

9. Representação de dados multidimensionais

2010

Dados: x_i , $i = 1, \dots, n$, vetores $p \times 1$ ($p \geq 2$) cujos componentes podem ser p variáveis qualitativas, p variáveis quantitativas ou de ambos os tipos.

Problema central. Existe algum tipo de relação entre as variáveis?

p variáveis quantitativas: matriz de gráficos de dispersão (Cap. 8).

p variáveis qualitativas: tabelas de contingência multidimensionais e gráficos de mosaico (Cap. 8).

Utilizaremos os gráficos em **grade** (*trellis plots*) em R (pacote `lattice`).

Sintaxe baseada em fórmulas.

Exemplos. (1) `var1 ~ var2 | var3 + var4 + var5`

(2) `~ var1 | var2 + var3`

A barra vertical (`|`) indica **condicionamento**. O sinal “`+`” não é adição.

Em (1), `var1` é a variável dependente e `var2` é a variável independente.

Todas as combinações de (`var3`, `var4`, `var5`) são consideradas na relação `var2 → var1`.

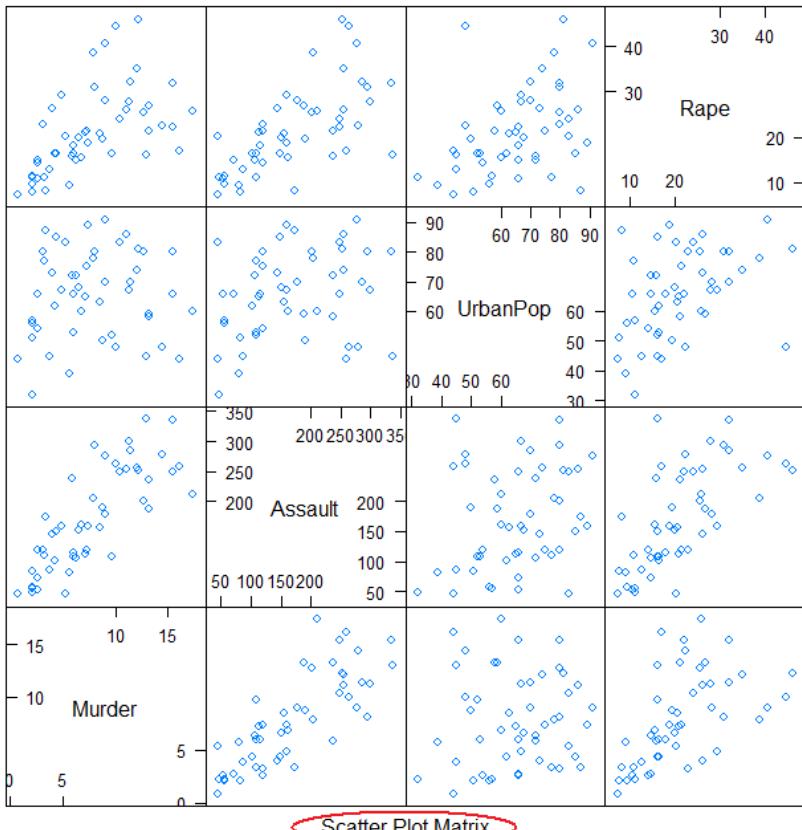
Em (2), não há variável dependente. Todas as combinações de (`var2`, `var3`) são consideradas.

9.1 Variáveis quantitativas

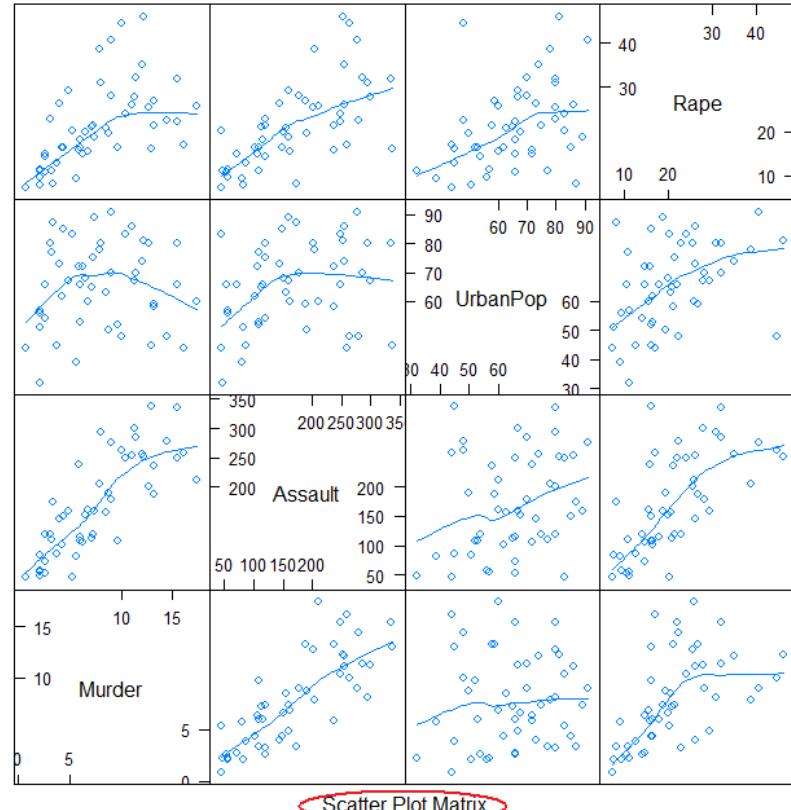
Função `splom` (`lattice`): matriz de gráficos de dispersão (scatter plot matrix).

Dados USArrests (Seção 8.1).

```
> library(lattice)  
> splom(USArrests)
```



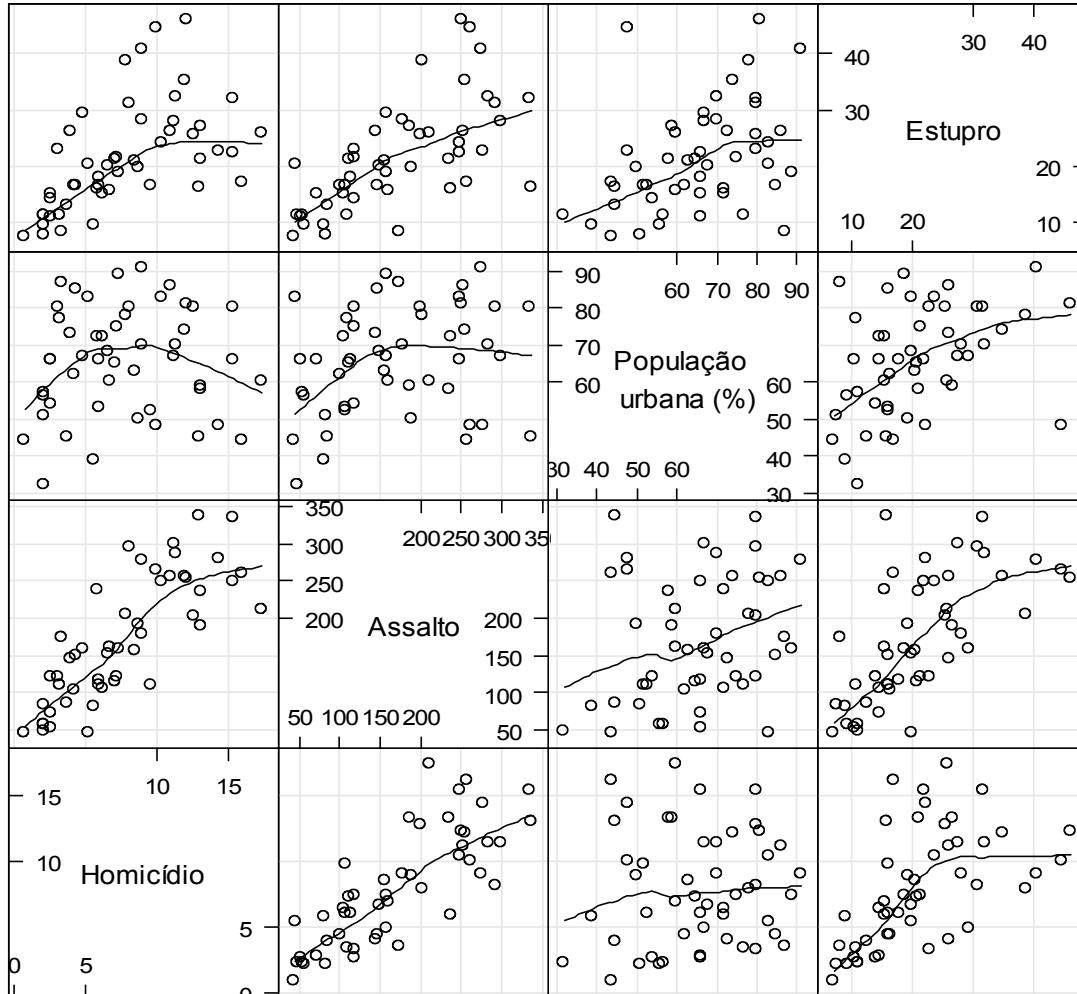
```
> splom(USArrests, type = c("p", "smooth"))
```



Gráficos com pontos (p) e linhas de tendência (smooth).

9.1 Variáveis quantitativas

```
> splom(USArrests, type = c("g", "p", "smooth"), col =  
"black", xlab = "", varnames = c("Homicídio",  
"Assalto", "População \n urbana (%)", "Estupro"))
```



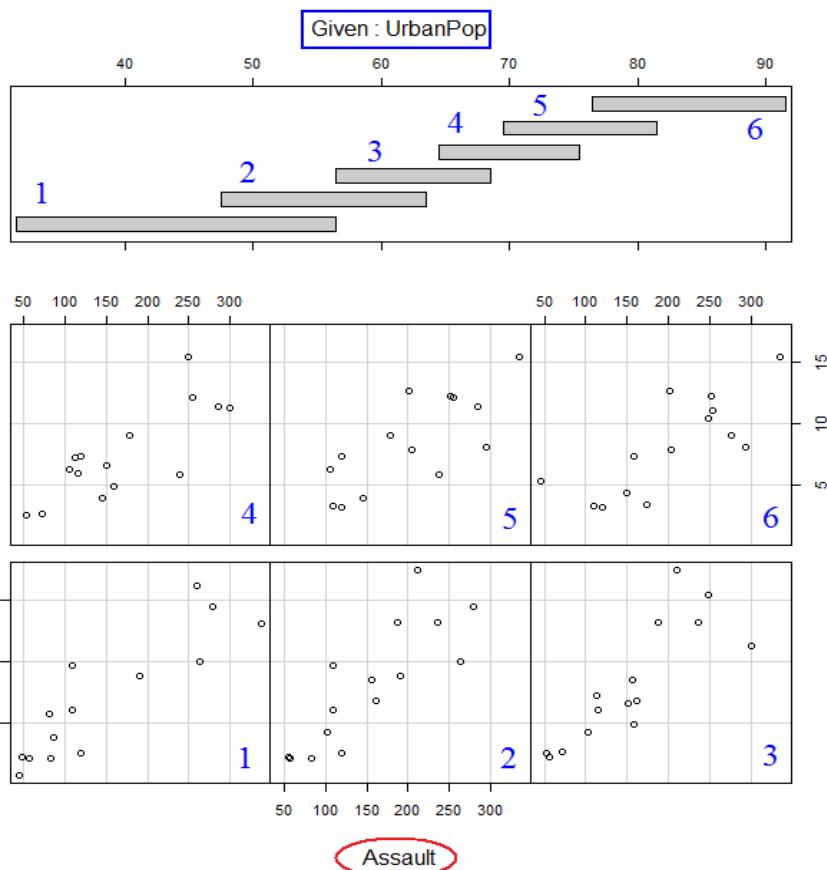
Gráficos com
reticulados (g),
pontos (p) e linhas de
tendência (smooth).

9.1 Variáveis quantitativas

Gráficos condicionais (*conditional plots*): gráfico de dispersão de (x_1, x_2) para faixas de valores de outras variáveis quantitativas.

Funções `coplot` (`graphics`) e `xyplot` (`lattice`).

```
> attach(USArrests)  
  
> coplot(Murder ~ Assault | UrbanPop)
```



Por default, são criadas seis faixas com aproximadamente o mesmo número de observações da variável condicionante e com superposição (overlap) de 50% (estes argumentos podem ser mudados).

Os painéis são dispostos a partir do canto inferior esquerdo.

Permite avaliar se a relação entre x_1 e x_2 depende de valores de outra(s) variável(is).

