UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE MATEMÁTICA
Cadernos de Matemática e Estatística
Série B: Trabalho de Apoio Didático

INTRODUÇÃO À ANÁLISE DE DADOS

UTILIZANDO O PROGRAMA SPSS

Jandyra Maria Guimarães Fachel

Suzi Alves Camey

Série B, Número 73
Porto Alegre - Julho de 2009

ÍNDICE

1. INTRODUÇÃO À ANÁLISE DE DADOS

INTRODUÇÃO

TIPOS DE VARIÁVEIS

As variáveis podem ser **quantitativas ou qualitativas.**

Variáveis quantitativas são as variáveis medidas com escalas com alguma unidade de medida.

Exemplos:
- Renda Familiar (unidade de medida: salários mínimos ou Reais);
- Idade (unidade de medida: anos ou meses de vida);
- Distância entre cada município e a capital do estado (unidade de medida: km);
- Faturamento de uma empresa (unidade de medida: reais, dólares)
- Número de empregados em uma empresa (unidade de medida: n° de pessoas)

Variáveis categóricas ou qualitativas são as variáveis medidas através de categorias ou classes às quais se atribuem códigos numéricos. As variáveis qualitativas podem ser:
- nominais (sem ordem entre as categorias)
-ordinais (com ordem entre as categorias).

Exemplos:
- Sexo (masculino e feminino)
- Profissão (Profissional liberal, empresário, funcionário público, empregado, etc.)
- Nível salarial (Baixo, Médio e Alto)
- Satisfação com o curso (Baixa, Média e Alta)
- Classe social (alta, média e baixa ou classe A, B, C, D, E)

Exercício: dê outros exemplos e classifique-os em quanti/quali e também classifique as qualitativas em nominais/ ordinais, incluindo os exemplos acima.

Observação Importante: as variáveis quantitativas sempre podem ser categorizadas, criando-se classes ou categorias.

Exemplo: posso tornar a variável Renda em uma variável categórica da seguinte forma:

Renda:	até 5 sal	(renda baixa)
	de 5,1 até 15 sal	(renda média baixa)
	de 15,1 sal até 40 sal	(renda média alta)
	mais de 40 sal	(renda alta).

No entanto, uma vez obtida a informação sobre Renda (no questionário, p.ex.) nós não podemos mais tornar a variável Renda uma variável quantitativa e, portanto, cálculos estatísticos com esta variável devem ser apenas os utilizados para variáveis categóricas. É sempre preferível obter a informação originalmente como uma variável quantitativa (sempre que possível!) e depois categorizá-la para apresentação e análise dos dados.

Exercício: Dê exemplos de outras variáveis quantitativas que podem ser categorizadas.

Observação Importante:
Há escalas que são categóricas na sua origem, como, por exemplo, as Escala de Likert cujas respostas são do tipo:
1. Concordo plenamente
2. Concordo
3. Não tenho opinião
4. Discordo
5. Discordo plenamente

No entanto, alguns autores tratam estas variáveis como variáveis quantitativas supondo que a opinião ou constructo que está sendo medido, e que está subjacente ao ítem a ser respondido, é uma variável contínua.

LEMBRETES IMPORTANTES

1) As técnicas estatísticas para análise de dados dependem do nível de medida das variáveis.

2) Não podemos calcular médias de variáveis categóricas, como, por exemplo, sexo, profissão, religião, etc. Desta forma, suponha que você solicite ao programa estatístico por descuido que calcule a média de todas as variáveis, o programa vai fornecer uma média numérica para variáveis categóricas inclusive, mas este valor não tem sentido nenhum, é apenas uma média dos códigos das categorias.

3) Sempre codifique suas variáveis numéricamente, pois isto torna mais fácil a análise de dados no computador, visto que variáveis alfanuméricas não são disponibilizadas em todas as opções de análise do SPSS.

4) Para digitar seus dados use o EXCEL, pois tem interface com os programas de Estatística mais usuais, como o SPSS, SAS, STATISTICA, STATA e SPHINX.

5) Ao elaborar o questionário, coloque sempre junto com a alternativa de resposta, o código que será usado na digitação (isto economizará tempo de digitação, não sendo necessário consulta a uma folha de códigos para cada questão e para cada questionário).

ANÁLISE DE DADOS (COMO FAZER A ANÁLISE ESTATÍSTICA?)

a) <u>ANÁLISE UNIVARIADA</u>: analisando cada variável separadamente.

Para **VARIÁVEIS QUANTITATIVAS**:

Estatísticas Descritivas (média, moda, mediana, desvio-padrão, etc.)

Gráficos (histogramas, *box-plots*)

Para **VARIÁVEIS QUALITATIVAS/ CATEGÓRICAS**:

Tabelas de Frequências e Percentagens

Gráficos (gráfico de setores ou pizza (pie), ou gráficos de colunas)

b) ANÁLISE BIVARIADA: analisando a relação de duas variáveis conjuntamente

Para **DUAS VARIÁVEIS QUANTITATIVAS**:
Coeficiente de Correlação de Pearson
Análise de Regressão Simples
Gráficos: *Scatterplot* de X e Y

Para **DUAS VARIÁVEIS QUALITATIVAS**:
Medir Associação pelo Teste Qui-Quadrado e Análise dos Resíduos
Análise Fatorial de Correspondência
Gráfico de Colunas por estratos da segunda variável.

Para **UMA VARIÁVEL QUANTITATIVA E UMA QUALITATIVA**:
Categoriza-se a variável quantitativa e procede-se como no ítem anterior.
Gráficos: *Box-Plots* para cada estrato ou categoria da variável qualitativa.

c) ANALISANDO CONJUNTAMENTE VÁRIAS VARIÁVEIS

- Quando todas as variáveis são **quantitativas** e uma variável é considerada como a **variável dependente** ou variável resposta do estudo e as outras variáveis são as variáveis explicativas ou variáveis independentes, a técnica adequada é a técnica de REGRESSÃO LINEAR MÚLTIPLA.

- Quando todas as variáveis são **quantitativas** e queremos apenas estudar o inter-relacionamento entre as variáveis e definir se existe um número menor de fatores, ou de dimensões latentes, determinando as inter-correlações entre as variáveis, as técnicas adequadas são ANÁLISE FATORIAL ou ANÁLISE DE COMPONENTES PRINCIPAIS. (Estas duas técnicas não serão objeto de estudo neste curso). Esta área da Estatística denomina-se Análise Multivariada.

d) COMPARANDO GRUPOS

- Comparando a média de uma variável quantitativa entre **dois grupos independentes:**
Teste t de Student para amostras independentes.

