράμματος είναι να επεξεργάζεται και να χειρίζεται δεδομένα. Το R χειρίζεται τα δεδομένα (π.χ. πίνακες, διανύσματα...) και τις δομές (π.χ. συναρτήσεις) σαν αντικείμενα (objects). Τα αντικείμενα ανάλογα με την δομή τους κατηγοριοποιούνται αυτόματα σε:

¹"GNU's Not Unix!" Το project GNU άρχισε το 1984 με σκοπό τη δημιουργία ενός ολοκληρωμένου λειτουργικού συστήματος τύπου Unix το οποίο θα είναι δωρεάν και ανοιχτό (ως προς τον πηγαίο κώδικα) λογισμικό. Το R-project αναπτύσσεται κάτω από την αιγίδα του GNU.

Διάνυσμα *vectors* Ένα τυπικό διάνυσμα ή μονοδιάστατος πίνακας. Παίρνει αριθμητικές τιμές.

Πίνακας *matrix* Πολυδιάστατοι πίνακες.

Παράγοντες *factors* Χρησιμοποιούνται για τον χειρισμό κατηγορικών μεταβλητών.

Λίστες *lists* Μια γενική μορφή διανύσματος που τα στοιχεία του δεν είναι απαραίτητα του ίδιου τύπου και μπορούν να εμπεριέχουν άλλα διανύσματα ή λίστες.

Πίνακες δεδομένων *data frames* Είναι δομημένοι όπως οι απλοί πίνακες αλλά σε κάθε γραμμή αντιστοιχεί μία παρατηρούμενη μονάδα. Οι γραμμές μπορούν να είναι διαφορετικών τύπων καθώς περιέχουν και κατηγορικές και ποσοτικές μεταβλητές.

Συναρτήσεις *functions* Θεωρούνται και αυτές αντικείμενα.

Τα αντικείμενα δημιουργούνται και αποθηκεύονται με βάση το όνομά τους. Επίσης το R λαμβάνει τον κάθε χαρακτήρα μοναδικά (*case sensitive*). Δηλαδή **δεν** είναι το ίδιο γράψουμε **A** και **a** όπως επίσης **OBJECT** **OBJEct** **object**.

Κεφάλαιο 2

Το περιβάλλον του R

2.1 Βασικές εντολές

Αρχίζοντας το R βλέπουμε μια γραμμή εκχώρησης εντολών:

>

Για να λάβουμε την αρχική βοήθεια:

```
> help.start()  
updating HTML package listing  
If nothing happens, you should open...
```

Αυτό έχει σαν αποτέλεσμα να δημιουργήσει ένα περιβάλλον βοήθειας που θα εκκινήσει τον τυπικό browser του συστήματος.

Σε οποιαδήποτε στιγμή ζητάμε βοήθεια με την εντολή:

```
> help("foo")  
'Οπου foo είναι αυτό που ζητάμε, ή ισοδύναμα:
```

> ?foo

Για να εκχωρήσουμε μία τιμή σε ένα αντικείμενο π.χ. στο zz την τιμή 6:

> zz <- 6

Είναι σημαντικό να διευκρινίσουμε ότι η εντολή εκχώρησης διαγράφει την προηγούμενη τιμή του αντικειμένου. Για παράδειγμα:

```
> zz <- 6  
> zz <- 2
```

Τώρα πλέον το zz έχει την τιμή 2 και όχι 6.

Αν θέλουμε να εκχωρήσουμε ένα διάνυσμα:

```
> zz <- c(10.4, 5.6, 3.1, 6.4, 21.7)
```

Όπου εκχωρούμε τις τιμές του πίνακα χρησιμοποιώντας μία συνάρτηση `c()` η οποία παίρνει ως όρισμα τα στοιχεία του διανύσματος, κατασκευάζει ένα διάνυσμα και με την εντολή `<-` το εκχωρεί στο αντικείμενο `zz`. Μια πιο πολύπλοκη διαδικασία:

```
> zz <- c(10.4, 5.6, 3.1, 6.4, 21.7)
> y <- c(zz,0,zz)
```

Τώρα δημιουργήσαμε ένα νέο διάνυσμα 11 στοιχείων¹ αντιγράφοντας το `zz` προσθέτοντας έκτο το 0 και αντιγράφοντας ξανά το `zz`. Ένας άλλος τρόπος για να τα καταχωρήσουμε είναι με την εντολή `scan`:

```
> zz <- scan()
1: 10.4 5.6 3.1 6.4 21.7
6:
Read 5 items
```

Η οποία απλά παίρνει τις τιμές από το πληκτρολόγιο ή από ένα αρχείο αν το ορίσουμε, ή αν το δούμε στην αποθήκευση δεδομένων, τερματίζεται με μια κενή γραμμή. Για να δούμε τις τιμές του `y` δίνουμε την εντολή:

```
> print(y)
[1] 10.4 5.6 3.1 6.4 21.7 0.0 10.4 5.6 3.1 6.4 21.7
```

Η `print` εμφανίζει στην οθόνη τα περιεχόμενα του αντικειμένου `π.χ.y`. Το σύμβολο `[1]` μας υπενθυμίζει ότι έπειτα από την πρώτη στοιχείο του διανύσματος.