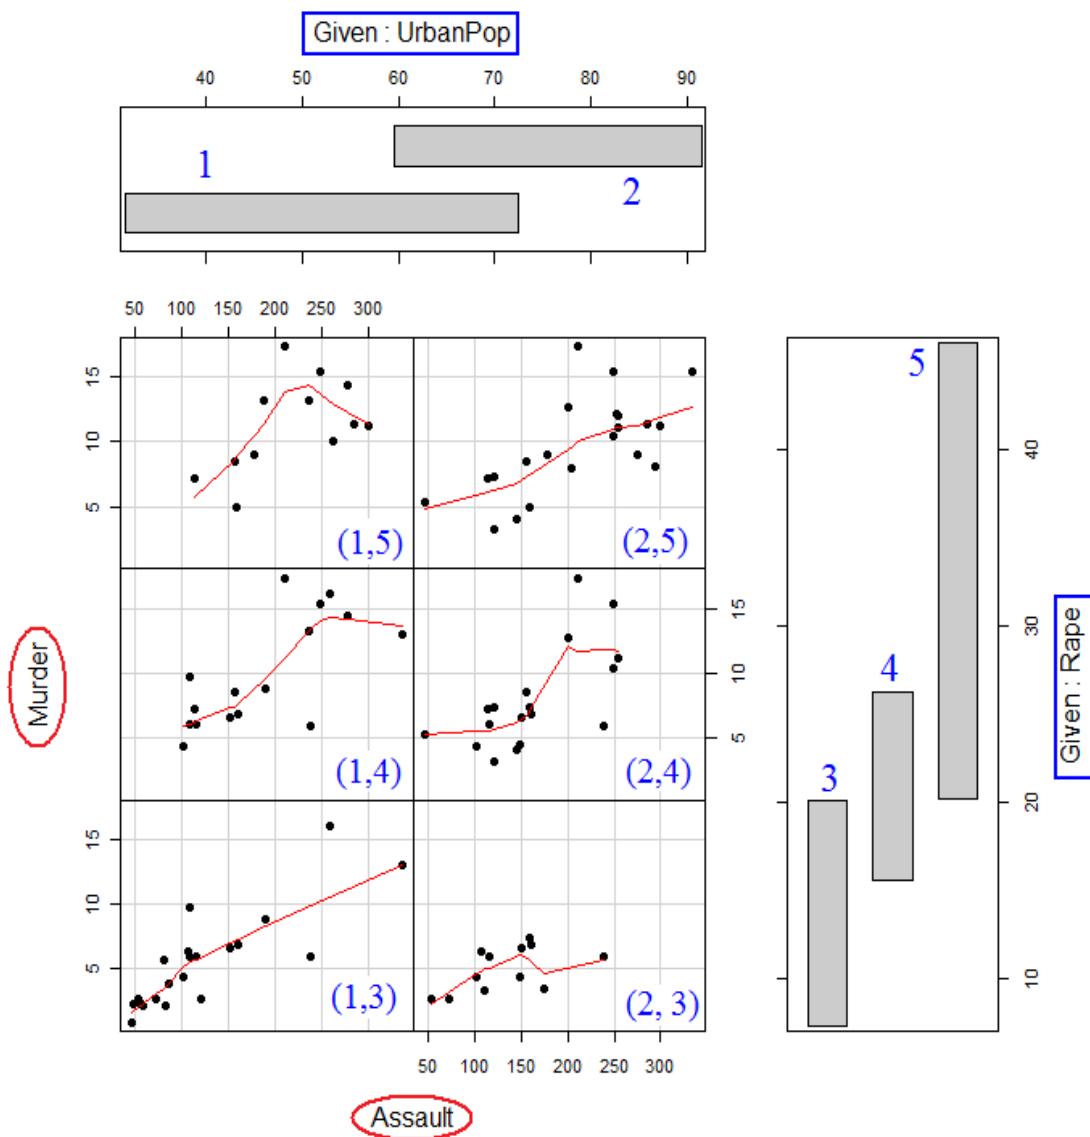
9.1 Variáveis quantitativas

Duas variáveis condicionantes:

UrbanPop e Rape.

Número de intervalos (faixas) é diferente para cada variável condicionante.

```
> coplot(Murder ~ Assault  
UrbanPop * Rape, number =  
c(2, 3), pch = 20, cex =  
1.5, panel = panel.smooth)
```



9.1 Variáveis quantitativas

UrbanPop com três intervalos de igual comprimento.

```
> xyplot(Murder ~ Assault |  
cut(UrbanPop, 3))
```

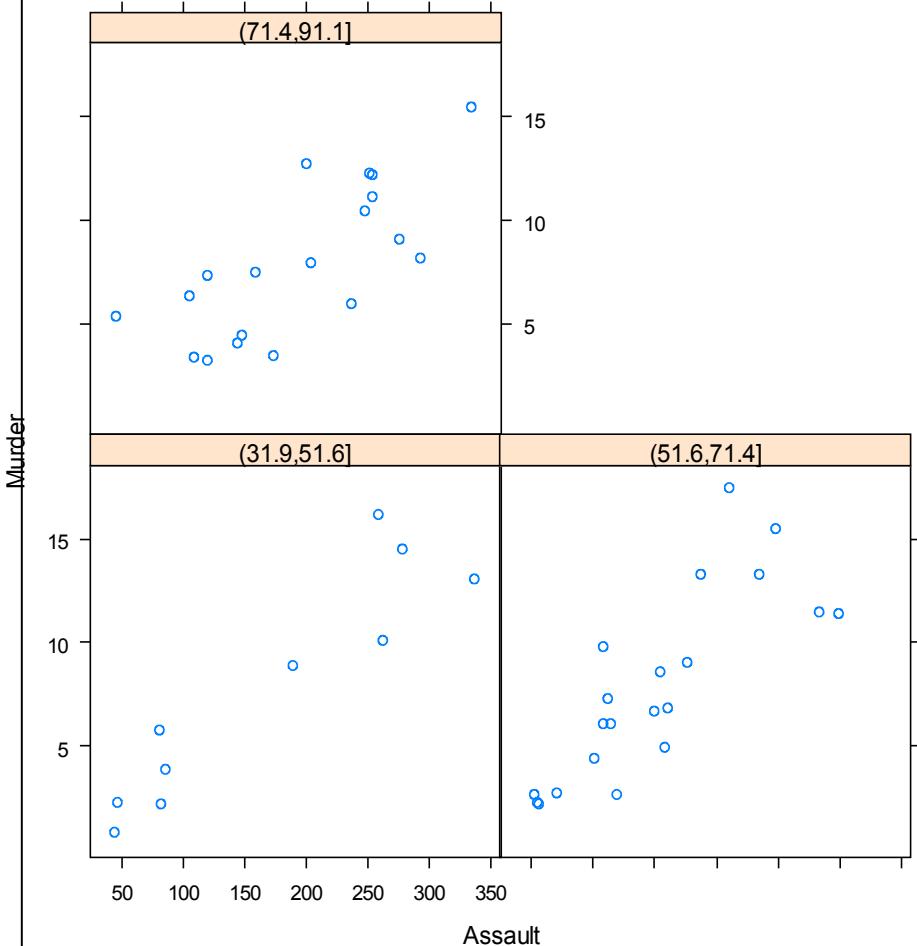
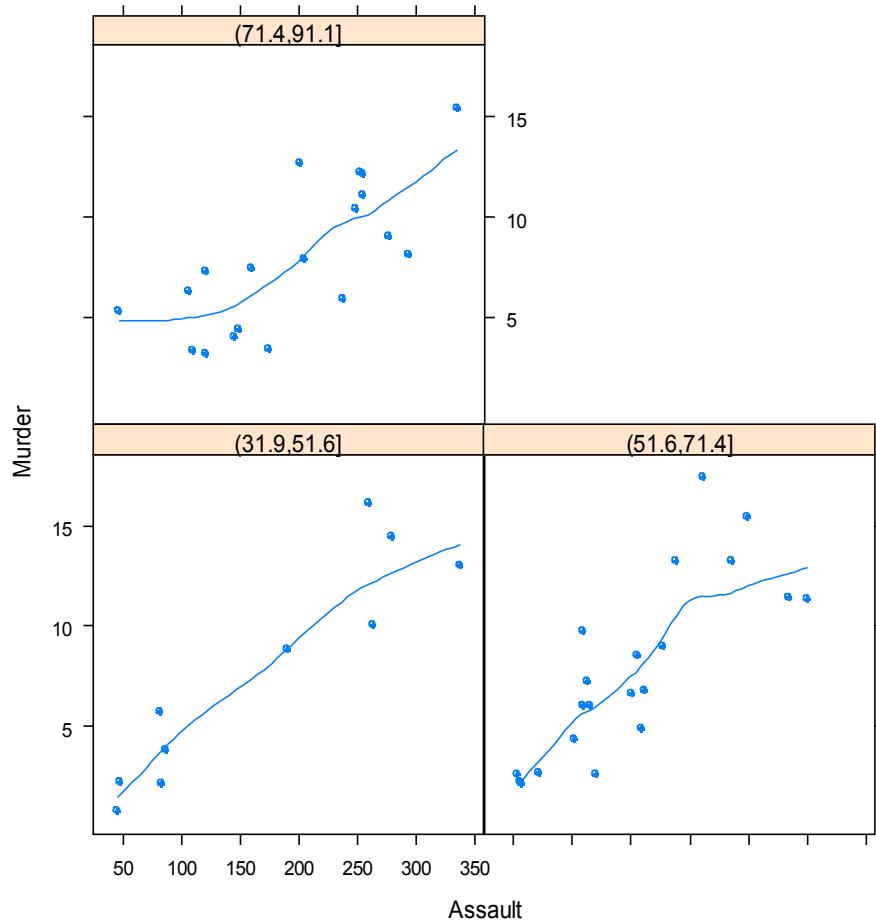


Gráfico com pontos (p) e linhas de tendência (smooth)

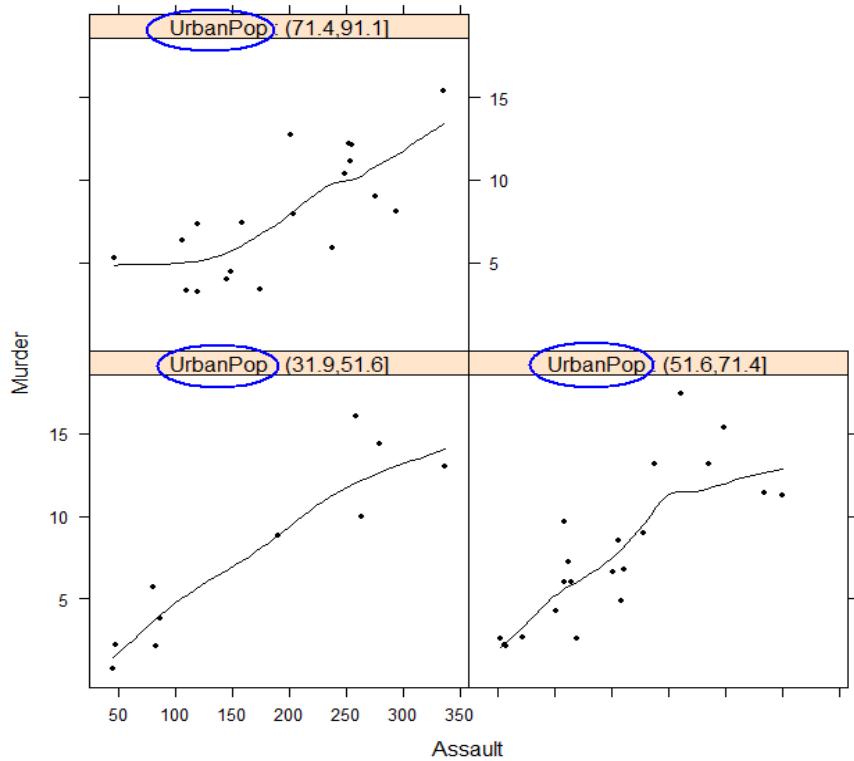
```
> xyplot(Murder ~ Assault |  
cut(UrbanPop, 3), type = c("p",  
"smooth"), pch = 20)
```



9.1 Variáveis quantitativas

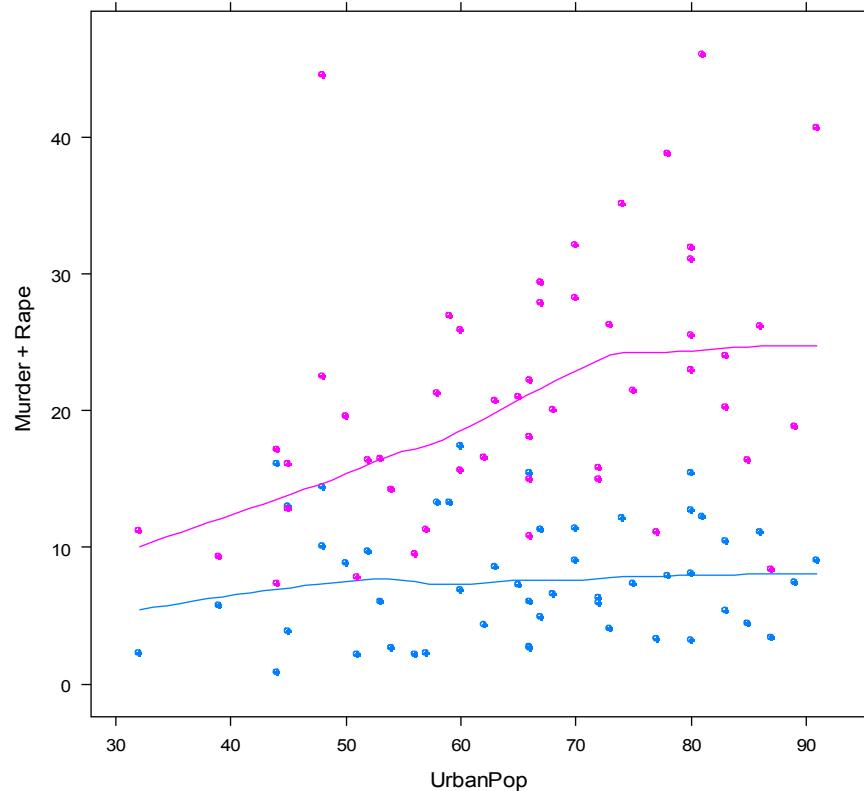
Inclusão do nome da variável condicionante nos painéis

```
> xyplot(Murder ~ Assault |  
cut(UrbanPop, 3), type = c("p",  
"smooth"), pch = 20,  
strip.custom(strip.names =  
TRUE, var.name = "UrbanPop"))
```