- Comparando a média de uma variável quantitativa entre **dois grupos relacionados** ou emparelhados (p.ex. casais, pares de empresas emparelhadas pelo tamanho, ou nas situações antes/depois, pré e pós-teste, etc):
Teste t de Student para amostras relacionadas ou emparelhadas (*paired*)

- Comparando a média de uma variável quantitativa entre **três ou mais grupos independentes:**
Análise de Variância para um fator (ANOVA *one-way*), seguido de uma análise de comparações múltiplas de médias.

ANÁLISE QUANTITATIVA VERSUS ANÁLISE QUALITATIVA (QUALI/QUANTI)

- Atualmente existem técnicas sofisticadas para tratar dados qualitativos da mesma forma como já existiam técnicas para a análise de dados quantitativos.

- Com o auxílio da informática é possível sintetizar a informação qualitativa (Análise de Discurso, **Dados Textuais** / Textos, Entrevistas, Questões Abertas, Observação Participante, Dados Etnográficos, etc) e dar um tratamento mais objetivo para estas análises, sem o trabalho manual existente num passado recente.

- Em resumo, os dados textuais passam a ser objeto também de análises estatísticas, mantendo-se o máximo possível a riqueza dos dados qualitativos.

PROGRAMAS DE COMPUTADOR PARA ANÁLISE DE DADOS TEXTUAIS:

SPHINX (Moscarola,J. - França)
SPADT (Lebart, L. - França)
ETNOGRAPHICS (USA)

ESTATÍSTICAS DESCRITIVAS

Distribuição de Frequência e Gráficos Estatísticos

a) Para dados quantitativos:

Quando os dados são quantitativos não é usual representá-los por uma distribuição de frequência bruta, é necessário antes agrupá-los em faixas numéricas ou classes e então apresentar a distribuição de frequências e percentuais das classes. Podemos também representá-los através de gráficos denominados Histogramas.

b) Para dados qualitativos/ categóricos:

No caso de dados categóricos podemos apresentar os dados através de distribuição de frequências brutas ou percentuais e o gráfico mais usual é o gráfico de pizza. Os gráficos de coluna ou barras também são utilizados.

Medidas de Tendência Central de uma Variável:

a) Para dados quantitativos:

Média - valor médio dos dados brutos. É obtida somando-se todos os valores obtidos na amostra e dividindo-se esta soma pelo número de observações.

Moda - é o valor mais frequente do conjunto de dados para cada variável.

Mediana - é o valor do conjunto de dados ordenados que divide a distribuição de frequências em duas partes: 50% do total de dados abaixo da mediana e 50% acima da mediana.

b) Para dados categóricos/ qualitativos:

Media - Atenção! Não é possível calcular a média de dados categóricos: os números são apenas códigos.

Moda - é a categoria mais frequente. Pode haver mais de uma moda, ou não ter nenhuma categoria mais frequente que as outras.

Mediana - só pode ser calculada se as variáveis são ordinais. É a categoria que divide os dados ordenados em duas partes iguais, 50% abaixo e 50% acima do valor da mediana.

Medidas de Variabilidade:

a) Para dados quantitativos:

Variância / Desvio-Padrão; Coeficiente de Variação
(conceitos a serem apresentados em aula, através de exemplos intuitivos)

b) Para dados categóricos/ qualitativos:

Desvio Inter-Quartílico (idem)

INFORMAÇÕES SOBRE O ARQUIVO DE DADOS PARA EXEMPLIFICAR A ANÁLISE ESTATÍSTICA

Nome do arquivo: 'EMPLOYEE.SAV' DO SPSS

VARIÁVEIS:

SEX - sexo dos empregados
AGE - Idade dos empregados
SEXRACE - classificação conjunta de sexo e raça
SALBEG - salário inicial (em dólares)
SALNOW - salário atual (em dólares)
EDLEVEL - nível educacional (em anos de educação)
WORK - experiência na função (em anos)
TIME - tempo de trabalho (em anos)
JOBCAT - categoria de trabalho (função na empresa)
MINORITY - raça do respondente (branco ou não-branco)

EXERCÍCIOS: Para fixar os comandos do SPSS é fundamental APRENDER FAZENDO! Então fazer:
1) Distribuição de frequência da variável NIRMAOS - número de irmãos; Histograma e estatísticas descritivas da variável NIRMAOS (Página 14).

2) Análise exploratória dos dados da variável NIRMAOS, mostrando as estatísticas descritivas, um gráfico estilizado, denominado Gráfico de ramos-e-folhas (Stem & Leaf), uma análise dos casos extremos e/ou valores atípicos (*outliers*) e finalmente um gráfico denominado *BOX-PLOT*.

3) Tabela de contingência ou tabela de frequência cruzada (bivariada) das variáveis RENDA e Satisfação com o Emprego (SATISF). A tabela apresenta os valores das frequências brutas (contagens) e os valores de frequências percentual, neste caso, percentual por linha da tabela, ou seja, pelos totais das categorias de Renda. A análise também mostra o resultado do TESTE QUI-QUADRADO com Análise de Resíduos. Este teste estatístico é utilizado, neste exemplo, para testar se existe ou não relação ou associação significante entre a Renda e Satisfação com o Emprego.

4) Os dados da tabela de contingência da análise bivariada entre Renda e Satisfação com o Emprego são analisados através da ANÁLISE DE CORRESPONDÊNCIA, que mostra gráficamente a relação ou associação entre as categorias das variáveis: Renda e Satisfação com o Emprego.

5) Tabela de Contingência eTeste Qui-quadrado para as variáveis SEXRACE e SALARIO para a amostra de 474 empregados de empresas americanas. A variável SALARIO encontra-se categorizada em 4 categorias (Baixo, Médio Baixo, Médio Alto e Alto). A tabela apresenta também as frequências esperadas (Expected Values) sob hipótese de independência entre as variáveis. O teste qui-quadrado deve ser usado preferencialmente quando não mais do que 25 % das caselas tiverem frequências esperadas menor do que 5.

6) Coeficiente de correlação entre Nível Educacional (EDLEVEL) e Salário Atual (SALNOW), a saída mostra a matriz de correlação entre estas duas variáveis. Cada casela da matriz mostra o coeficiente de correlação de Pearson, o número de casos e o nível de significância associado ao coeficiente de correlação observado. A seguir mais um exemplo da aplicação do Teste Qui-quadrado, mostrando a associação entre Raça (MINORITY) e Salário (SALARIO). A variável SALARIO encontra-se categorizada em 4 categorias (Baixo, Médio Baixo, Médio Alto e Alto).