Μία άλλη πολύ χρήσιμη εντολή είναι η `summary`. Δημιουργεί μια "περίληψη" του αντικειμένου που παίρνει ως όρισμα και το είδος της περίληψης εξαρτάται από την κλάση του αντικειμένου (αν είναι π.χ. διάνυσμα, πίνακας, αλφαριθμητικό, κ.τ.λ.).

```
> summary(y)
   Min. 1st Qu. Median      Mean 3rd Qu.      Max.
0.000  4.350  6.400  8.582 10.400 21.700
```

Συγκεκριμένα για την μεταβλητή `y` και για κάθε ποσοτική, τα σύμβολα των αποτελεσμάτων σημαίνουν:²

Min.	ελάχιστο
1st Qu.	πρώτο τεταρτημόριο
Median	διάμεσος
3rd Qu.	τρίτο τεταρτημόριο
Max.	μέγιστο
NA's	ελλειπούσες τιμές

Υπολογίζουμε τις συσχετίσεις ανάμεσα σε δεδομένα με την ίδια λογική της `summary` χρησιμοποιώντας την εντολή `cor` από το `correlation` (συσχέτιση):

¹5 του `zz`, 0, ξανά 5 του `zz`

²Στο συγκεκριμένο παράδειγμα δεν υπάρχουν ελλειπούσες τιμές και δεν απεικονίζονται.

```

> cor(zz, use = "pairwise.complete.obs")
      MPG      ENGINE      HORSE      WEIGHT      ACCEL      YEAR
MPG      1.0000000 -0.7886070 -0.7712932 -0.8070043  0.4343043  0.4658041
ENGINE   -0.7886070  1.0000000  0.8970699  0.9333334 -0.5446237 -0.2022022
HORSE    -0.7712932  0.8970699  1.0000000  0.8594179 -0.7014089 -0.2827388
WEIGHT   -0.8070043  0.9333334  0.8594179  1.0000000 -0.4152115 -0.1233154
ACCEL    0.4343043 -0.5446237 -0.7014089 -0.4152115  1.0000000  0.3024866
YEAR     0.4658041 -0.2022022 -0.2827388 -0.1233154  0.3024866  1.0000000
ORIGIN   NA        NA        NA        NA        NA        NA
CYLINDER NA        NA        NA        NA        NA        NA
FILTER.. NA        NA        NA        NA        NA        NA
               ORIGIN CYLINDER FILTER..
MPG       NA        NA        NA
ENGINE   NA        NA        NA
HORSE    NA        NA        NA
WEIGHT   NA        NA        NA
ACCEL    NA        NA        NA
YEAR     NA        NA        NA
ORIGIN   NA        NA        NA
CYLINDER NA        NA        NA
FILTER.. NA        NA        NA
Warning message:
NAs introduced by coercion

```

Σχόλια: Όσες τιμές έχουν NA είναι διότι έχουμε συμπεριλάβει και τις ποιοτικές μεταβλητές των δεδομένων. Παρατηρούμε επίσης ότι στην διαγώνιο των αποτελεσμάτων έχουμε τον αριθμό 1 μια και συγχρίνονται με τον εαυτό τους. Οι μεταβλητές που χρησιμοποιούμε έχουν αγνοούμενες τιμές και ο υπολογισμός των συσχετίσεων ύα τερματίζοταν με την πρώτη άγνωστη τιμή (missing value - NA) • ξεπερνάμε αυτό το πρόβλημα δίνοντας το όρισμα use = "pairwise.complete.obs" για να υπολογισθεί η συσχέτιση χρησιμοποιώντας μόνο τα ζευγάρια τιμών, από κάθε μεταβλητή, που δεν έχουν άγνωστες τιμές και αγνοεί ολόκληρο το ζευγάρι τιμών αν βρεθεί έστω και μία από το καθένα.

Μπορούμε να εκτελούμε και αριθμητικές διαδικασίες με την βοήθεια τελεστών όπως της γλώσσας προγραμματισμού c :

```

> x <- 2
> x <- x*x
> print(x)
[1] 4

```

Οι τελεστές είναι: + - * / για πρόσθεση, αφαίρεση, πολλαπλασιασμό και διαίρεση αντίστοιχα.

2.2 Αποθήκευση και επανάκτηση αντικειμένων

Το R παρέχει την δυνατότητα αποθήκευσης των αντικειμένων τα οποία αποθηκεύονται είτε σε ένα προκαθορισμένο πρότυπο που χρησιμοποιεί το R είτε σε ένα απλό αρχείο κειμένου. Η πλέον εύκολη αποθήκευση αντικειμένων γίνεται με την εντολή:

```
> save(zz, file="zz.Rdata")
```

Όπου το zz είναι το όνομα του αντικειμένου και στο "zz.Rdata" το όνομα του αρχείου που θα αποθηκευθεί. Για να μπορούμε να χρησιμοποιήσουμε το αποθηκευμένο αντικείμενο και σε άλλα στατιστικά πακέτα προσθέτουμε άλλη μια παράμετρο:

```
> save(zz, file="zz.Rdata", ascii = TRUE)
```

Που σημαίνει ότι θα το αποθηκεύσει ως ένα απλό αρχείο κειμένου.

Για να "φορτώσουμε", επανακτήσουμε, το προηγούμενο αντικείμενο δίνουμε:

```
> load("zz.Rdata")
```

Για επιπλέον πληροφορίες μπορεί κάποιος να ανατρέξει στο εγχειρίδιο R Data Import/Export που το συμπεριλαμβάνει κάθε διανομή του R .

2.3 Πακέτα

To R αποτελείται από πακέτα που περιέχουν ρουτίνες για στατιστικούς ελέγχους, δεδομένα (data sets), βιβλιοθήκες για εισαγωγή - εξαγωγή δεδομένων, εξειδικευμένες στατιστικές μεθόδους και γενικά επεκτείνουν τις δυνατότητες του R . Στην βασική του διανομή περιέχει 8 βασικά πακέτα. Μπορούμε να προσθέσουμε και άλλα χρησιμοποιώντας το CRAN . Για να δημιουργηθεί μια λίστα με μια μικρή περιγραφή των πακέτων που είναι εγκατεστημένα δίνουμε:

Παράδειγμα

```
>library()  
Packages in library '/rw1061/library':
```

base	The R base package
boot	Bootstrap R (S-Plus) Functions (Canty)
class	Functions for classification
cluster	Functions for clustering (by Rousseeuw et al.)
ctest	Classical Tests
.	
.	
.	
ts	Time series functions

Για να ενεργοποιήσουμε ένα πακέτο δίνουμε:

```
>library(foo)
```

'Όπου foo είναι το όνομα του πακέτου που θέλουμε πχ >library(ctest) για το ctest πακέτο. Για να εγκαταστήσουμε ένα πακέτο αρχεί από το γραφικό περιβάλλον να δώσουμε: Packages - Install packages from και αναλόγως αν έχουμε το πακέτο στον τοπικό μας δίσκο ή θα το κατεβάσουμε μέσω διαδικτύου δίνουμε local zip file ή CRAN αντίστοιχα. Είναι δινατόν να το εγκαταστήσουμε και από την γραμμή εντολών του λειτουργικού μας δίνοντας την εντολή:

R CMD INSTALL name

'Όπου name το όνομα του πακέτου.