Duas variáveis dependentes, sem variável condicionante

```
> xyplot(Murder + Rape ~ UrbanPop,  
type = c("p", "smooth"), pch = 20)
```



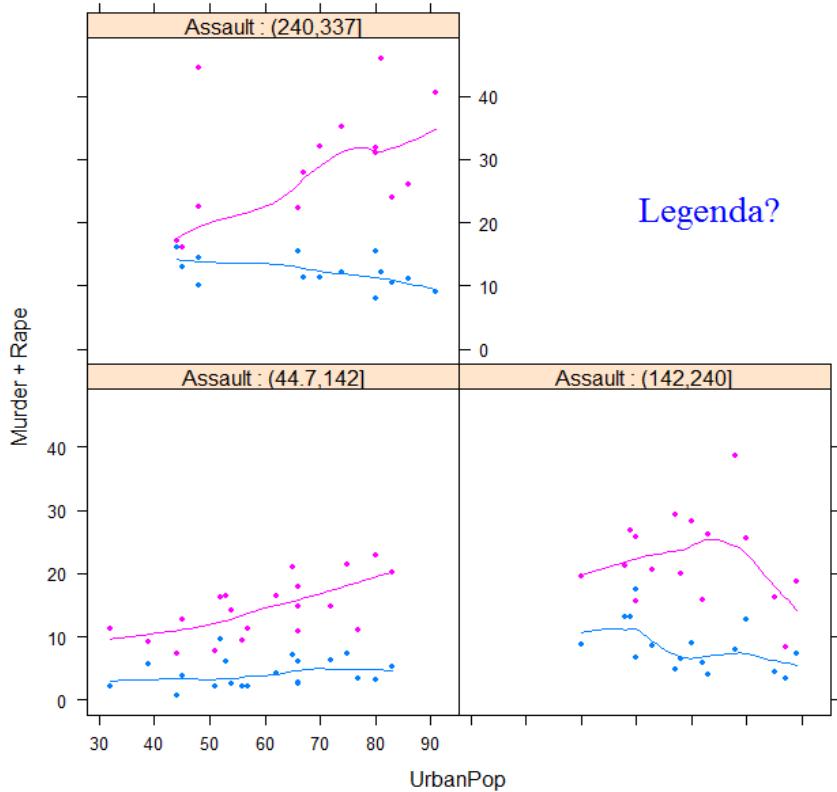
Obs. “+” não significa adição.

Exercício. Incluir uma legenda.

9.1 Variáveis quantitativas

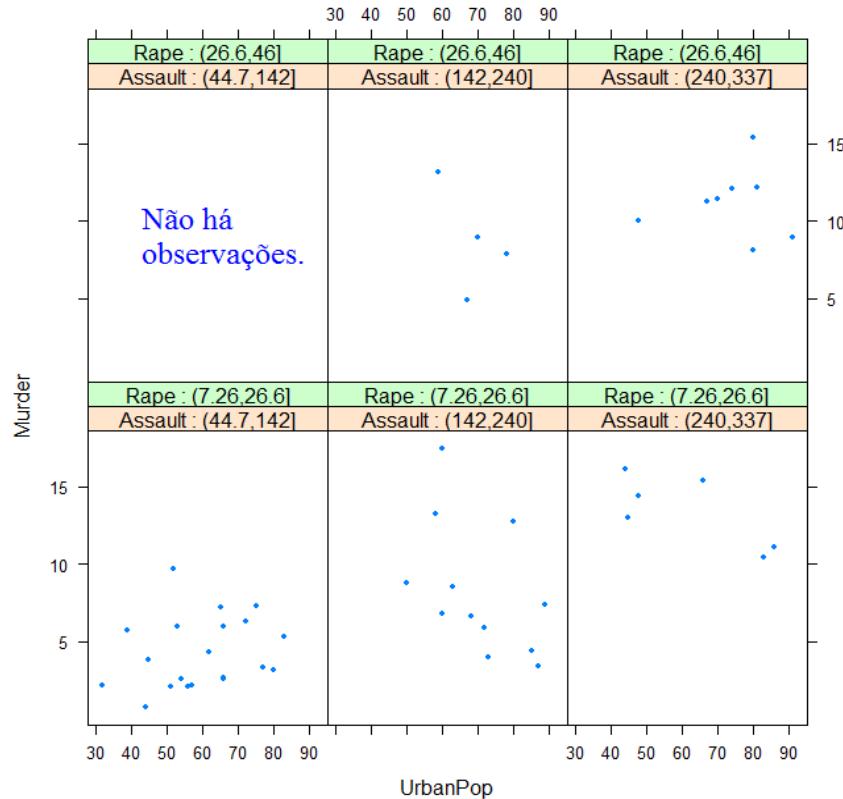
Duas variáveis dependentes e uma variável condicionante

```
> xyplot(Murder + Rape ~ UrbanPop |  
| cut(Assault, 3), type = c("p",  
"smooth"), pch = 20, strip =  
strip.custom(strip.names = TRUE,  
var.name = "Assault"))
```



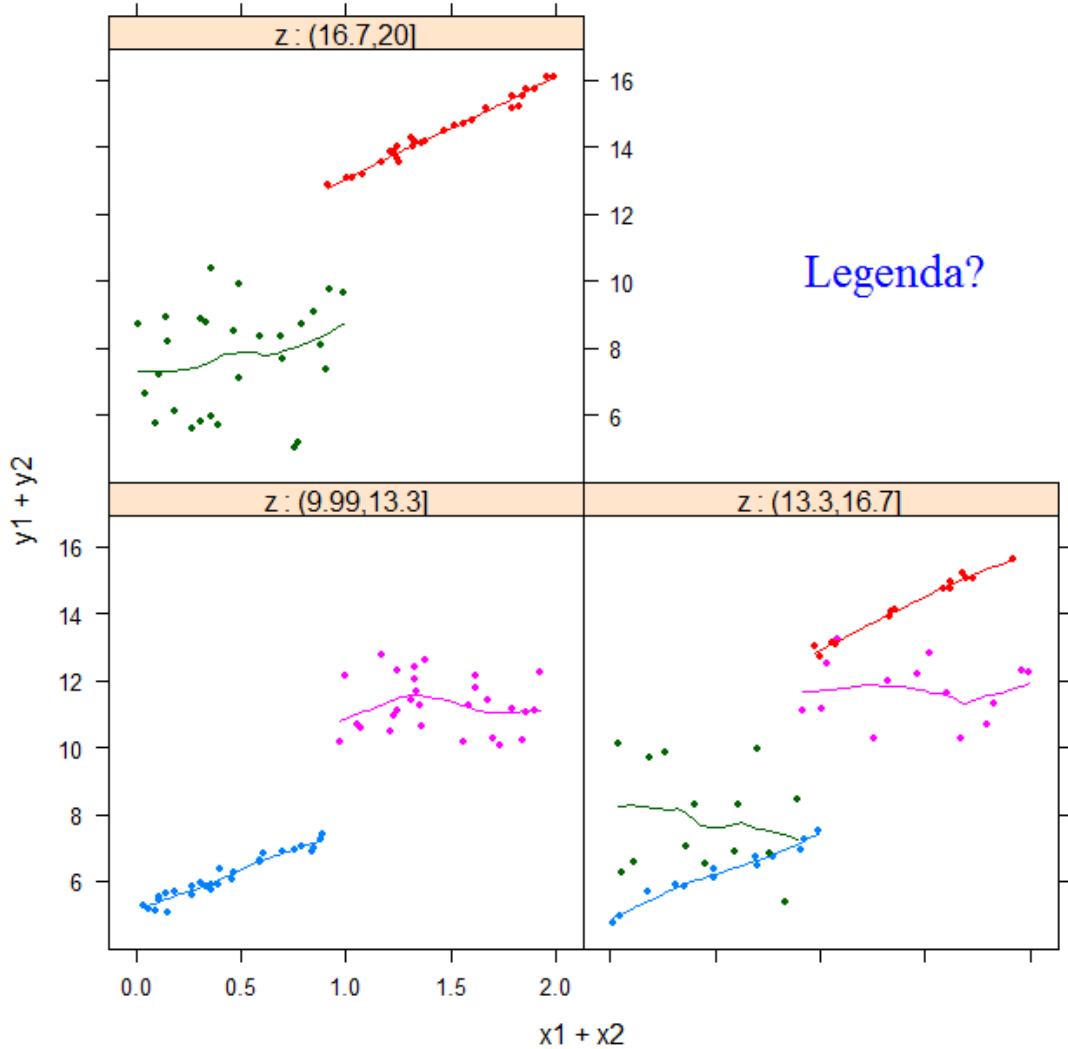
Duas variáveis condicionantes

```
> xyplot(Murder ~ UrbanPop |  
| cut(Assault, 3) + cut(Rape, 2),  
pch = 20, strip =  
strip.custom(strip.names = TRUE,  
var.name = c("Assault", "Rape")))
```



9.1 Variáveis quantitativas

Duas variáveis dependentes, duas variáveis independentes e uma variável condicionante (**cinco** variáveis)



Obs. (1) **Quatro** cores correspondem aos quatro pares de variáveis (x, y).

Neste exemplo, em cada painel podemos ter **até quatro** gráficos de dispersão.

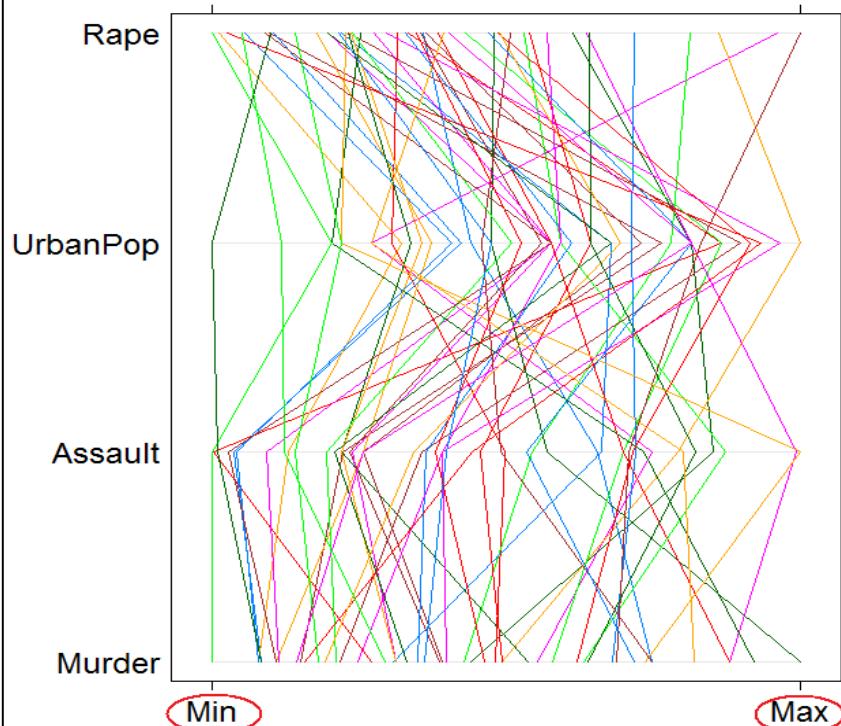
(2) Em uma fórmula, se quisermos somar variáveis (e se fizer sentido), utilizamos $I(x_1 + x_2)$ e/ou $I(y_1 + y_2)$.

9.1 Variáveis quantitativas

Função `parallel` (`lattice`): gráfico de coordenadas paralelas.