7) Teste t de Student para comparar a média de salário inicial (SALBEG) entre os dois grupos de sexo (teste t para amostras independentes) e Teste t de Student para comparar as médias do Salário Atual (SALNOW) entre as duas categorias de Sexo (SEX). Nestas análises aparece também um teste de comparação entre as variâncias dos dois grupos que é necessário para escolher qual o resultado do teste t que devemos analisar. Se as variâncias forem iguais ($p>0,05$), vamos para a linha do EQUAL, mas se as variâncias são diferentes ($p<0,05$), então o resultado do teste t deve ser visto na linha do UNEQUAL.

8) Teste t para amostras relacionadas ou emparelhadas. Neste exemplo queremos comparar as médias do salário inicial (antes) com o salário atual (depois). Neste caso, o saláro inicial e o salário atual formam pares de observações que são relacionadas por serem salários do mesmo sujeito.

9) Tabela de frequência simples da variável SEXRACE, que é uma variável única constuída a partir das variáveis Sex e Minority (são as combinações das categorias das duas variáveis).

10) Teste de comparação de médias da variável Salário Atual (SALNOW) entre os quatro grupos formados pela variável SEXRACE. Este teste estatístico denomina-se Análise de Variância (ANOVA) com um fator (ONEWAY). Apresentamos também um teste de comparação múltipla entre as médias para verificarmos quais grupos diferem significativamente em salário.

11) Análise de Regressão Linear Simples entre as variáveis SALNOW (variável dependente ou variável explicada) e a variável: Nível Educacional (EDLEVEL) que é a variável escolhida como variável independente ou explicativa.

12) Análise de Regressão Linear Múltipla entre a variável dependente Salário Atual (SALNOW) e as variáveis independentes EDLEVEL e SALBEG (Páginas 25 e 26).

13) Análise de Regressão Múltipla entre a variável SALNOW e várias variáveis explicativas: EDLEVEL, SALBEG, TIME, WORK.

14) Análise de Regressão Múltipla idêntica a anterior, mas incluindo a variável Idade (AGE) como mais uma variável independente. Observe a alteração na significância dos coeficientes de regressão das demais variáveis. Todos estes exemplos de Análise de Regressão fazem parte de um processo que em Estatística chama-se MODELAGEM. Estamos tentando criar um modelo (o melhor modelo) para explicar a variável: Salário Atual. Quais são verdadeiramente as variáveis que influem na definição do salário atual do empregado, com vistas à predição de salários de novos empregados?

15) Exemplos de Testes Não-Paramétricos:

-Teste de Mann-Whitney ou Teste da Soma de Postos de Wilcoxon, que é utilizado para variáveis ordinais, comparando médias entre dois grupos (ou postos/ ranks médios). Comparamos as médias de Nível Educacional (EDLEVEL) entre os dois grupos da variável Sexo.

-Teste de Kruskal-Wallis, que é a alternativa não paramétrica para Análise de Variância com um fator (oneway). No caso, comparamos as médias do nível educacional entre os quatro grupos de Sexrace.

2. INTRODUÇÃO AO SPSS

O pacote estatístico **SPSS** (Statistical Package for Social Sciences) é uma ferramenta para análise de dados utilizando **técnicas estatísticas** básicas e avançadas. É um software estatístico de fácil manuseio, internacionalmente utilizado há muitas décadas, desde suas versões para computadores de grande porte.

Tela inicial do *SSPS 16.0 for Windows.*

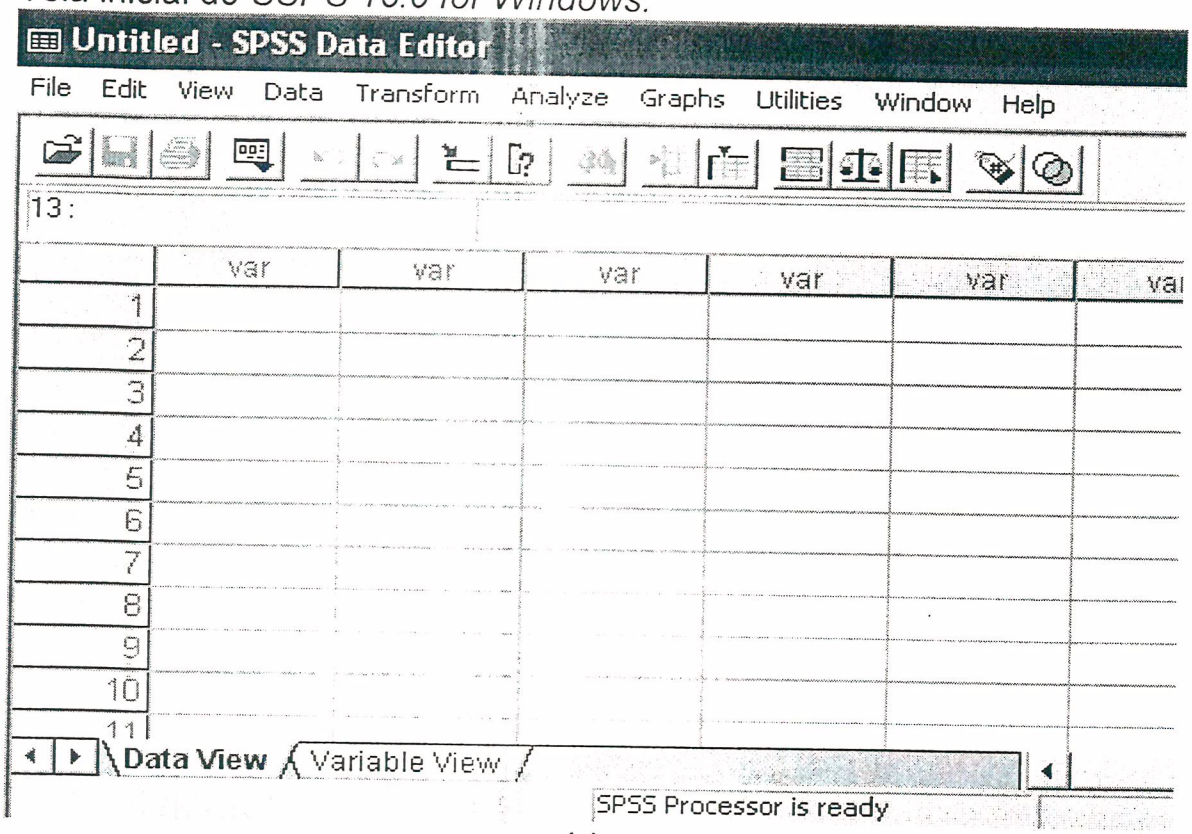

(a)