2.3.1 Το πακέτο foreign

Στο R υπάρχει η δυνατότητα να εισάγει κανείς δεδομένα από άλλα στατιστικά πακέτα χρησιμοποιώντας το πακέτο foreign . Τα στατιστικά πακέτα που υποστηρίζονται είναι:

Spss	με την εντολή read.spss
S3	με τις εντολές data.restore, read.S, SModeNames
Stata	με την εντολή read.dta
SAS	με τις εντολές lookup.xport,read.xport,read.ssd
Epi Info	με την εντολή read.epiinfo

Παράδειγμα Εισάγουμε δεδομένα από το Spss . Συγκεκριμένα από το αρχείο Cars.sav το οποίο περιέχει στοιχεία για αυτοκίνητα. Έχουμε:

```
> zz <- read.spss("/Program files/spss/Cars.sav", to.data.frame = TRUE)
> summary(zz)
```

MPG	ENGINE	HORSE	WEIGHT	ACCEL	YEAR
Min. : 9.00	Min. : 4.0	Min. : 46.00	Min. : 732	Min. : 8.00	Min. : 0.00
1st Qu.:17.50	1st Qu.:104.3	1st Qu.: 75.75	1st Qu.:2224	1st Qu.:13.63	1st Qu.:73.00
Median :23.00	Median :148.5	Median : 95.00	Median :2811	Median :15.50	Median :76.00
Mean :23.51	Mean :194.0	Mean :104.83	Mean :2970	Mean :15.50	Mean :75.75
3rd Qu.:29.00	3rd Qu.:293.3	3rd Qu.:129.25	3rd Qu.:3612	3rd Qu.:17.07	3rd Qu.:79.00
Max. :46.60	Max. :455.0	Max. :230.00	Max. :5140	Max. :24.80	Max. :82.00
NA's : 8.00		NA's : 6.00			

ORIGIN	CYLINDER	FILTER..
Japanese: 79	8 Cylinders:107	Selected :291
European: 73	6 Cylinders: 84	Not Selected:107
American:253	5 Cylinders: 3	NA's : 8
NA's : 1	4 Cylinders:207	
	3 Cylinders: 4	
	NA's : 1	

Εδώ το zz είναι (ως προς την υλάση) ένας πίνακας δεδομένων data frame που περιέχει πολλές μεταβλητές. Όπως έχουμε αναφέρει στην summary (σελίδα 6) η "περίληψη" αυτή προσαρμόζεται ανάλογα με το είδος (υλάση) του αντικειμένου. Τα δεδομένα του αρχείου Cars.sav έχουν χρησιμοποιηθεί από το βασικό πακέτο του Spss και περιέχουν τις εξής μεταβλητές (με * είναι ποιοτικές):

MPG	Αριθμός μιλίων με ένα γαλόνι βενζίνης
ENGINE	Κυβικές ίντσες μηχανής
HORSE	Ιπποδύναμη
WEIGHT	Βάρος σε λίβρες
ACCEL	Επιτάχυνση από 0 σε 60 μίλια ανά ώρα
YEAR	Το πηλίκο της χρονιάς του μοντέλου δια 100
ORIGIN*	Χώρα προέλευσης
CYLINDER*	Αριθμός κυλίνδρων
FILTER*	Καταλυτικό (ναι ή όχι)

2.3.2 Το πακέτο `ctest`

Είναι μια συλλογή από κλασσικούς ελέγχους (τεστ) όπως:

<code>binom.test</code>	Ακριβείς διωνυμικός έλεγχος
<code>chisq.test</code>	Chi-squared έλεγχος του Pearson για μετρήσιμα δεδομένα
<code>cor.test</code>	Έλεγχος μηδενικής συσχέτισης
<code>friedman.test</code>	Friedman Rank Sum Test
<code>kruskal.test</code>	Kruskal-Wallis Rank Sum Test
<code>ks.test</code>	Kolmogorov-Smirnov Tests
<code>mantelhaen.test</code>	Cochran-Mantel-Haenszel Chi-Squared Test for Count Data
<code>mcnemar.test</code>	McNemar's Chi-squared Test for Count Data
<code>oneway.test</code>	Test for Equal Means in a One-Way Layout
<code>pairwise.prop.test</code>	Pairwise comparisons of proportions
<code>pairwise.t.test</code>	Pairwise t tests
<code>pairwise.table</code>	Tabulate p values for pairwise comparisons
<code>pairwise.wilcox.test</code>	Pairwise Wilcoxon rank sum tests
<code>power.prop.test</code>	Power calculations two sample test for proportions
<code>power.t.test</code>	Power calculations for one and two sample t tests
<code>prop.trend.test</code>	Test for trend in proportions
<code>t.test</code>	Student's t-Test
<code>var.test</code>	F Test για να συγχριθούν οι διασπορές
<code>wilcox.test</code>	Wilcoxon Rank Sum and Signed Rank Tests

2.4 Κατανομές

Στο R μας δίνεται η δυνατότητα να χρησιμοποιήσουμε μία πληθώρα κατανομών:

Κατανομή	R εντολή	πρόσθετα ορίσματα
<code>beta</code>	<code>beta</code>	<code>shape1, shape2, ncp</code>
<code>binomial</code>	<code>binom</code>	<code>size, prob</code>
<code>Cauchy</code>	<code>cauchy</code>	<code>location, scale</code>
<code>chi-squared</code>	<code>chisq</code>	<code>df, ncp</code>
<code>exponential</code>	<code>exp</code>	<code>rate</code>
<code>F</code>	<code>f</code>	<code>df1, df2, ncp</code>
<code>gamma</code>	<code>gamma</code>	<code>shape, scale</code>
<code>geometric</code>	<code>geom</code>	<code>prob</code>
<code>hypergeometric</code>	<code>hyper</code>	<code>m, n, k</code>
<code>log-normal</code>	<code>lnorm</code>	<code>meanlog, sdlog</code>
<code>logistic</code>	<code>logis</code>	<code>location, scale</code>
<code>negative</code>	<code>binomial</code>	<code>nbinom size, prob</code>
<code>normal</code>	<code>norm</code>	<code>mean, sd</code>
<code>Poisson</code>	<code>pois</code>	<code>lambda</code>
<code>Student's t</code>	<code>t</code>	<code>df, ncp</code>
<code>uniform</code>	<code>unif</code>	<code>min, max</code>
<code>Weibull</code>	<code>weibull</code>	<code>shape, scale</code>
<code>Wilcoxon</code>	<code>wilcox</code>	<code>m, n</code>

Βάζοντας ένα πρόθεμα μπροστά από κάθε όνομα κατανομής μπορούμε να υπολογίσουμε αντίστοιχα:

- d για την συνάρτηση πυκνότητας πιθανότητας
- p για την συνάρτηση κατανομής πιθανότητας
- q για το ελάχιστο x ώστε δοθέντος ενός εκατοστημόριου (q) να υπολογίζει την $P((X \leq x) > q)$
- r για την δημιουργία τυχαίων δεδομένων από κανονική κατανομή.

Μερικά παραδείγματα:

- Για να βρούμε την πιθανότητα 3 επιτυχιών σε 4 δοκιμές με πιθανότητα 0.5 στην διωνυμική:

```
> dbinom(3,4,0.5)
[1] 0.25
```

- Τώρα έχουμε $P(X > 2.45)$, $X \sim t$ με 5 β.ε.

```
> pt(2.45, df=5, lower.tail= FALSE)
[1] 0.0289682
```

Αν το lower.tail ήταν TRUE τότε θα υπολόγιζε: $P(X \leq 2.45)$

- Έστω ότι θέλουμε να υπολογίσουμε το 1% πάνω άκρο μιας $F(2, 7)$ κατανομής.

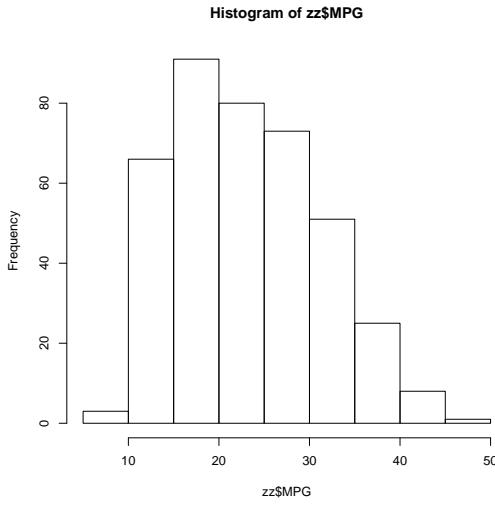
```
> qf(0.99,2,7)
[1] 9.546578
```

2.5 Γραφήματα στο R

Για τις ανάγκες των γραφημάτων θα χρησιμοποιήσουμε τα δεδομένα Cars.sav όπως τα περιγράψαμε παραπάνω.

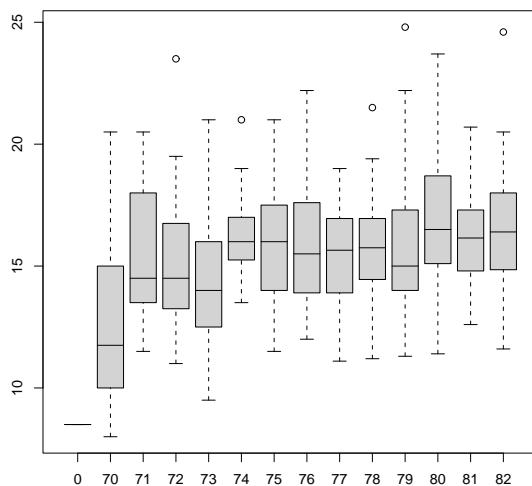
Ιστογράμματα Τα ιστογράμματα κατασκευάζονται με την εντολή:

```
> hist(zz$MPG)
```



Θηκογράμματα Τα θηκογράμματα ή διαγράμματα πλαισίων είναι ένας πολύ καλός τρόπος να αναπαραστήσουμε, διαγραμματικά, τα περιγραφικά μεγέθη ενός δείγματος ή πληθυσμού. Χρησιμεύουν επίσης στην γρήγορη σύγχριση ομάδων δεδομένων. Τα θηκογράμματα παίρνουν ορίσματα όπως τα ιστογράμματα μόνο που επιτρέπεται η προσθήκη και άλλων μεταβλητών:

```
> boxplot(ACCEL ~ YEAR, data = zz, col = "lightgray")
```

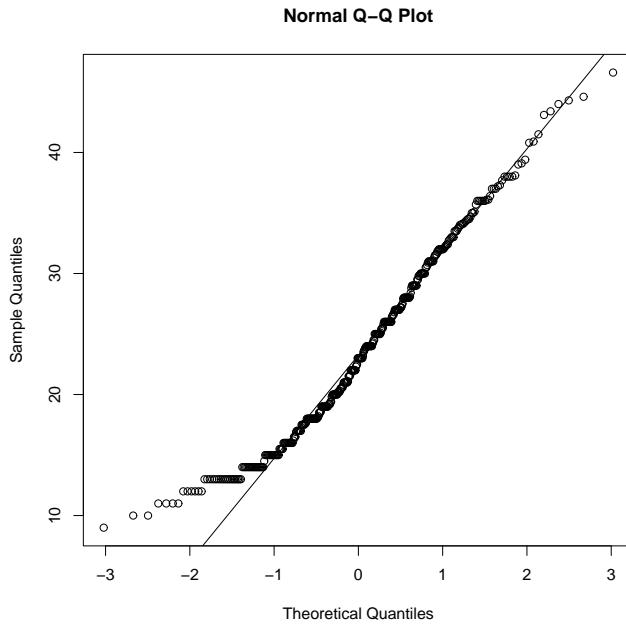


Σχήμα 2.1: Εδώ έχουμε ένα θηκόγραμμα με την επιτάχυνση των αυτοκινήτων ανά έτος κατασκευής τους, χρωματίζοντας και τα πλαίσια.