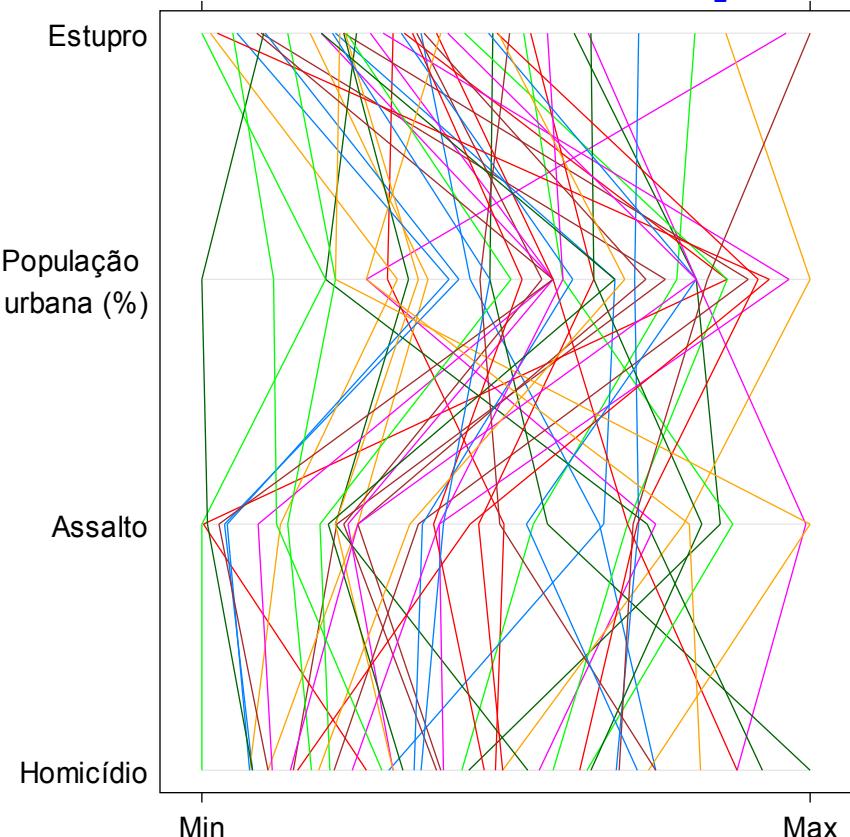
$p - 1$ segmentos de retas para cada observação unindo os valores escalonados em [Min, Max] para cada variável.

```
> parallel(USArrests)
```



Podem ser úteis para identificar grupos de observações (*cluster analysis*).

```
> parallel(USArrests,  
varnames = c("Homicídio",  
"Assalto", "População \n urbana (%)", "Estupro"))
```



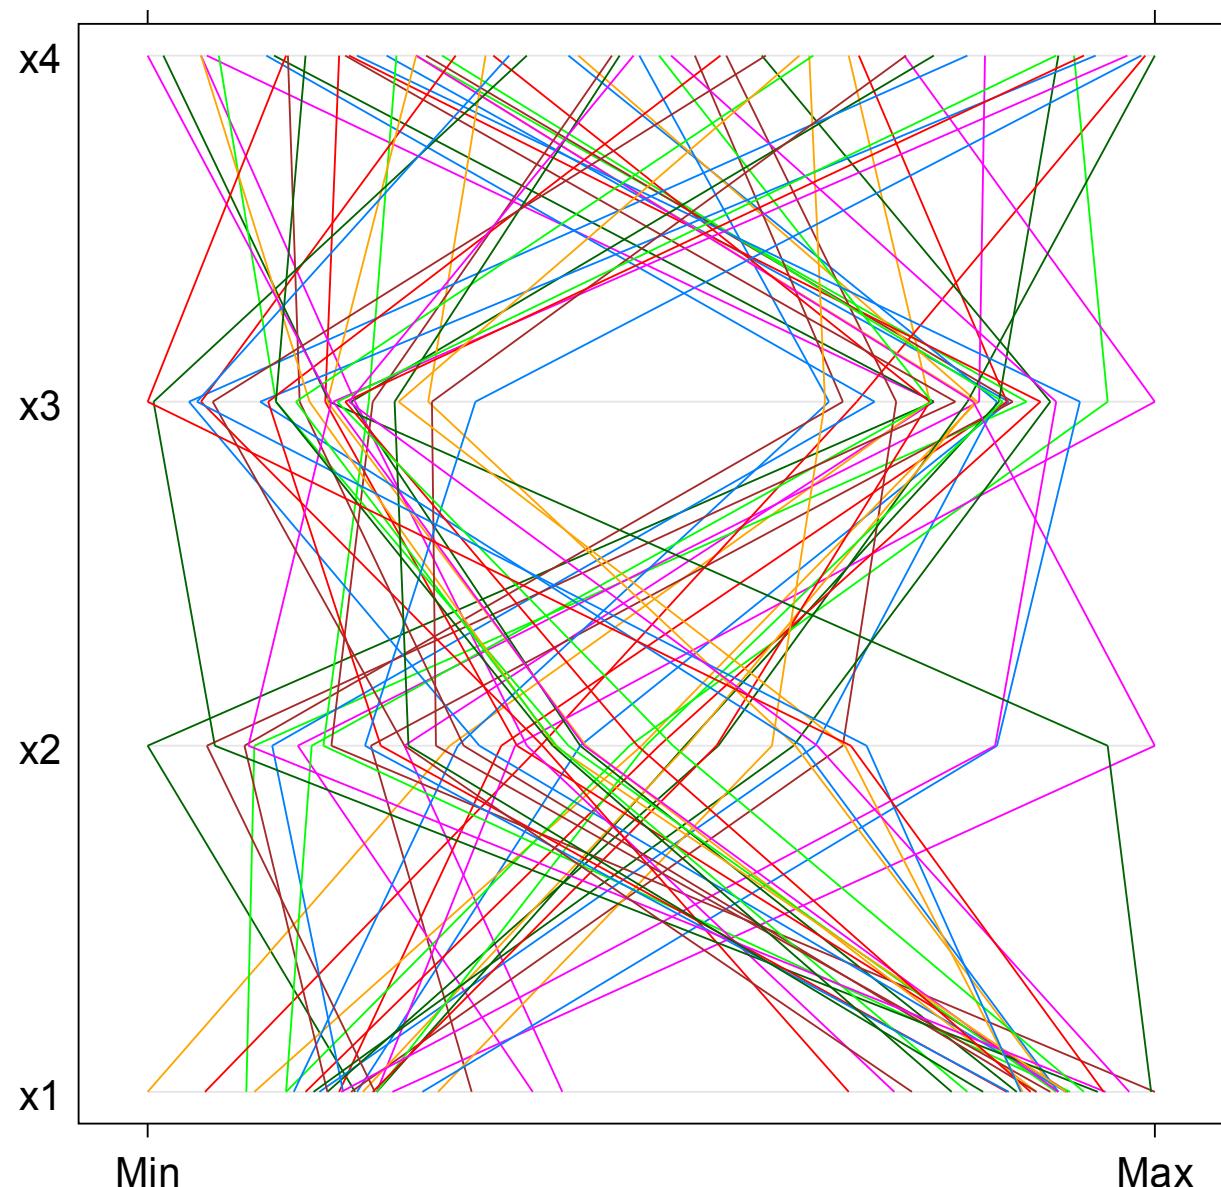
9.1 Variáveis quantitativas

As variáveis x_1 e x_3 separam as observações em dois grupos.

Em um dos grupos os valores de x_1 são os menores e os valores de x_3 são os maiores.

No outro grupo há uma inversão.

As variáveis x_2 e x_4 não permitem uma separação tão nítida quanto x_1 e x_3 .



9.2 Variáveis qualitativas

Dados Ilocos da Seção 8.2.

```
> library(ineq)  
  
> data(Ilocos)      "income" "sex" "family.size" "urbanity" "province" "AP.income"  
> dados = Ilocos    "AP.family.size" "AP.weight"  
  
> attach(dados)  
  
> names(dados)
```

Função `ftable`: tabela de contingências multidimensional.

```
> (tab3 =  
  ftable(urbanity,  
         province, sex))  
  
> tab3rel =  
  prop.table(tab3, margin  
  = 1)  
  
> (tab3rexp = tab3rel *  
  100)
```

			sex	female	male
urbanity	rural	Ilocos Norte		5	42
		Ilocos Sur		9	36
		La Union		9	62
		Pangasinan		18	120
	urban	Ilocos Norte		3	15
		Ilocos Sur		9	14
		La Union		9	36
		Pangasinan		52	193

			sex	female	male
urbanity	rural	Ilocos Norte		10.63830	89.36170
		Ilocos Sur		20.00000	80.00000
		La Union		12.67606	87.32394
		Pangasinan		13.04348	86.95652
	urban	Ilocos Norte		16.66667	83.33333
		Ilocos Sur		39.13043	60.86957
		La Union		20.00000	80.00000
		Pangasinan		21.22449	78.77551

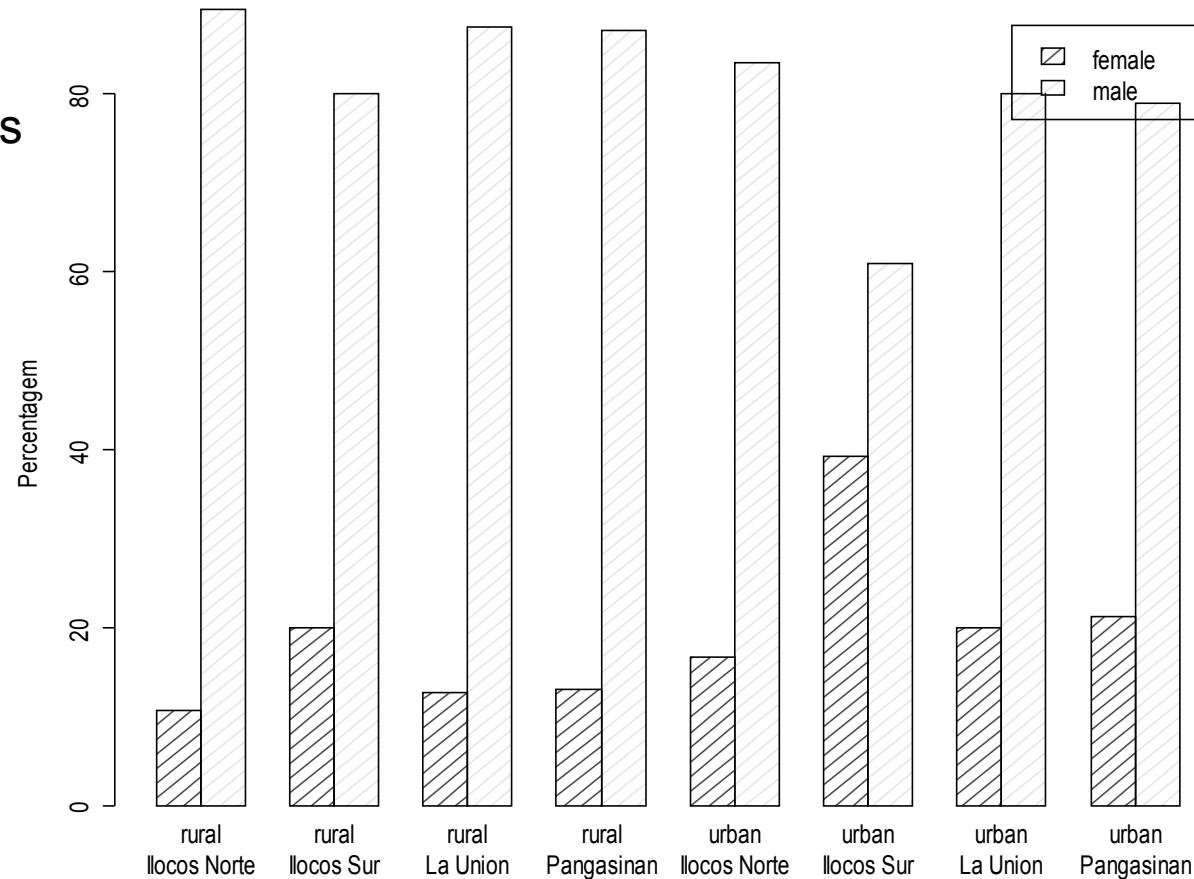
9.2 Variáveis qualitativas

Gráfico de barras

```
> rownames(tab3relp) = paste(rep(levels(urbanity), each =  
length(levels(province))), levels(province), sep = "\n")  
> barplot(t(tab3relp), beside = TRUE, legend = levels(sex), density  
= 15, ylab = "Percentagem")  
> box()
```

Gráfico com as distribuições condicionais de sex | (urbanity, province).

Exercício. Apresentar os rótulos e a legenda em português.