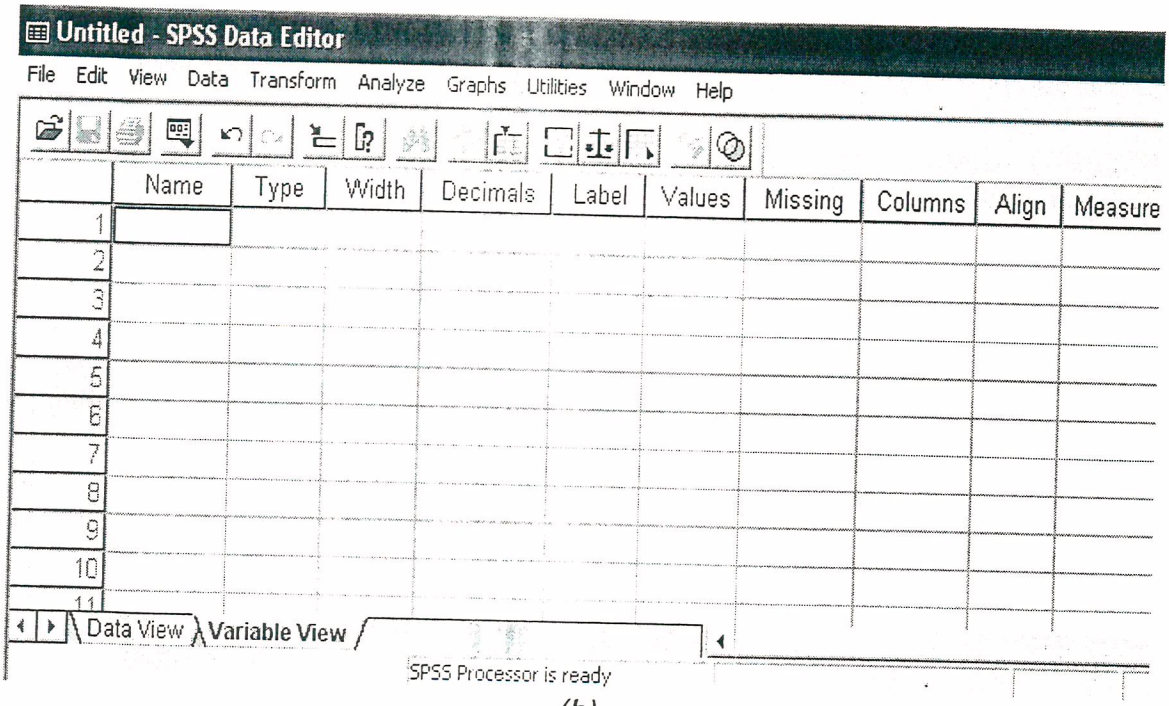

(b)

Figura 1: Tela inicial do *SSPS 16.0 for Windows. 1(a): Planilha Data View; 1(b): Planilha Variable View.*

BANCO DE DADOS: Definição

Banco de dados é um conjunto de dados registrados em uma planilha, em forma de matriz, com n linhas, correspondentes aos casos em estudo e p colunas, correspondentes às variáveis em estudo ou itens de um questionário.

O número de casos (número de linhas da matriz) deve ser, em geral, **maior** do que o número de variáveis em estudo (número de colunas).

COMO CRIAR UM BANCO DE DADOS

Para criar um BANCO DE DADOS novo procede-se da seguinte forma:

a) Clicar em **File**; **New**; **Data.** Aparece a planilha de dados. Na primeira linha estão indicadas as posições das variáveis (VAR001,

VAR002, etc.), e uma margem vertical numerada a partir de **1** (como mostrado na Figura1a).

b) Na primeira coluna, correspondendo à VAR001, vamos criar uma variável, por exemplo, NumCaso com o número do questionário ou do caso em estudo.

c) Para registrar as características da variável, clicar **duas vezes** sobre o nome da coluna. Aparece a planilha **variable view** na qual cada variável está definida em uma linha.

d) Na primeira coluna (**Name)** digitar o nome da variável (NumCaso). Para o nome das variáveis utilize 8 dígitos no máximo, não utilize espaço em branco nem os símbolos -, . e /.

e) Clicar na coluna **Type** para definir o tipo de variável, aparece a janela **Variable Type** onde se deve deixar a opção **Numeric.** Se a variável for alfa-numérica (texto) escolha a opção **String**. Preferencialmente use sempre a modalidade Numeric para variáveis categóricas, como por exemplo, sexo, estado civil, município, etc. criando-se um código para as categorias.

f) No caso de não-resposta ou respostas que não desejamos considerar para o tratamento estatístico, como por exemplo, respostas não corretas, etc..., clicar na coluna **Missing**, abre-se a janela (**Missing Values**), registrar, na opção **Discrete Missing Values,** o código de não-resposta. Clicar em **OK.** A melhor opção para não resposta é deixar o espaço em branco no banco de dados.

g) Retornar à planilha de **dados** e passar a digitar, em cada linha da coluna identificada, o valor da variável.

h) À medida que o BANCO DE DADOS vai sendo registrado é importante salvar as informações digitadas, para tanto se procede da seguinte forma: Clicar em **File**, **Save as** (abre-se a janela do caminho desejado) e criar um nome para o Banco de dados, que terá automaticamente a terminação **.sav**.

COMO DAR NOME AOS NÍVEIS DE UMA VARIÁVEL

É conveniente registrar no banco de dados os nomes das categorias de variáveis categóricas. Por exemplo, para a variável **sexo,** os códigos poderiam ser: 1 = masculino e 2 = feminino. Para registrar estes nomes, clicar **2 vezes** sobre a variável **sexo**, abrindo a planilha **Variable View** e proceder da seguinte forma:

a) Clicar em **Values**. Abre-se a janela **Value Labels**:
b) Em **Value**, digitar **0**;
c) Em **Value Label**, digitar masculino;
d) Clicar em **ADD**;
e) Procede-se da mesma forma para os demais níveis de categorização: digitar **1** para **Value** e feminino para **Value Label**, seguindo-se por **ADD**
f) Clicar em **OK**.

OBSERVAÇÃO:
A manipulação do BANCO DE DADOS nos permite:
- Criar e recodificar variáveis;
- Realizar análise de dados através de estatísticas descritivas, gráficos, etc;
- Selecionar casos para análise, repetir a análise para grupos de casos diferentes.