Πιθανοθεωρητικά διαγράμματα κανονικής κατανομής (normal plots): Τα διαγράμματα απευθύνονται σε ένα δείγμα και χρησιμεύουν στο να προσδιορίσουμε πόσο κοντά στην κανονική κατανομή είναι οι παρατηρούμενες τιμές σε σχέση με αυτές της κανονικής κατανομής. Υπάρχουν δύο ειδών: τα p-p και τα q-q normal plots. Η διαφορά τους είναι στο ότι τα p-p συγκρίνουν

την αθροιστική συχνότητα με την υποτιθέμενη κανονική κατανομή ενώ τα q-q τα εκατοστημόρια τη της παρατηρούμενης τιμής ως προς την αναμενόμενη κανονική κατανομή. Η εντολή `qqnorm` σχεδιάζει το αντικείμενο που έχει ως όρισμα και η `qqline` απλά προσθέτει την γραμμή που αναπαριστά την κανονική κατανομή.

```
> qqnorm(zz$MPG) ; qqline(zz$MPG)
```



Σχήμα 2.2: Πιθανοθεωρητικό διάγραμμα q-q plot του MPG

2.5.1 Η εντολή Plot

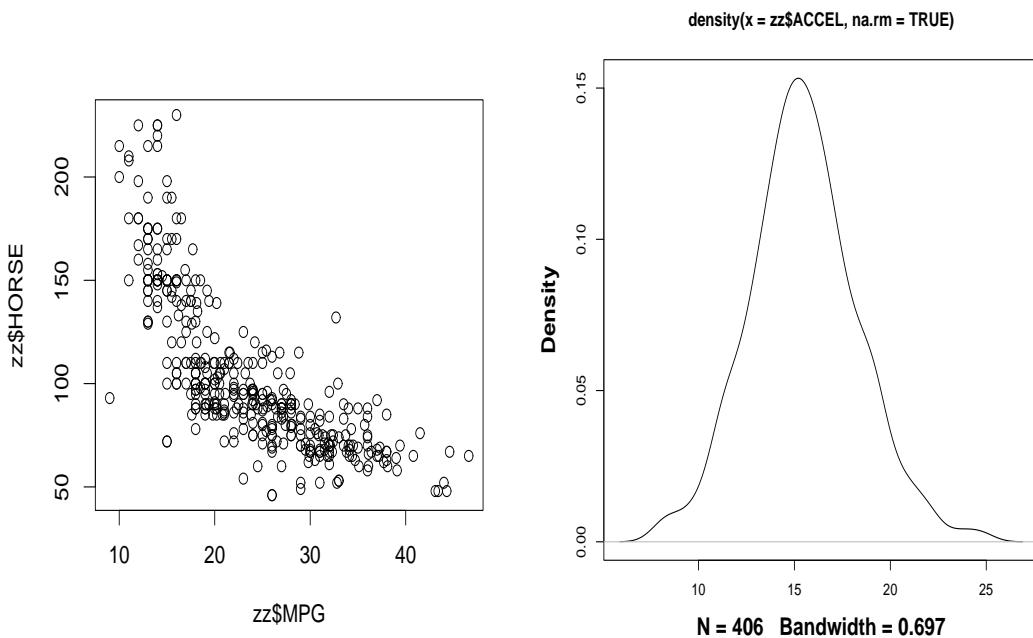
Η πιο διαδεδομένη συνάρτηση στα γραφήματα είναι η plot που είναι μια γενική συνάρτηση. Ο τύπος του γραφήματος εξαρτάται από τον τύπο ή την κατηγορία του πρώτου αντικειμένου που μπαίνει ως όρισμα. Για να κάνουμε ένα scatterplot με δύο μεταβλητές αρκεί να δώσουμε δύο ορίσματα (σχήμα 2.3):

```
> plot(zz$MPG,zz$HORSE)
```

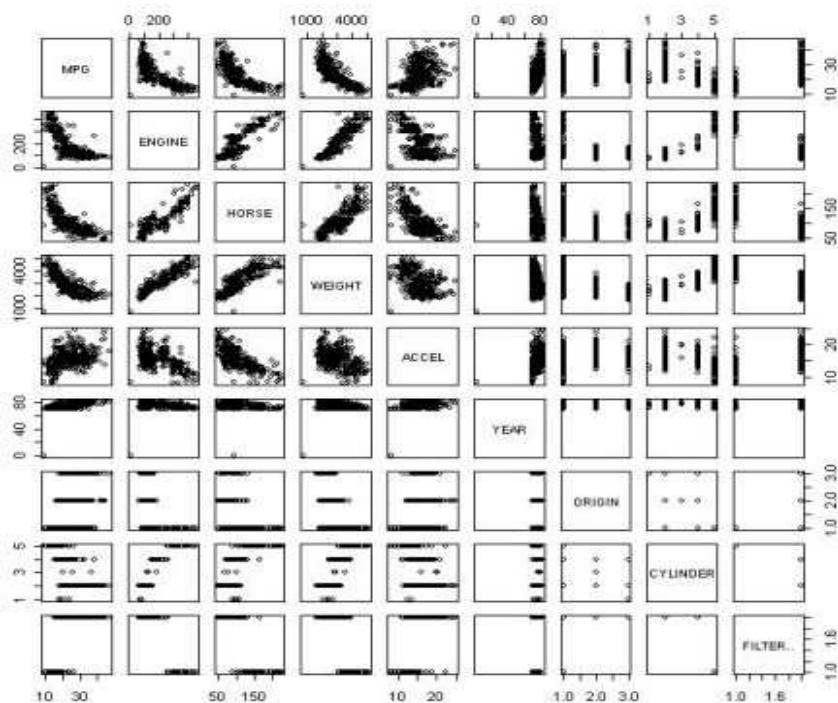
Για ένα πιο εντυπωσιακό γράφημα μπορούμε να δώσουμε το αντικείμενο χωρίς όρισμα και αυτόματα να δημιουργήσει ένα πίνακα με scatterplots (π.χ. `> plot(zz)` σχήμα 2.4). Μία άλλη επιλογή είναι να χρησιμοποιήσουμε το plot σε συνδυασμό με μια άλλη συνάρτηση όπως μια εκτίμηση του ιστογράμματος `kernell` (kernell density estimate):

```
>plot(density(zz$ACCEL,na.rm=TRUE))
```

Παρατηρούμε ότι η γραφική παράσταση είναι ένα είδος "λειασμένου" ιστογράμματος (smoothing).