9.2 Variáveis qualitativas

Função `xtabs`: tabelas multidimensionais utilizando uma formula.

```
> (tab3var = xtabs(~ urbanity + province + sex))
```

, , **sex = female**

province

urbanity Ilocos Norte Ilocos Sur La Union Pangasinan

rural 5 9 9 18

urban 3 9 9 52

, , **sex = male**

province

urbanity Ilocos Norte Ilocos Sur La Union Pangasinan

rural 42 36 62 120

urban 15 14 36 193

As duas vírgulas indicam as outras duas variáveis.

```
> class(tab3var)
```

```
[1] "xtabs" "table"
```

Tabela na forma de uma folha de dados (*data frame*)

```
> as.data.frame(tab3var)
```

	urbanity	province	sex	Freq
1	rural	Ilocos Norte	female	5
2	urban	Ilocos Norte	female	3
3	rural	Ilocos Sur	female	9
4	urban	Ilocos Sur	female	9
5	rural	La Union	female	9
6	urban	La Union	female	9
7	rural	Pangasinan	female	18
8	urban	Pangasinan	female	52
9	rural	Ilocos Norte	male	42
10	urban	Ilocos Norte	male	15
11	rural	Ilocos Sur	male	36
12	urban	Ilocos Sur	male	14
13	rural	La Union	male	62
14	urban	La Union	male	36
15	rural	Pangasinan	male	120
16	urban	Pangasinan	male	193

9.2 Variáveis qualitativas

Gráfico de barras de sex com frequencias relativas ao par (urbanity, province).

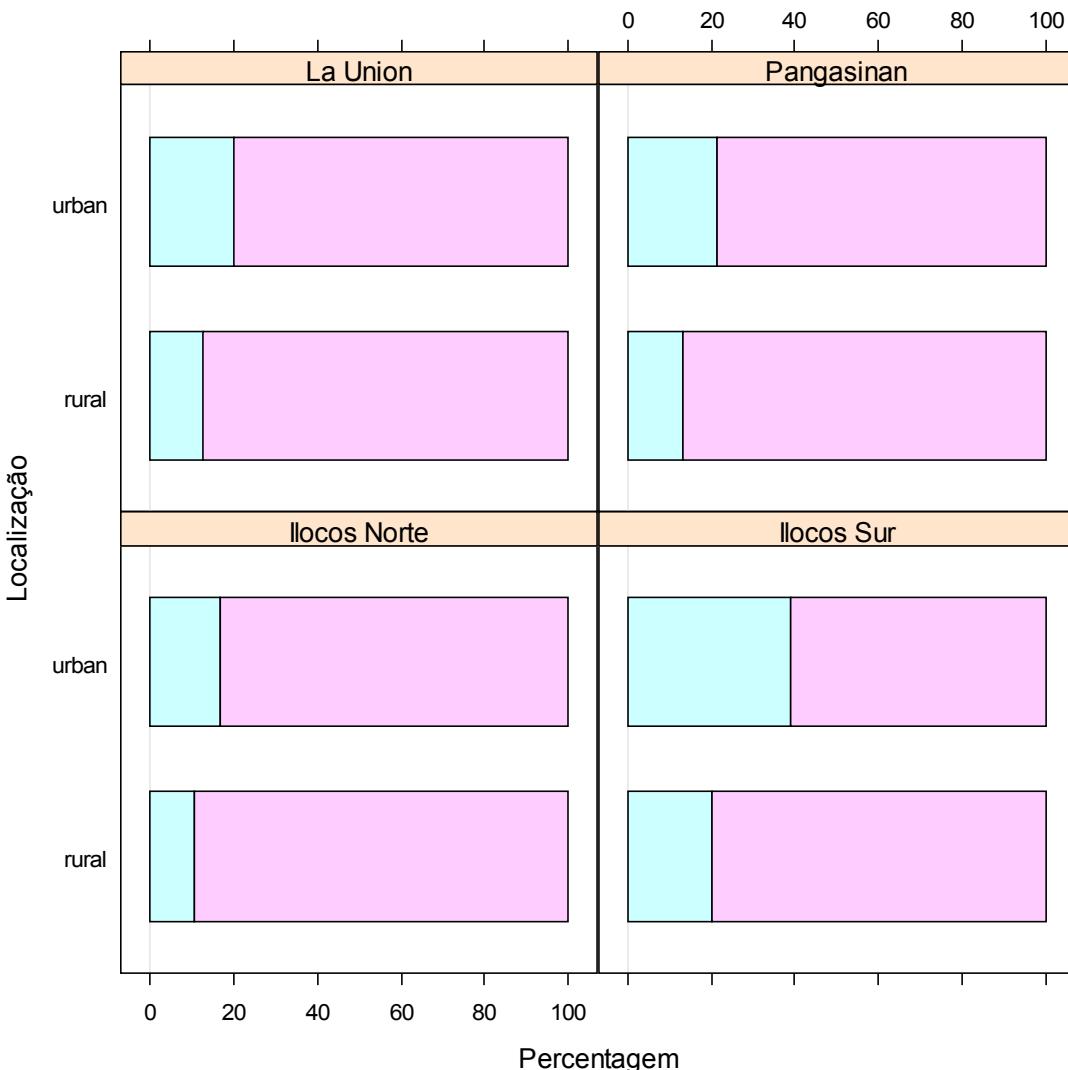
Função barchart (lattice).

```
> barchart(prop.table(tab3var, margin = c(1, 2)) * 100, xlab ="Percentagem",  
ylab = "Localização")
```

Cada nível de sex com uma cor diferente.

Exercícios.

1. Mudar as cores e adicionar uma legenda.
2. Verificar o resultado da função prop.table.



9.2 Variáveis qualitativas

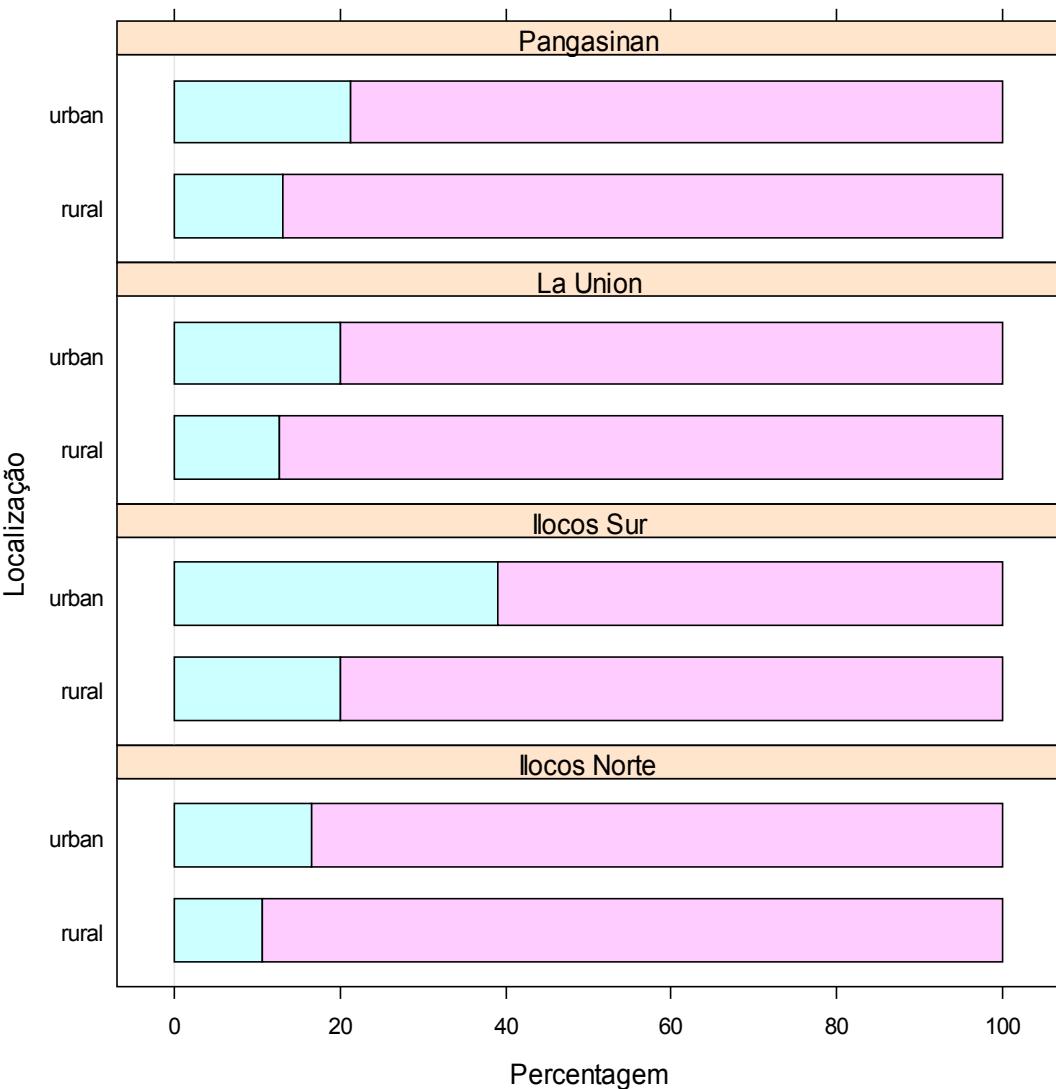
Gráfico de barras de sex com frequencias relativas ao par (urbanity, province).

Níveis de province empilhados.

```
> barchart(prop.table(tab3var, margin = c(1, 2)) * 100, xlab = "Percentagem",  
  ylab = "Localização",  
  layout = c(1, 4))
```

Exercício. Compare com o gráfico da lâmina 14.

O que pode ser afirmado sobre a associação entre as variáveis?



9.3 Variáveis quantitativas e qualitativas

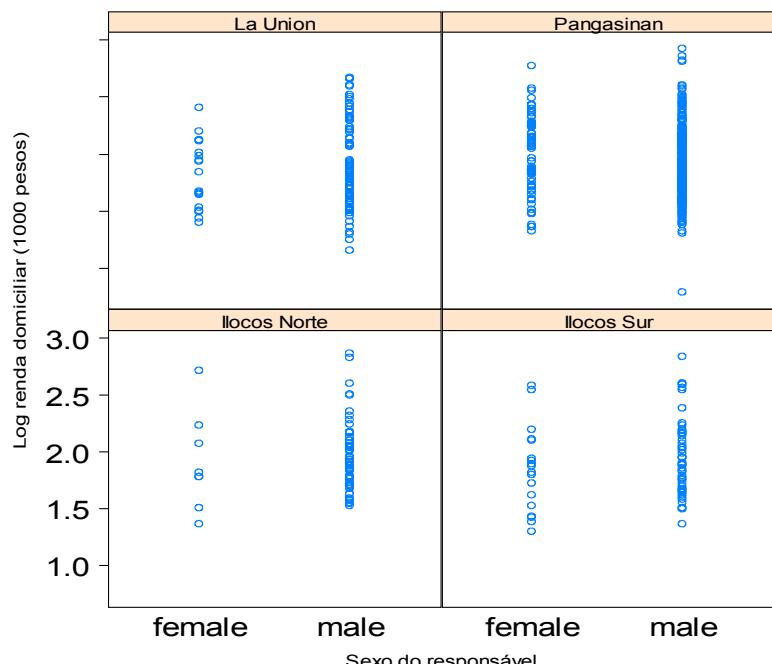
Dados Ilocos da Seção 8.2.

> names(dados)

Gráfico de pontos

Função `stripplot` (lattice)

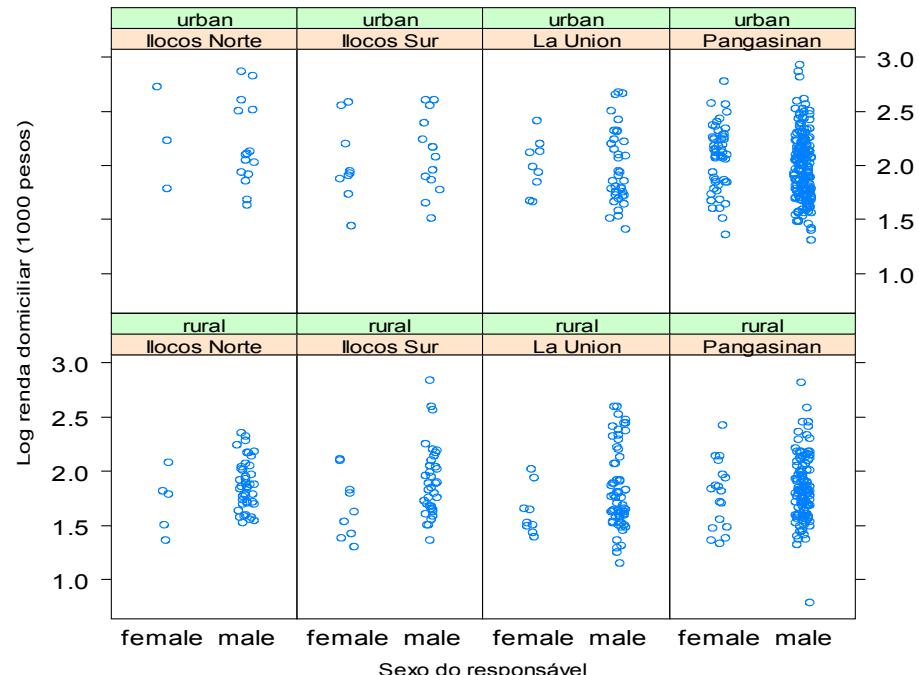
```
> stripplot(log(income /  
1000, 10) ~ sex | province,  
xlab = "Sexo do responsável",  
ylab = "Log renda domiciliar  
(1000 pesos)")
```



y x y x x
"income" "sex" "family.size" "urbanity" "province" "AP.income"
"AP.family.size" "AP.weight"