É importante dar-se ao arquivo o nome mais claro possível para facilitar sua localização e acesso. Os arquivos de dados são do tipo **. sav**

RECOMENDAÇÃO: A primeira coluna da matriz deve corresponder ao número do questionário, número do caso, ou ainda código do registro, pois facilita a localização de informações no caso de serem identificados equívocos de digitação.

COMO ACESSAR UM BANCO DE DADOS JÁ EXISTENTE

Para acessar um banco de dados já existente, procede-se da seguinte maneira:

a) Iniciar o programa **SPSS** (clicar 2 vezes sobre o ícone);
b) Clicar em **File**, **Open**, **Data**, abrir o arquivo que se deseja. Usaremos como exemplo o arquivo chamado **World95.sav** que se encontra disponível junto com o programa SPSS.

3. INTRODUÇÃO AOS MÉTODOS ESTATÍSTICOS

Um primeiro passo para analisar qualquer banco de dados é analisar uma por uma das variáveis (o que será denominado de **análise univariada**). Se as variáveis são quantitativas usamos estatísticas descritivas (média, desvio padrão, valor mínimo, valor máximo) ou gráficos (ex: histograma). Se as variáveis são qualitativas usaremos tabelas de freqüência ou gráficos (ex: de setores, também conhecido como pie, barra).

OBSERVAÇÃO:
Não podemos calcular média, variância ou desvio-padrão de variáveis qualitativas ou variáveis categóricas.

COMO CATEGORIZAR UMA VARIÁVEL QUANTITATIVA

Para exemplificar usaremos uma variável categorizada utilizando quartis. Os quartis são pontos de corte na escala da variável de tal forma que, cada grupo formado a partir destes pontos de corte terá um quarto dos casos, ou seja, 25% do tamanho total da amostra.

Os passos necessários para categorizar uma variável utilizando os quartis são os seguintes:

1. Calcular os quartis da variável em questão, neste caso, População **(population):**

a) Clicar em **Analyze**, **Descritive Statistics**, **Frequencies**;
b) Selecionar a variável que se deseja categorizar na janela esquerda e clicar →;
c) Retirar a opção de **Display Frequency Tables**, a fim de que não venha listada a totalidade de casos da variável (no estudo em pauta o número é de 109 casos);
d) Clicar em **Statistics** e assinalar **Quartiles**;
e) Clicar em **Continue**; **OK**.

RESULTADOS:

Frequencies

Statistics

Population in thousands

N	Valid	109
	Missing	0
Percentiles	25	5000,00
	50	10400,00
	75	37100,00

2. Criar uma variável com 4 categorias, definidas pelos quartis, da seguinte maneira:

Categoria	Intervalo de valores
1	Mínimo até 5000,00
2	5001,00 até 10400,00
3	10401,00 até 37100,00
4	37101,00 até o Máximo no Banco de Dados

Para categorizar a variável **population**, usando os limites dados pelos quartis procede-se da seguinte forma:

a) Clicar em **Transform**, **Recode**, **Into Different Variables**;
b) Localizar, na janela à esquerda, a variável a ser categorizada (**population**) e clicar na →;
c) Digitar um novo nome para a variável de saída (**Output Variable**), por exemplo, POPREC e clicar em **Change**;
d) Clicar em **Old and New Values**;
e) Clicar em **Range (lowest through)** e digitar o valor obtido para o primeiro quartil, no caso 5000,00;
f) Em **New Value**, digitar **1**;
g) Clicar em **ADD**;
h) Assinalar **Range**, colocando: 5001,00 até (Through) 10400,00 (segundo quartil);
i) Na opção **New Value**, digitar **2**;
j) Clicar em **ADD**;

k) Assinalar **Range**, 10401,00 até (Through) o terceiro quartil 37100,00;
l) Na opção **New Value**, digitar **3**;
m) Clicar em **ADD**;
n) Clicar em **Range (Through Highest)** e digitar o valor imediatamente superior ao 3º quartil, no caso 37101,00;
o) Na opção **New Value**, digitar **4**;
p) Clicar em **ADD**; **Continue OK.**

A nova variável **POPREC** corresponde à variável **populatn** categorizada, sendo esta automaticamente incluída no banco de dados que estamos utilizando (**World95.sav / Arquivo Data**).

COMO CRIAR UMA VARIÁVEL A PARTIR DE UMA DATA

Para criar uma variável, p.ex, Idade, a partir do ano de nascimento, utilizamos a função XDATE.YEAR (datevalue) a partir da variável data de nascimento, que no exemplo é **BDATE**:

a) Selecionar **Transform, Compute**;
b) Em **Target Variable** digite o nome da nova variável, por exemplo, AGE;
c) Na janela **Numeric Expression** digite 2001-;
d) Na janela **Functions** selecionar a opção XDATE.YEAR (datevalue) e clicar na ↑;
e) Localizar na janela abaixo de **Target Variable** a variável **bdate** e clicar na → (a variável selecionada deve ficar entre os parênteses);
f) Clicar em **OK**.

COMO CRIAR UMA VARIÁVEL ATRAVÉS DA COMBINAÇÃO DE OUTRAS DUAS

Nesta seção, será utilizado o banco **GSS93.sav**. Para criar uma variável a partir da combinação de outras duas, como, por exemplo, combinar a variável sexo (**sex**) e a variável raça (**race**) utilizaremos o seguinte procedimento para criar a variável SEXRACE.

Sabendo que a variável SEX é categorizada da seguinte forma:
1-Male e 2-Female
e a variável RACE é categorizada da seguinte forma:
1- White, 2-Black e 3-Other
pode-se criar a variável SEXRACE com as seguintes categorias:

1- White Male,
2- White Female,
3- Black Male
4- Black Female
5- Other Male
6- Other Female

Então se procede da seguinte forma:

a) Selecionar **Transform, Compute;**
b) Em **Target Variable** digite o nome da nova variável, por exemplo SEXRACE;
c) Na janela **Numeric Expression** digite 1;
d) Clicar em **if**;
e) Selecione a opção **Include if case satisfies condition**;
f) Localizar na janela abaixo de **Include if case satisfies condition** a variável desejada,
g) Após ter selecionado a variável (neste caso, **sex**), clicar na →;
h) Digitar =1 & na janela ao lado da variável **sex**;
g) Selecionar na janela ao lado a variável **race** e clicar na →;
h) Na janela ao lado da variável **race** digitar =1;
i) Após esse procedimento a expressão na janela deve ser a seguinte: sex=1 & race=1;
j) Clicar em **Continue** e **OK**, (a variável **SEXRACE** aparecerá no final do banco de dados),
k) Para criar as demais categorias da variável **SEXRACE** procede-se de maneira análoga, alterando o código na janela **Numeric Expression** para 2, 3, 4, 5 e 6 e a expressão da janela **Include if case satisfies condition.**