Σχήμα 2.3: Το πρώτο σχήμα είναι το scatterplot των zz\$MPG και zz\$HORSE ενώ το δεύτερο είναι η kernel density estimate .



Σχήμα 2.4: Εδώ απεικονίζεται ο πίνακας των scatterplots όλων των μεταβλητών, ποσοτικών και ποιοτικών για τα δεδομένα του αρχείου Cars.sav .

Κεφάλαιο 3

Έλεγχοι

3.1 Γενικά για τους έλεγχους - tests

Μία πολύ συνηθισμένη λειτουργία των στατιστικών πακέτων είναι να συγχρίνουν διάφορα μεγέθη δειγμάτων όπως η μέση τιμή και η διασπορά. Όλοι οι “κλασσικοί” έλεγχοι (τεστ) εμπεριέχονται στο πακέτο **ctest** το οποίο πρέπει να ενεργοποιηθεί πριν το χρησιμοποιήσουμε. Το πακέτο όπως περιγράψαμε περιέχει πλήθος ελέγχων, που δεν είναι δυνατή ολόκληρη η παρουσίασή τους, άλλα μια μικρή επίδειξη του.

3.2 Ένα παράδειγμα απλών ελέγχων

Τα δεδομένα, που τα χρησιμοποιούμε σε όσους έλεγχους θα παρουσιάσουμε, αναφέρονται στην λανθάνουσα θερμότητα της τήξης του πάγου¹. Τα καταχωρούμε στα αντίστοιχα αντικείμενα A,B:

```
A <- scan()  
79.98 80.04 80.02 80.04 80.03 80.03 80.04 79.97  
80.05 80.03 80.02 80.00 80.02
```

```
B <- scan()  
80.02 79.94 79.98 79.97 79.97 80.03 79.95 79.97
```

Ελέγχουμε την ισότητα των μέσων τιμών των δύο δειγμάτων χρησιμοποιώντας ένα μη-ζευγαρωτό t -έλεγχο (unpaired t-test) . Έστω οι υποθέσεις:

$$H_0 : \mu_A = \mu_B \Rightarrow \mu_A - \mu_B = 0$$

$$H_1 : \mu_A \neq \mu_B \Rightarrow \mu_A - \mu_B \neq 0$$

Στο R έχουμε:

```
> library(ctest)  
> t.test(A, B)
```

Welch Two Sample t-test

¹ Από το ”‘An introduction to R”’ σελ. 38

```

data: A and B
t = 3.2499, df = 12.027, p-value = 0.00694
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
0.01385526 0.07018320
sample estimates:
mean of x mean of y
80.02077 79.97875

```

Ο έλεγχος μας παρουσιάζει μια σημαντική διαφορά ($p - value = 0.00694 < 0.05$), υποθέτοντας κανονικότητα. Είναι προκαθορισμένο στο R να μην δέχεται ως υπόθεση την ισότητα των διασπορών στα δύο δείγματα (σε αντίθεση με το S-plus). Μπορούμε να χρησιμοποιήσουμε ένα F-έλεγχο (F-test) για να εξετάσουμε την ισότητα των διασπορών με την βοήθεια των λόγων διασπορών, προύπονθέτοντας ότι τα δύο δείγματα προέρχονται από κανονικούς πληθυσμούς, δηλαδή:

$$H_0 : \sigma_a^2 = \sigma_b^2 \Rightarrow \frac{\widehat{S}_a^2}{\widehat{S}_b^2} = 1$$

$$H_1 : \sigma_a^2 \neq \sigma_b^2 \Rightarrow \frac{\widehat{S}_a^2}{\widehat{S}_b^2} \neq 1$$

```

> var.test(A, B)

F test to compare two variances

```

```

data: A and B
F = 0.5837, num df = 12, denom df = 7, p-value = 0.3938
alternative hypothesis: true ratio of variances is not equal to 1
95 percent confidence interval:
0.1251097 2.1052687
sample estimates:
ratio of variances
0.5837405

```

Ο οποίος μας δείχνει ανυπαρξία σημαντικής διαφοράς ($p - value = 0.3938 > 0.05$), οπότε μπορούμε να χρησιμοποιήσουμε τον κλασικό t-έλεγχο που προύπονθέτει ισότητα διασπορών.

```

> t.test(A, B, var.equal=TRUE)
Two Sample t-test data: A and B
t = 3.4722, df = 19, p-value = 0.002551
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
0.01669058 0.06734788
sample estimates:
mean of x mean of y
80.02077 79.97875

```

Αυτή τη φορά μας παρουσιάζει μια ακόμα πιο σημαντική διαφορά ($p - value = 0.002551 < 0.00694 < 0.05$) σε σχέση με τον προηγούμενο έλεγχο.

Κάθε έλεγχος του πακέτου ctest (2.3.2 σελ. 10) έχει τα δικά του ορίσματα και μπορούμε να πάρουμε περισσότερες πληροφορίες δίνοντας: `help(, package ="ctest")` ή προσθέτωντας το όνομα του ελέγχου π.χ.: `help(t.test , package ="ctest")`

Κεφάλαιο 4

Γραμμικά μοντέλα

Το R χειρίζεται, όπως έχουμε αναφέρει, τα μοντέλα ως **αντικείμενα**. Τα μοντέλα μοιάζουν με τις συναρτήσεις. Η κύρια διαφορά είναι ότι αποτελούνται αριθμητικές μεταβλητές, παράγοντες και φυσικά εξαρτημένες μεταβλητές που συγχρίνονται αργότερα με παρατηρούμενες αριθμητικές τιμές.