Duas variáveis condicionantes e acréscimo de ruído

```
> stripplot(log(income / 1000, 10) ~  
sex | province + urbanity, xlab =  
"Sexo do responsável", ylab = "Log  
renda domiciliar (1000 pesos)",  
jitter.data = TRUE)
```



9.3 Variáveis quantitativas e qualitativas

Gráfico de violino

Função `bwplot` (lattice)

```
> bwplot(log(income / 1000, 10) ~ sex, panel = panel.violin, xlab =  
  "Sexo do responsável", ylab = "Log  
 renda domiciliar (1000 pesos)",  
  col = "white")
```

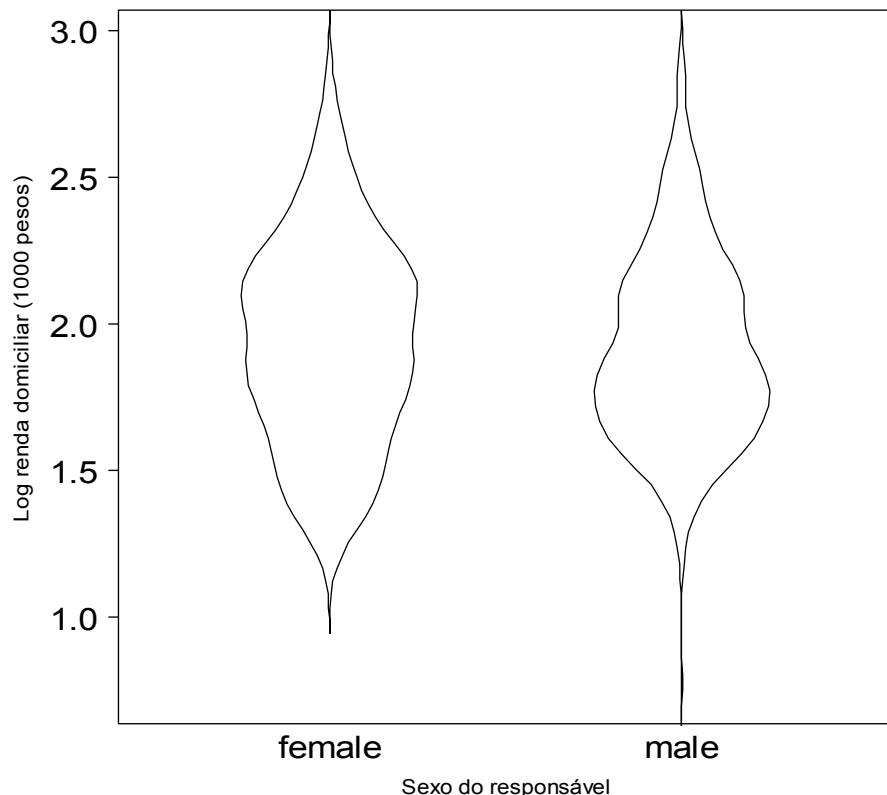
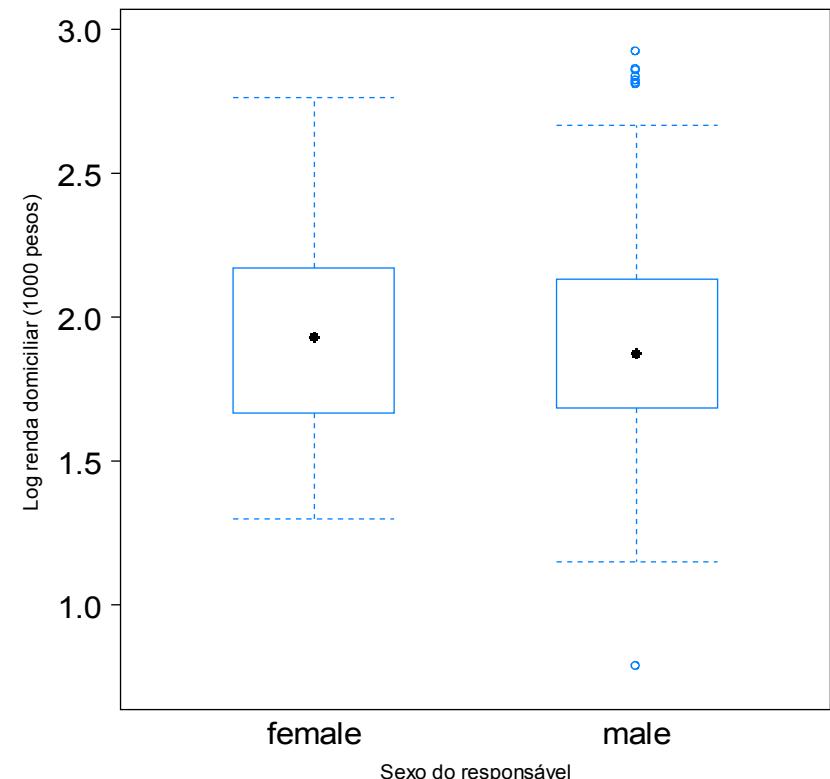


Gráfico de caixas

Função `bwplot` (lattice)

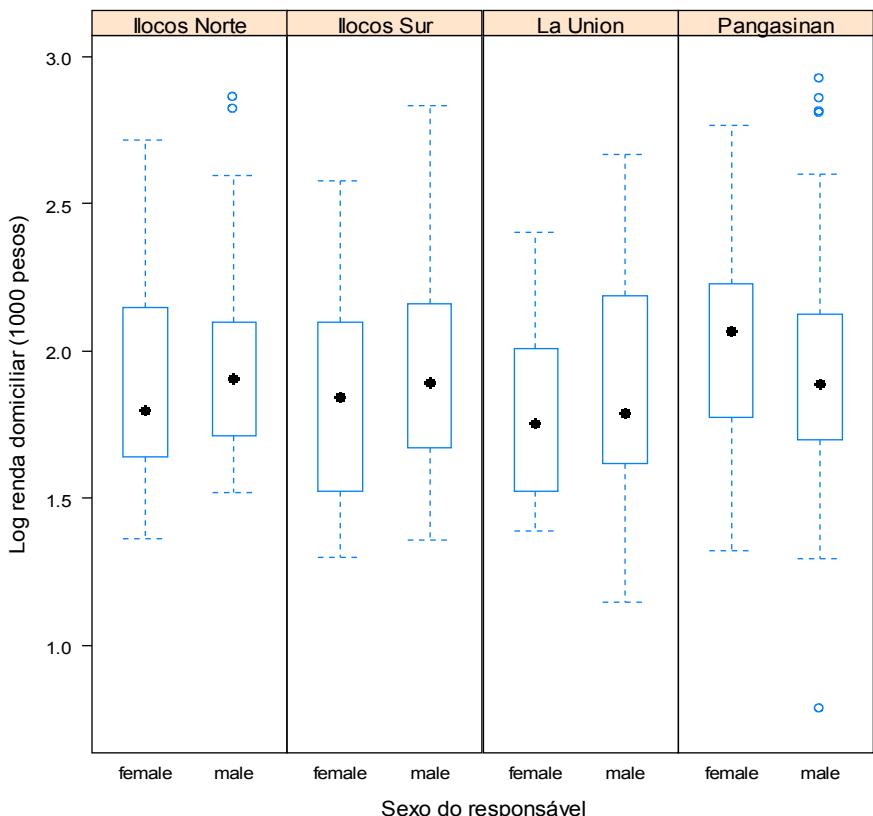
```
> bwplot(log(income / 1000, 10)  
  ~ sex, xlab = "Sexo do  
  responsável", ylab = "Log  
  renda domiciliar (1000 pesos)")
```



9.3 Variáveis quantitativas e qualitativas

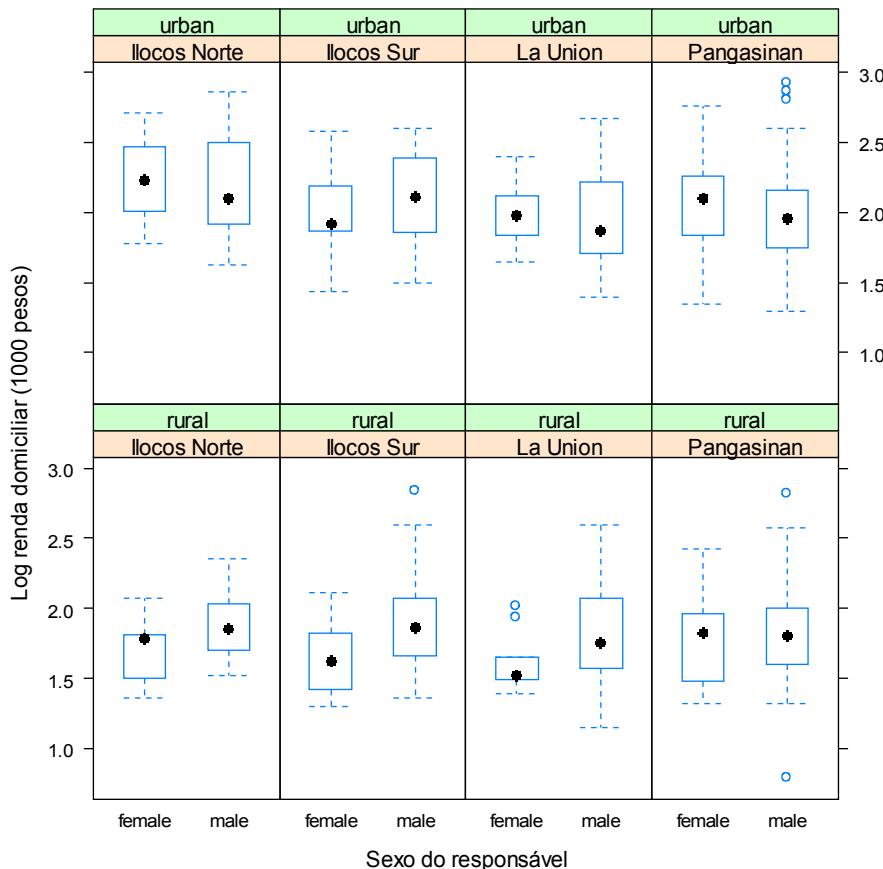
Uma variável condicionante

```
> bwplot(log(income / 1000, 10)
~ sex | province, xlab = "Sexo
do responsável", ylab = "Log
renda domiciliar (1000 pesos)",
layout = c(4, 1))
```



Duas variáveis condicionantes

```
> bwplot(log(income / 1000, 10)
~ sex | province + urbanity,
xlab = "Sexo do responsável",
ylab = "Log renda domiciliar
(1000 pesos)")
```