4. ANÁLISE UNIVARIADA

VARIÁVEIS QUANTITATIVAS

COMO OBTER AS ESTATÍSTICAS DESCRITIVAS

a) Clicar em **Analyze**, **Descriptive Statistics**, **Descriptives**;
b) Localizar na janela à esquerda a variável de interesse (por exemplo, mortalidade infantil) e clicar na →;
c) Clicar em **Options**, e assinalar as opções desejadas;
d) Clicar em **Continue**; **OK**;
e) Os resultados da análise estatística aparecem na janela de resultados (**OUTPUT**), que poderá ser salva, dando origem a um arquivo do tipo **.spo** (**SPSS output**) – nas versões até SPSS15. Nas versões a partir do SPSS, o arquivo de output tem a terminação **.spv. Para ler os outputs com terminação .spo na Versão 16 em diante deve-se usar o SPSS Viewer, que deve ser instalado juntamente com o programa.**

EXEMPLO:

Descriptives

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
Infant mortality (deaths per 1000 live births)	109	4,0	168,0	42,313	38,0792
Valid N (listwise)	109				

COMO OBTER UM HISTOGRAMA

a) Clicar em **Graphs**, **Histogram**
b) Localizar na janela a variável desejada,
c) Após ter selecionado a variável (neste caso, **babymort**), clicar na →;
d) Pode-se clicar na opção **Titles** para dar um título ao histograma.
e) Clicar em **OK**

EXEMPLO: Histograma da variável **Infant Mortality**

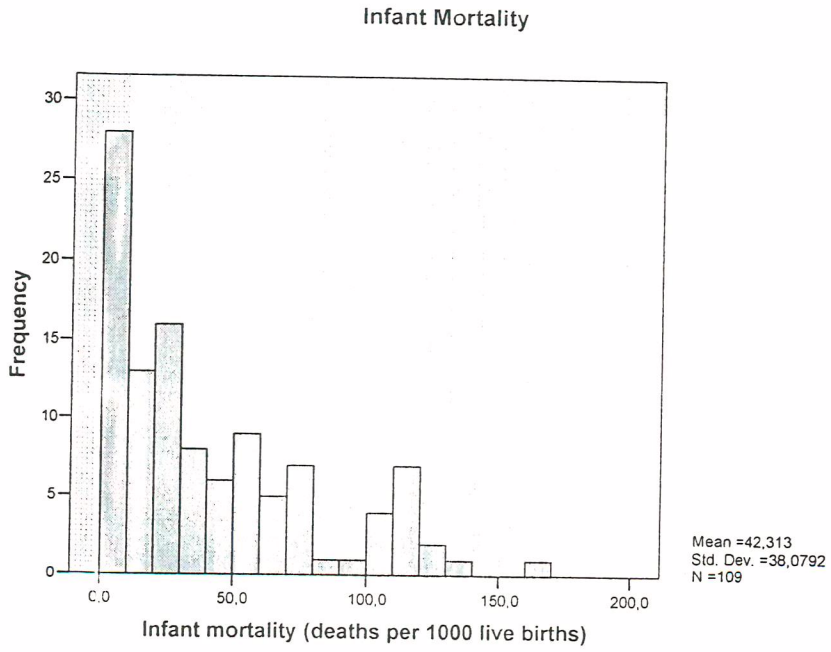

VARIÁVEIS CATEGÓRICAS (QUALITATIVAS)

COMO OBTER A DISTRIBUIÇÃO DE FREQÜÊNCIAS

a) Clicar em **Analyze**, **Descriptive Statistics**, **Frequencies**;
b) Selecionar a variável desejada (neste caso, **region**), clicar na →;
c) Selecionar **Display frequency tables**;
d) Clicar em **OK.**

RESULTADO:

Frequencies

Statistics

Region or economic group

N	Valid	109
	Missing	0

Region or economic group

		Frequency	Percent	Valid Percent	Cumulative Percent
Valid	OECD	21	19,3	19,3	19,3
	East Europe	14	12,8	12,8	32,1
	Pacific/Asia	17	15,6	15,6	47,7
	Africa	19	17,4	17,4	65,1
	Middle East	17	15,6	15,6	80,7
	Latn America	21	19,3	19,3	100,0
	Total	109	100,0	100,0	

COMO OBTER GRÁFICOS

a) Clicar em **Graphs**, selecionar o gráfico desejado, que ao salvá-lo, dá origem a um arquivo do tipo **.cht (Chart)** (arquivo de gráficos).

OBSERVAÇÃO:
Com variáveis categóricas, o adequado é fazer gráfico de setores (Pie), de Colunas...

EXEMPLO: Gráfico de Setores (Pie) para a variável **region**

a) Clicar em **Graphs**, selecionar **Pie**;
b) Selecionar a opção **Summaries for groups of cases** e clicar em **Define**;
c) Na opção **Define Slices by** selecionar a variável **region**.

RESULTADO:

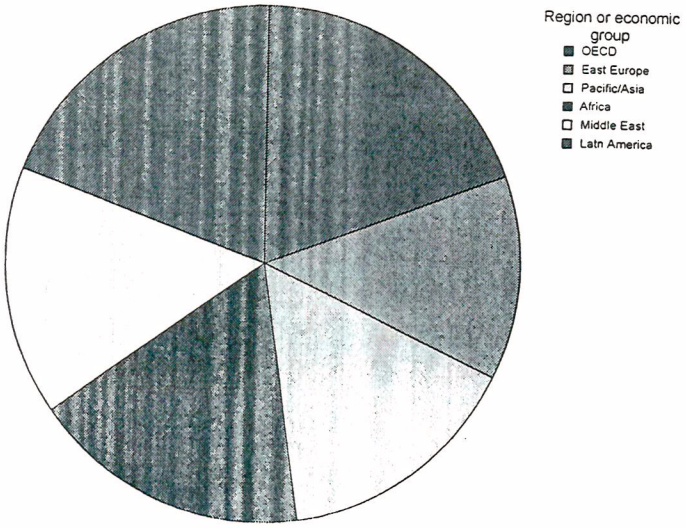

Para colocar o valor percentual de cada categoria no gráfico:

a) Clicar duas vezes no gráfico;
b) Abre o **SPSS Chart Editor**; clicar em **elements/show data labels**;
c) Na janela **properties,** em data value labels, selecionar **percents**;
d) Clicar **OK.**