4.1 Ορισμός ενός γραμμικού μοντέλου

Για να ορίσουμε ένα μοντέλο, γενικά, ορίζουμε την εξαρτημένη μεταβλητή ακολουθεί το σύμβολο “~” και τέλος οι παράγοντες:

$$y \sim x$$

Εδώ ορίσαμε την y ως εξαρτημένη και την x ως παράγοντα - ανεξάρτητη. Προσθέτοντας τελεστές μπορούμε να ορίσουμε τις σχέσεις των παραγόντων:

$$y \sim x + z^2 - 5$$

Όπου το $y \sim x + z^2 - 5$ μας δηλώνει: $y = x + y^2 - 5$. Για να προσαρμόσουμε ένα γραμμικό μοντέλο δίνουμε το όρισμα:

$$object <- lm(formula, data = data.frame)$$

Όπου *object* είναι το αντικείμενο που θα περιέχει το μοντέλο, *formula* ο τύπος του μοντέλου και *data.frame* τα δεδομένα αν περιέχονται σε ένα μόνο αντικείμενο, για παράδειγμα:

```
> fm <- lm(MPG ~ ENGINE + HORSE , data = zz)
```

Το R αυτόματα κάνει μια ανάλυση γραμμικής παλινδρόμησης στο μοντέλο που του έχουμε εκχωρήσει τα δεδομένα τα πήραμε από το αρχείο Cars.sav (2.3.1 σελ. 9) και μπορούμε να την δούμε με:

```
> summary(fm)
```

Call:

```
lm(formula = MPG ~ ENGINE + HORSE, data = zz)
```

Residuals:

	Min	1Q	Median	3Q	Max
	-22.2185	-3.2771	-0.3892	2.3535	16.5639

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	37.533786	0.755398	49.687	< 2e-16 ***
ENGINE	-0.037064	0.005067	-7.315	1.48e-12 ***
HORSE	-0.066312	0.013906	-4.769	2.63e-06 ***

Signif. codes:	0 ‘***’	0.001 ‘**’	0.01 ‘*’	0.05 ‘.’
	0.1 ‘ ’	1		

Residual standard error: 4.67 on 389 degrees of freedom

Multiple R-Squared: 0.6439, Adjusted R-squared: 0.6421

F-statistic: 351.7 on 2 and 389 DF, p-value: < 2.2e-16

Σχετικά με την παλινδρόμηση, παρατηρούμε ότι όλες οι τιμές των F, t test είναι μικρές δηλαδή σημαντικές παράμετροι και υπάρχει σχέση μεταξύ εκτιμώμενων και παρατηρούμενων τιμών, και το R^2 μεγάλο οπότε δεχόμαστε το μοντέλο. Ουσιαστικά υποθέσαμε ότι η κατανάλωση βενζίνης σχετίζεται γραμμικά με τον κυβισμό και την ιπποδύναμη. Το μοντέλο μας είναι σύμφωνα με την γραμμική παλινδρόμηση:

$$y = -0.037064 \text{ ENGINE} - 0.066312 \text{ HORSE} + 37.533786$$

4.2 Συναρτήσεις για πιο λεπτομερειακές αναλύσεις

Στην γενική κλάση των γραμμικών μοντέλων (`lm`) υπάρχουν και επιπλέον συναρτήσεις για περαιτέρω εξαγωγή πληροφοριών, σχεδιασμού διαγραμμάτων κ.λ.π. Μια λίστα με αυτές είναι:

anova(object₁, object₂) Συγκρίνει ένα υπο-μοντέλο με ένα άλλο υπαρκτό και παράγει ένα πίνακα ανάλυσης διακύμανσης.

coefficients(object) ή **coef(object)** Παράγει έναν πίνακα συντελεστών της παλινδρόμησης.

deviance(object) Το άθροισμα των τετραγώνων των υπολοίπων (`residuals`).

formula(object) Παράγει τον τελικό τύπο του μοντέλου.