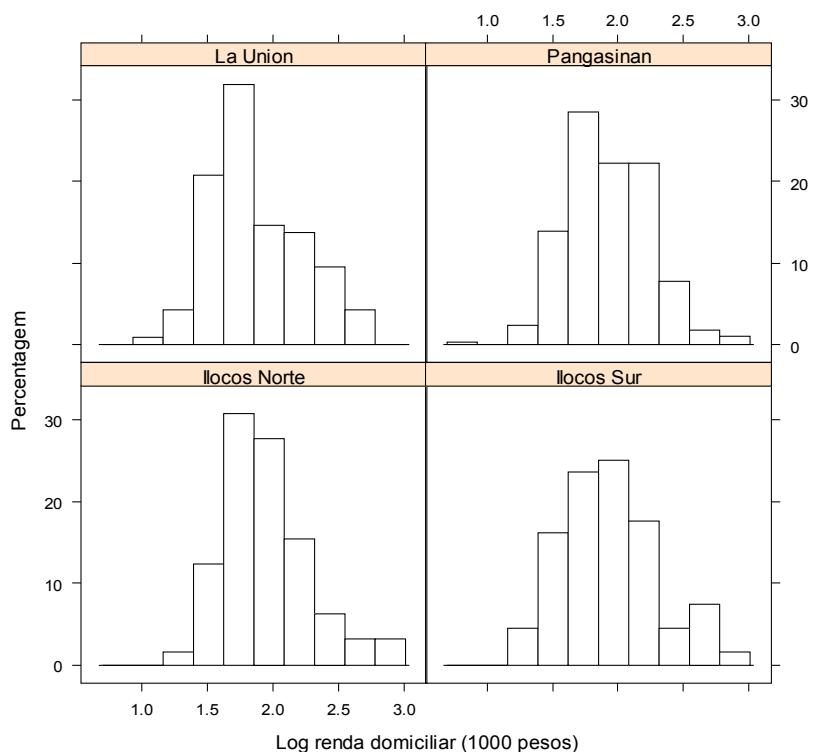


9.3 Variáveis quantitativas e qualitativas

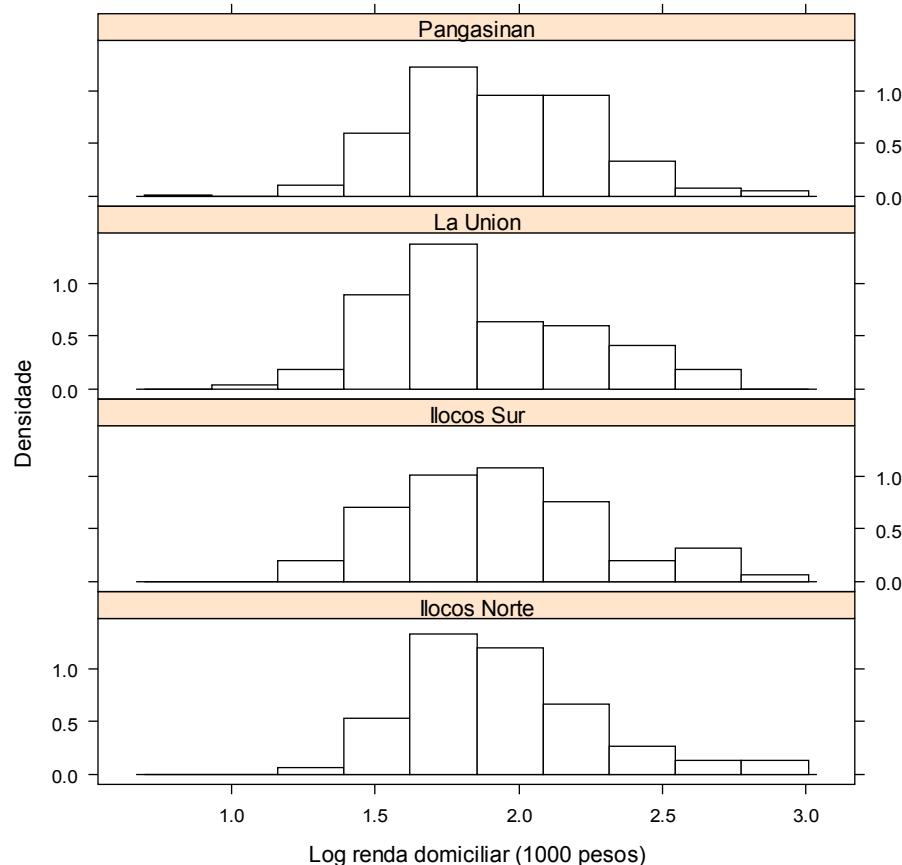
Histograma

Função `histogram` (`lattice`)

```
> histogram(~ log(income /  
1000, 10) | province, type =  
"percent", ylab =  
"Percentagem", xlab = "Log  
renda domiciliar (1000 pesos)",  
col = "white")
```



```
> histogram(~ log(income /  
1000, 10) | province, type =  
"density", layout = c(1,  
length(levels(province))), ylab =  
"Densidade", xlab = "Log  
renda domiciliar (1000 pesos)",  
col = "white")
```

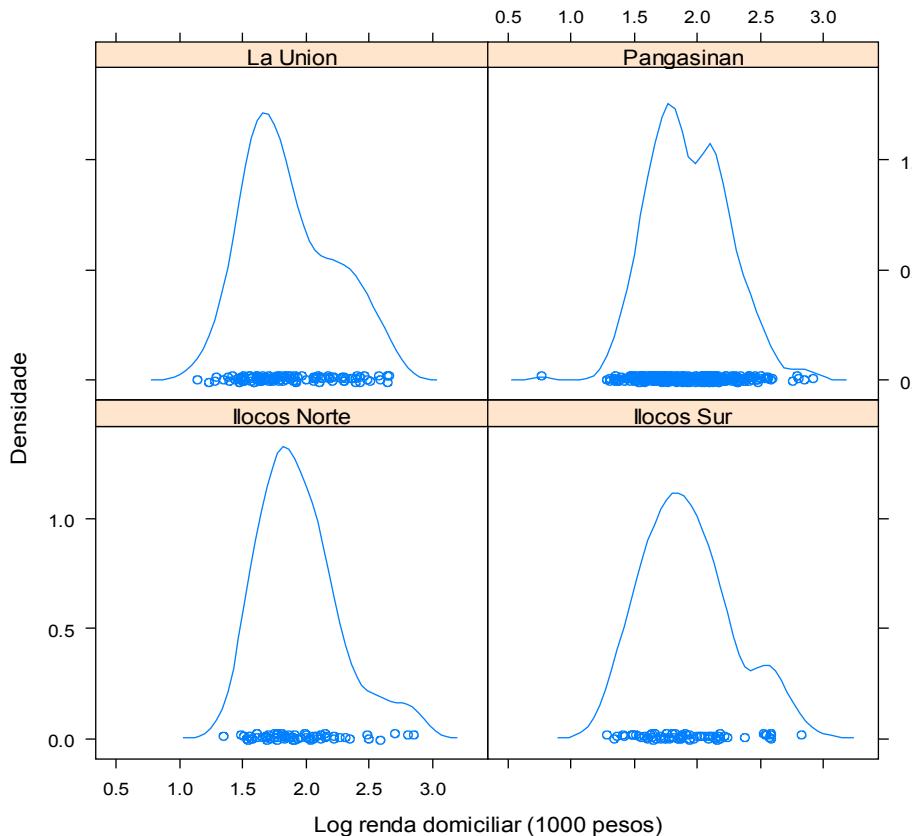


9.3 Variáveis quantitativas e qualitativas

Gráfico de densidade

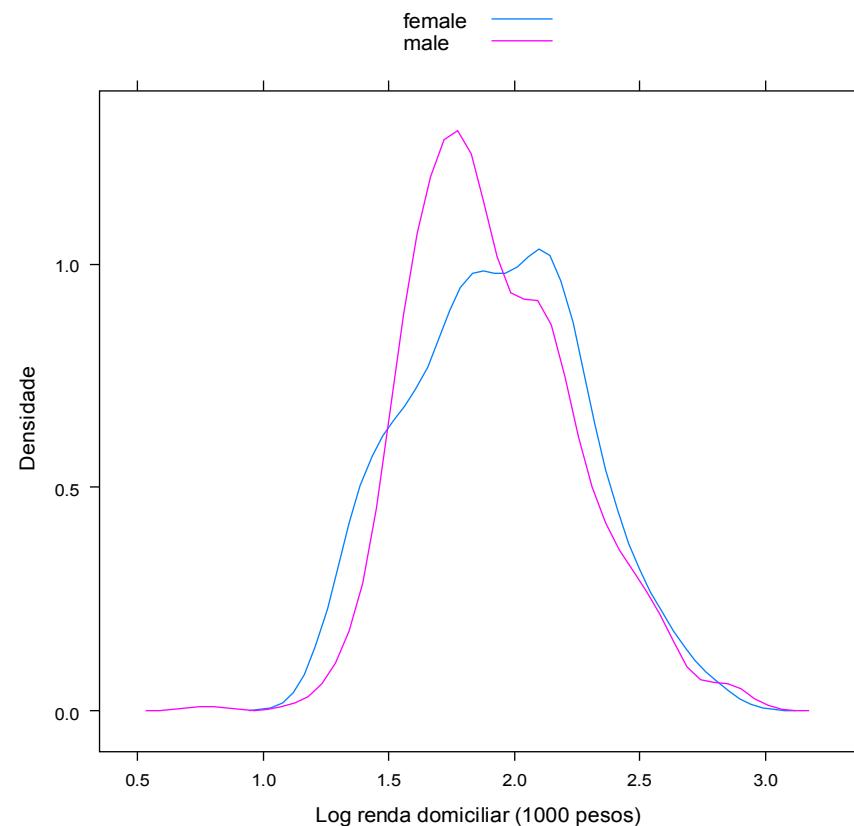
Função `densityplot(lattice)`

```
> densityplot(~ log(income /  
1000, 10) | province, ylab =  
"Densidade", xlab = "Log renda  
domiciliar (1000 pesos)")
```



Grupos em um só painel

```
> densityplot(~ log(income /  
1000, 10), groups = sex, ylab =  
"Densidade", xlab = "Log renda  
domiciliar (1000 pesos)",  
plot.points = FALSE, auto.key =  
TRUE)
```



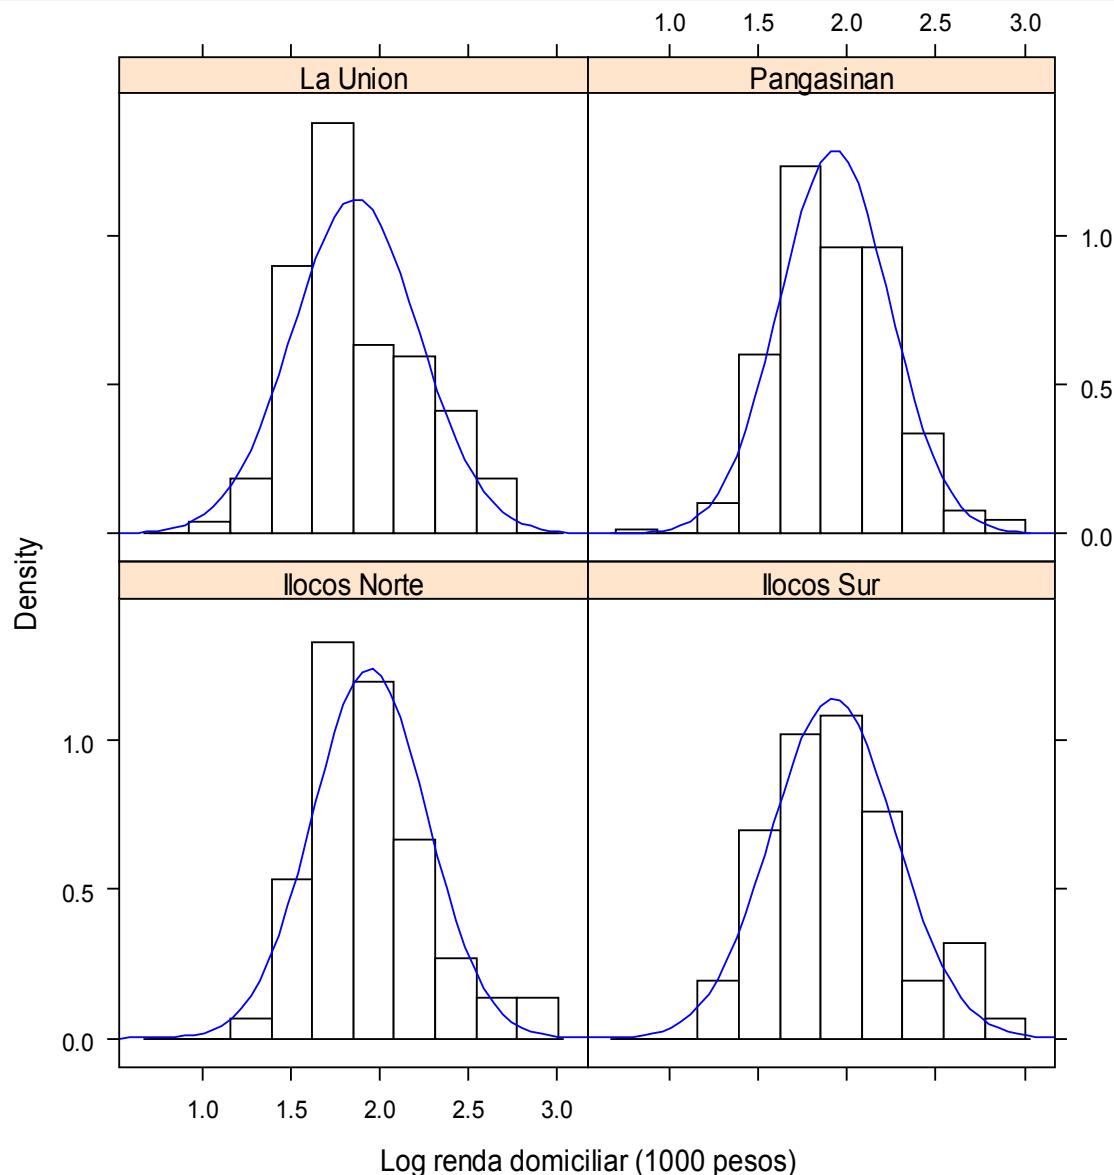
9.3 Variáveis quantitativas e qualitativas

Histograma e função densidade normal

```
> histogram(~ log(income / 1000, 10) | province,
  type = "density",
  ylab = "Densidade",
  xlab = "Log renda
domiciliar (1000
pesos)", col = "white",
  panel = function(x,
  ...)
  { panel.histogram(x,
  ...)
  panel.mathdensity(dmath
= dnorm, col = "blue",
  args = list(mean =
mean(x), sd = sd(x)))) })
```

Exercícios.