RESULTADO:

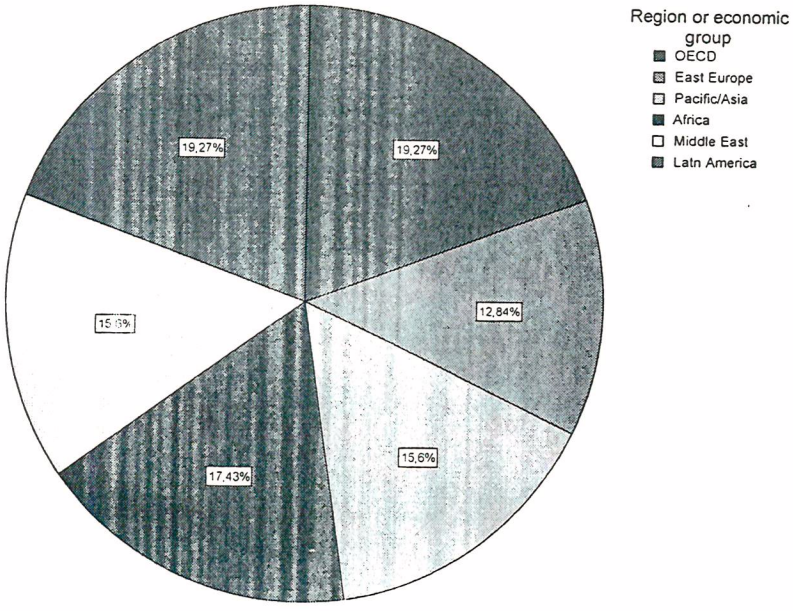

5. ANÁLISE BIVARIADA

Para realizar uma análise **bivariada**, ou seja, análise da relação entre duas variáveis, utilizam-se testes estatísticos e/ou gráficos adequados, conforme foi visto no primeiro capítulo:

a) **Para duas variáveis quantitativas**
- Gráfico - **Scatterplot** de X e Y
- Coeficiente de Correlação de Pearson
- Análise de Regressão Simples

b) **Para duas variáveis categóricas (qualitativas)**
- Teste Qui-Quadrado e a Análise dos Resíduos
- Análise de Correspondência
- Gráfico de colunas por estratos da segunda variável

c) **Para uma variável quantitativa e uma qualitativa**
- Categoriza-se a variável quantitativa e procede-se como no item anterior.
- Gráfico **Box-Plot**, para cada estrato ou categoria da variável qualitativa.

VARIÁVEIS QUANTITATIVAS X QUANTITATIVAS

COMO CALCULAR A CORRELAÇÃO ENTRE DUAS VARIÁVEIS QUANTITATIVAS

Para medir o grau de correlação entre duas variáveis quantitativas estão disponíveis no programa alguns coeficientes de correlação, entre os quais, o Coeficiente de Correlação de Pearson.

COMO OBTER GRÁFICO DE PONTOS (SCATTERPLOT)

O gráfico de pontos (**Scatterplot)** deve ser uma etapa preliminar ao cálculo do Coeficiente de Correlação. Neste gráfico, cada ponto representa um par observado de valores das duas variáveis (X,Y). Através deste gráfico podemos visualizar empiricamente a relação entre as variáveis.

Para se obter o gráfico **Scatterplot** (gráfico de pontos) procede-se da seguinte maneira:

a) Clicar em **Graphs**; **Scatter**, abre a janela **Scatterplot**, onde se seleciona o tipo de gráfico, neste caso **Simple**;
b) Clicar em **Define**. São apresentadas as variáveis do Banco de Dados, escolhem-se as variáveis, no caso, **Literacy** e **Babymort**;
c) Define-se a variável Y no caso **Babymort**, clicar na flecha pertinente e a variável X, no caso **Literacy**, clicando-se na flecha correspondente;
d) Clicar em **OK**. O gráfico é gerado na janela **Chart**. Esta janela pode ser salva em arquivo com a extensão**.cht** (arquivo de gráfico).

RESULTADO:

Graph

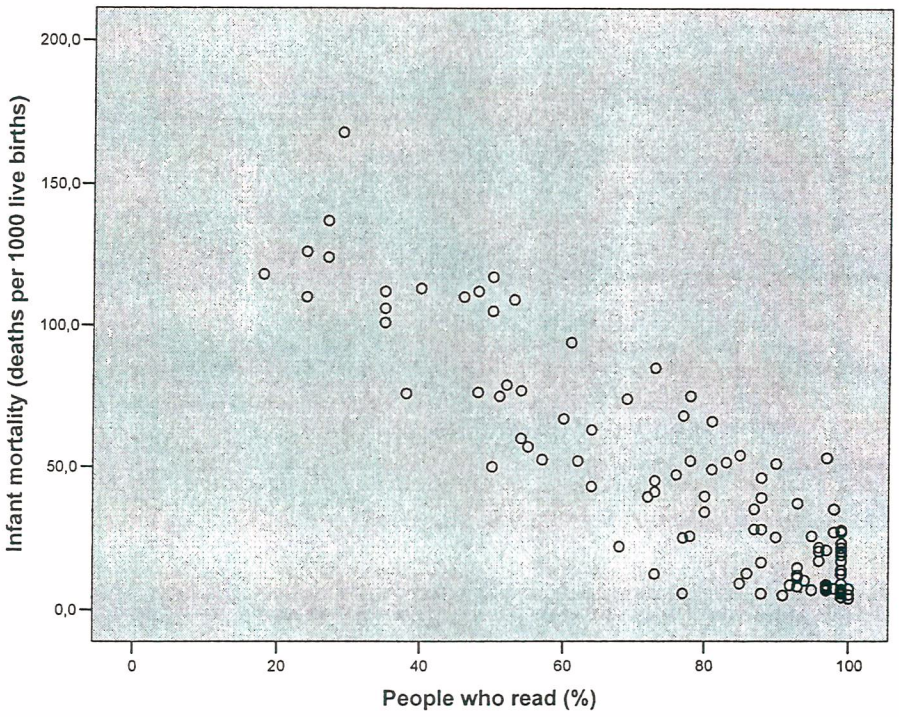

COMO OBTER O COEFICIENTE DE CORRELAÇÃO DE PEARSON

Para calcular o coeficiente de Correlação de Pearson procede-se da seguinte maneira:

a) Clicar em **Analyze**, **Correlate**, **Bivariate**, abre-se a janela **Bivariate Correlations;**
b) Selecionar as variáveis (no caso **Literacy** e **Babymort**), clicar na →;
c) Selecionar a estatística desejada, no caso, Pearson;
d) Clicar em **OK**;

OBSERVAÇÃO:

O coeficiente de Correlação Linear de Pearson (r) é uma medida que varia de –1 a +1.