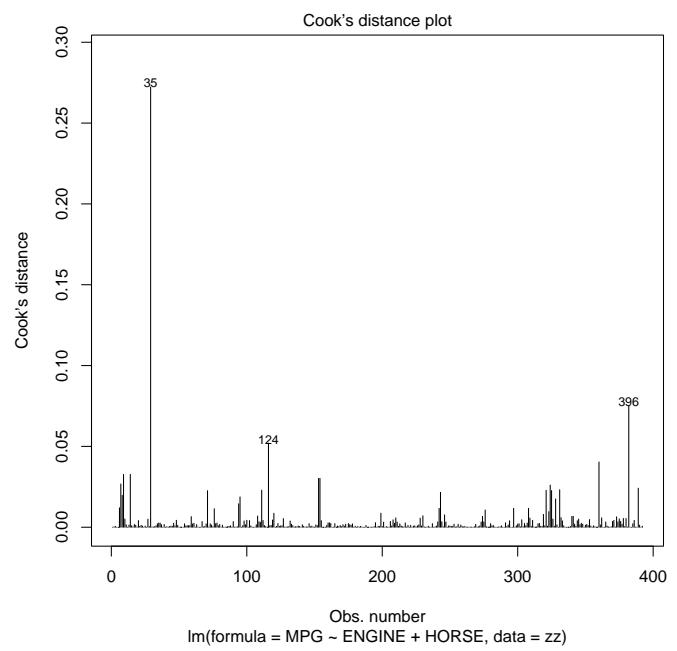
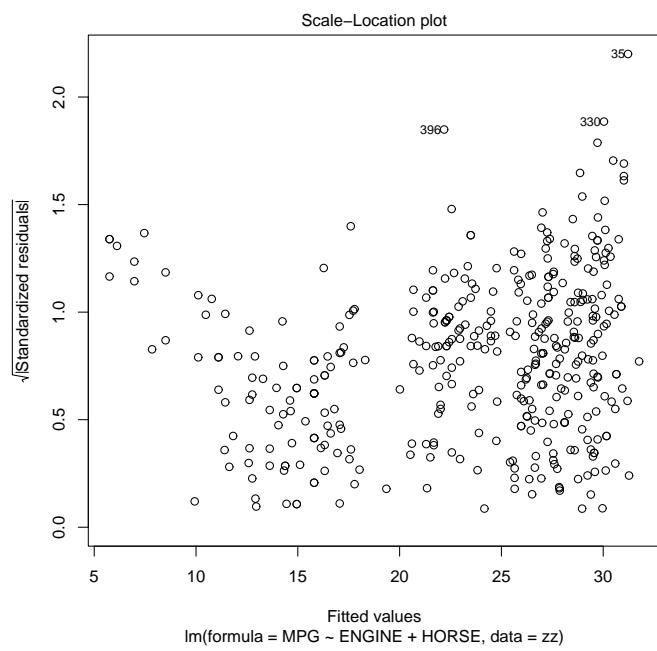
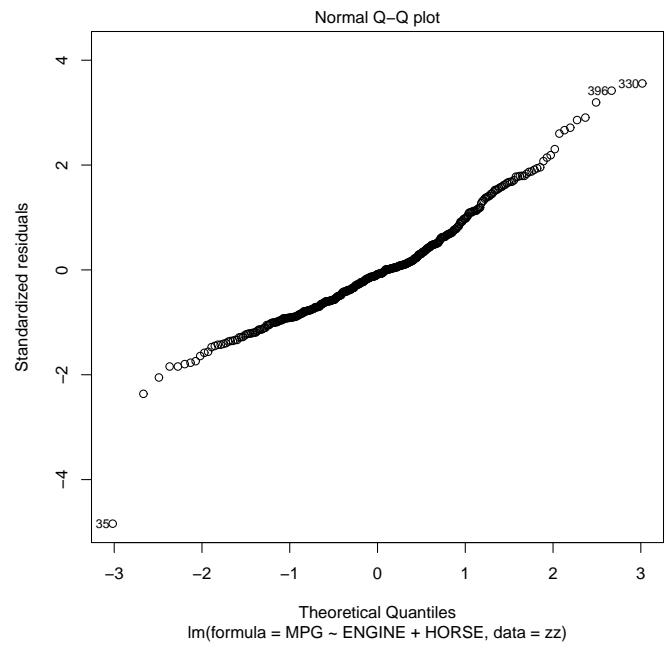
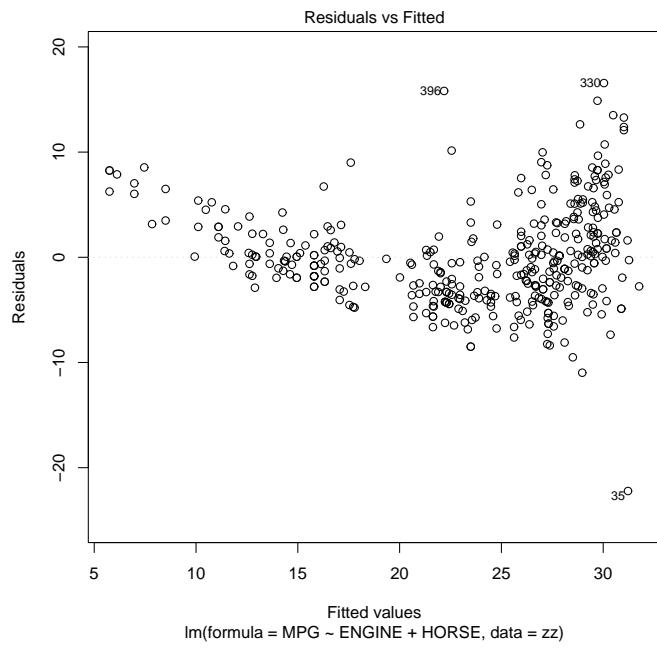
plot(object) Παράγει 4 διαγράμματα: για τα υπόλοιπα, τις προβλεπόμενες τιμές και μερικά διαγνωστικά.

residuals(object) ή **resid(object)**. Ο πίνακας των υπολοίπων (`residuals`), σταθμισμένος κατάλληλα.

step(object) Διαλέγει ένα βέλτιστο μοντέλο προσθέτοντας ή αφαιρώντας παράγοντες διατηρώντας την ιεραρχία, σύμφωνα με τη μεγαλύτερη τιμή του AIC (Akaike's An Information Criterion) από την βηματική stepwise παλινδρόμηση.

summary(object) Δίνει μια αναλυτική περίληψη των αποτελεσμάτων της ανάλυσης παλινδρόμισης.

Τέλος μερικά διαγράμματα από το μοντέλο `plot(fm)` :



Βιβλιογραφία

An itroduction to R, Bill Venables, David M. Smith and R Developent Core team, 1.6.1 (2002-11-01) ISBN 3-901167-55-2

R Data Import/Export, 1.6.1 (2002-11-01) ISBN 3-901167-53-6

Θα τα βρείτε στο www.r-project.org

Practical Regression and Anova using R, Julian Faraway, July 2002

Θα το βρείτε στον διακτυακό τόπο: <http://www.stat.lsa.umich.edu/~faraway/book>

Και τέλος η εσωτερική βοήθεια-αναφορά του R .

Ευρετήριο

case sensitive , 4
CRAN , 3, 8
 Comprehensive R Archive , 3
Cars.sav , 9
ctest , 10, 15
foreign , 9
objects , 3
αντικείμενα, 3

Εντολές

? , 5
boxplot , 12
hist , 11
library , 8
lm , 18
plot , 13
print , 6
qqnorm , 13
scan , 6
summary , 6
t.test , 16
var.test , 16
<-, 5
help , 5
αριθμητικοί τελεστές, 7

Γραμμικά μοντέλα, 18

Κατανομές, 10

Λίστα συναρτήσεων γραμμικών μοντέλων, 19

παχέτα, 8