1. Substituir a função densidade normal pela densidade estimada.
2. Incluir os pontos no eixo horizontal.

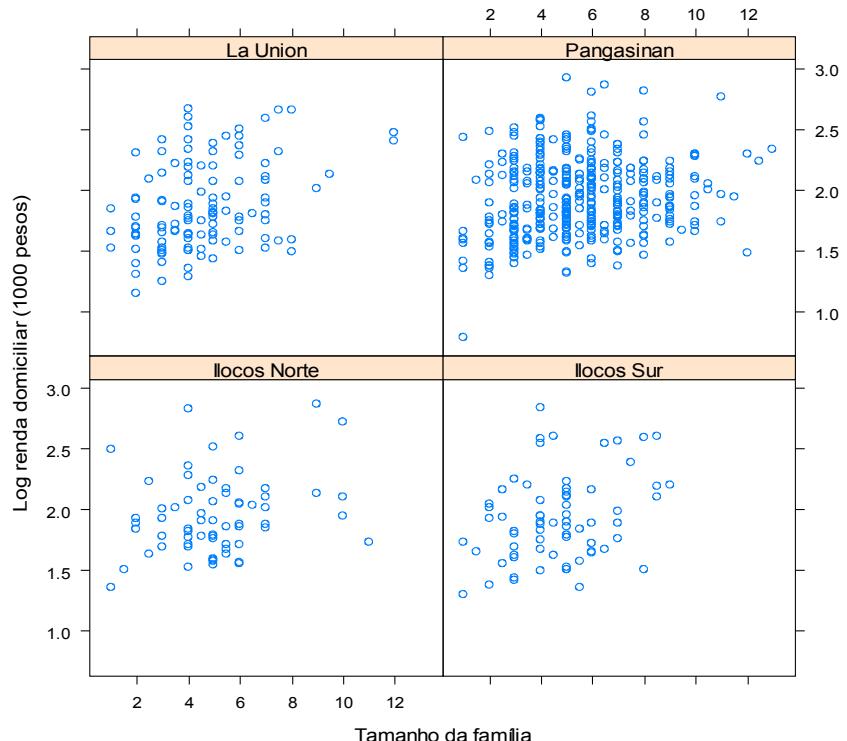


9.3 Variáveis quantitativas e qualitativas

Gráfico de dispersão

Função `xyplot` (lattice)

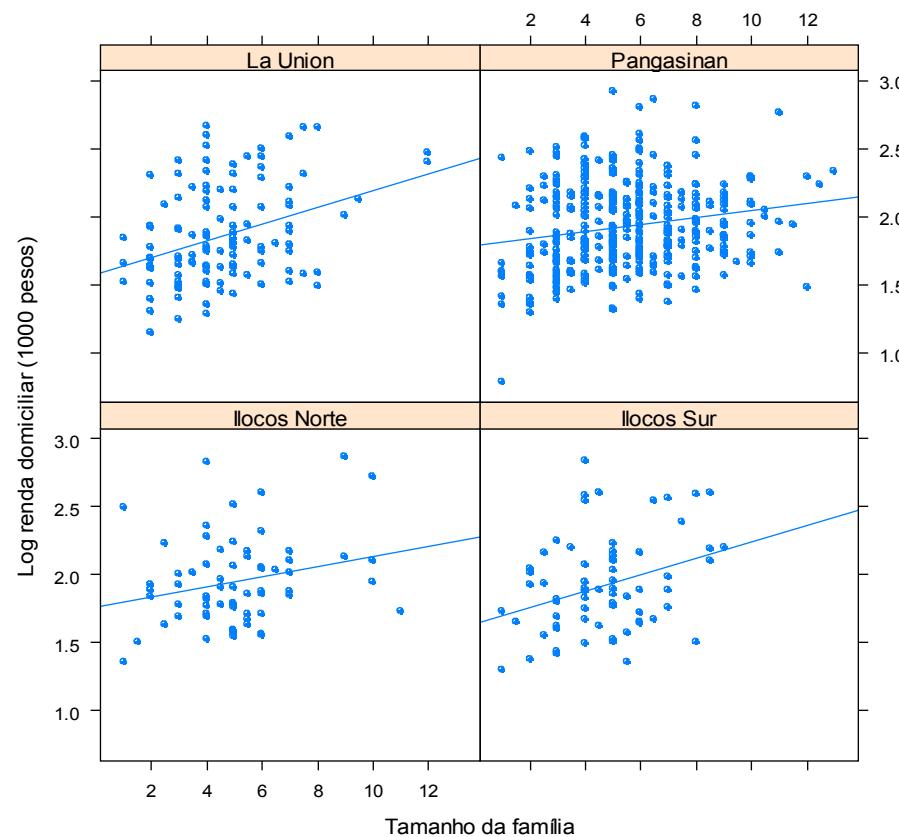
```
> xyplot(log(income / 1000, 10) ~ family.size | province, xlab =  
= "Tamanho da família", ylab =  
"Log renda domiciliar (1000 pesos)")
```



Exercício. Substituir as retas ajustadas por linhas de tendência.

Gráfico com pontos (p) e reta ajustada (r)

```
> xyplot(log(income / 1000, 10) ~ family.size | province, xlab =  
= "Tamanho da família", ylab = "Log  
renda domiciliar (1000 pesos)", pch = 20, type = c("p", "r"))
```

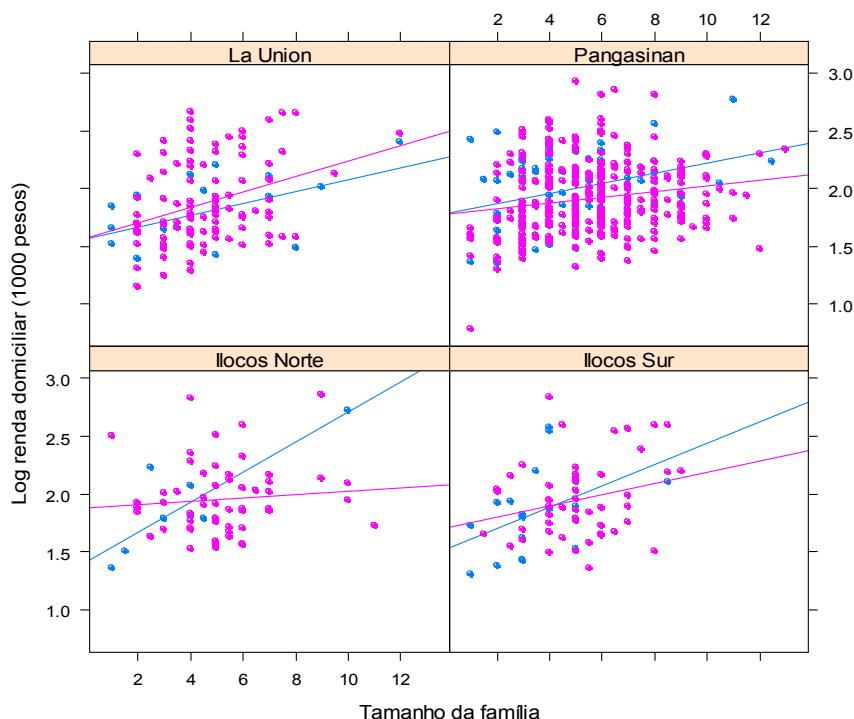


9.3 Variáveis quantitativas e qualitativas

Grupos de acordo com a variável sex

```
> xyplot(log(income / 1000, 10) ~ family.size | province, group = sex, auto.key = TRUE, xlab = "Tamanho da família", ylab = "Log renda domiciliar (1000 pesos)", pch = 20, type = c("p", "r"))
```

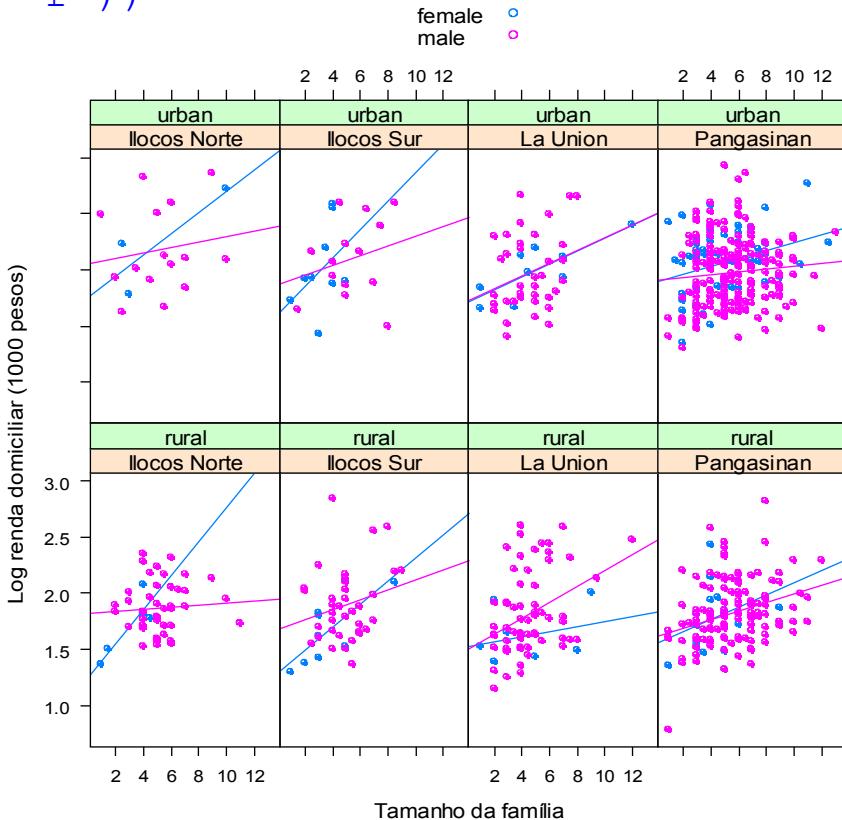
female
male



Duas variáveis condicionantes

```
> xyplot(log(income / 1000, 10) ~ family.size | province + urbanity, group = sex, auto.key = TRUE, xlab = "Tamanho da família", ylab = "Log renda domiciliar (1000 pesos)", pch = 20, type = c("p", "r"))
```

female
male

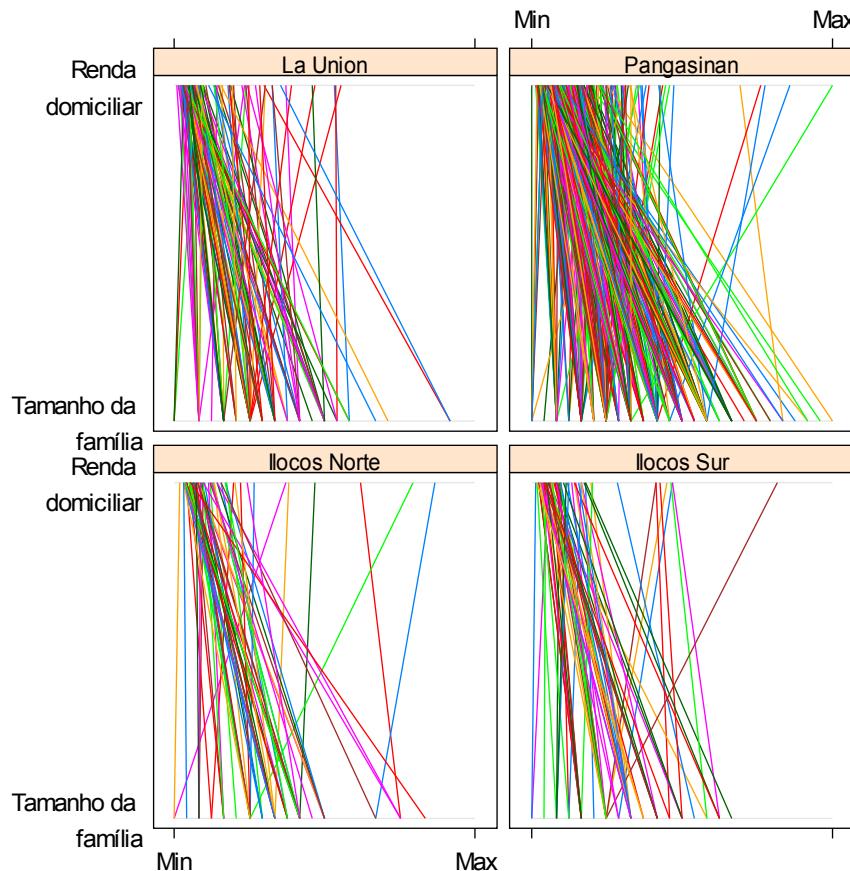


9.3 Variáveis quantitativas e qualitativas

Gráfico de coordenadas paralelas

Função `parallel` (lattice)

```
> parallel(~ cbind( family.size,
+ income) | province, varnames =
+ c("Tamanho da \nfamília",
+ "Renda\ \n domiciliar"))
```



Duas variáveis condicionantes

```
> parallel(~ cbind(family.size,
+ income) | province + urbanity,
+ varnames = c("Tamanho da \nfamília",
+ "Renda domiciliar"))
```