O coeficiente fornece informação do tipo de associação das variáveis através do sinal:

- Se r for positivo, existe uma relação direta entre as variáveis (valores altos de uma variável correspondem a valores altos de outra variável);
- Se r for negativo, existe uma relação inversa entre as variáveis (valores altos de uma variável correspondem a valores baixos de outra variável);
- Se r for nulo ou aproximadamente nulo, significa que não existe correlação linear.

RESULTADO:

Nos resultados aparece uma tabela com 3 linhas em cada célula: o coeficiente de correlação, o resultado do teste de significância desse coeficiente e o número de observações utilizadas no cálculo do coeficiente.

Correlations

Correlations

		People who read (%)	Infant mortality (deaths per 1000 live births)
People who read (%)	Pearson Correlation	1	-,900**
	Sig. (2-tailed)	,	,000
	N	107	107
Infant mortality (deaths per 1000 live births)	Pearson Correlation	-,900**	1
	Sig. (2-tailed)	,000	,
	N	107	109

**. Correlation is significant at the 0.01 level (2-tailed).

As hipóteses do teste do Coeficiente de Correlação de Pearson são:

- **Hipótese Nula (H_0): $\rho = 0$ (não existe correlação entre as variáveis)**
- **Hipótese Alternativa (H_1): $\rho \neq 0$ (existe correlação significativa)**

CONCLUSÃO:

Ao analisarmos os dados obtidos, rejeita-se **H_0** (hipótese nula) de que **não há correlação** entre **Literacy** e **Babymort**, uma vez que o valor de p<0,001 (Sig. 2-tailed) e conclui-se que há correlação significante entre as duas variáveis acima.

Este resultado confirma a configuração do gráfico **Scatterplot**, mostrando que a medida que a taxa de pessoas alfabetizadas aumenta, a mortalidade infantil tende a diminuir.

COMO FAZER REGRESSÃO LINEAR SIMPLES

O modelo de regressão linear utiliza-se quando queremos ajustar uma equação linear entre duas variáveis quantitativas com a finalidade, por exemplo, de estimar o valor de uma variável em função de outra (Y em função de X). Para aplicar o modelo de regressão devemos definir a *priori* a variável explicativa ou independente (X) e a variável explicada ou dependente (Y). A relação entre as variáveis deve ser explicada teoricamente dentro da área de estudo.

Para obter a reta de regressão entre duas variáveis, por exemplo, **Literacy** e **Babymort**, procede-se da seguinte forma:

a) Clicar **Analyze, Regression, Linear**;
b) Definir a variável independente **Literacy**, e a variável dependente **Babymort**;
c) Selecionar **Method Enter**;
d) Na opção **Statistics**, selecionar **Casewise Diagnostics** para mostrar a tabela com os valores residuais atípicos;
e) Na opção **Save**, selecionar **Predicted Values / Unstandardized,** para salvar no banco de dados os valores estimados pela reta ajustada;
f) Clicar **OK**.

RESULTADO:

Regression

Variables Entered/Removed[b]

Model	Variables Entered	Variables Removed	Method
1	People who read (%)[a]	,	Enter

a. All requested variables entered.

b. Dependent Variable: Infant mortality (deaths per 1000 live births)

INTERPRETAÇÃO: O coeficiente de determinação (R square) é igual a 0,811, este valor indica que 81,1% da variação da variável mortalidade infantil (Babymort) é explicada pela variável percentagem de pessoas alfabetizadas (Literacy) através do modelo de regressão linear simples.

ANOVA[b]

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	126066,8	1	126066,834	450,226	,000[a]
	Residual	29400,822	105	280,008		
	Total	155467,7	106			

a. Predictors: (Constant), People who read (%)

b. Dependent Variable: Infant mortality (deaths per 1000 live births)

b. Dependent Variable: Infant mortality (deaths per 1000 live births)

INTERPRETAÇÃO: A tabela acima testa se pelo menos um dos coeficientes das variáveis independentes é significativo.

Coefficients[a]

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	160,732	5,794		27,740	,000
	People who read (%)	-1,507	,071	-,900	-21,219	,000

a. Dependent Variable: Infant mortality (deaths per 1000 live births)

INTERPRETAÇÃO: A equação de regressão é **Y = a + bX**, onde o coeficiente linear da reta é **a** = 160,732 e o coeficiente angular é **b** = -1,507. Como p< 0,001, rejeitamos a hipótese nula de que $\beta = 0$. A partir desta equação podemos estimar (predizer) os valores da variável dependente **(babymort)**.

As hipóteses do Coeficiente Angular β são:

- **Hipótese Nula (H_0): $\beta = 0$**
- **Hipótese Alternativa (H_1): $\beta \neq 0$**

Casewise Diagnostics[a]

Case Number	Std. Residual	Infant mortality (deaths per 1000 live births)	Predicted Value	Residual
1	3,046	168,0	117,027	50,973

a. Dependent Variable: Infant mortality (deaths per 1000 live births)

INTERPRETAÇÃO: A tabela **Casewise Diagnostics** apresenta os casos em que os valores residuais são atípicos, isto é, valores dos resíduos padronizados maiores do que 3 em valor absoluto, mostrando que a diferença entre o valor observado e o valor predito é relativamente grande e isto pode ser um sintoma de que o modelo não está bem ajustado.

Residuals Statistics[a]

	Minimum	Maximum	Mean	Std. Deviation	N
Predicted Value	10,026	133,605	42,674	34,4864	107
Residual	-38,888	50,973	,000	16,6543	107
Std. Predicted Value	-,947	2,637	,000	1,000	107
Std. Residual	-2,324	3,046	,000	,995	107

a. Dependent Variable: Infant mortality (deaths per 1000 live births)

INTERPRETAÇÃO: Esta tabela mostra um resumo das estatísticas descritivas dos principais resultados da Análise de Regressão.

OBSERVAÇÃO: Os valores de Y estimados por essa equação aparecem na última coluna do banco de dados, pois selecionamos a opção **Save / Predicted Values / Unstandardized.** Essa coluna tem o nome de **pre-1 (Unstandardized Predicted Value).** Os resíduos que forem calculados para outras variáveis terão os nomes pre-2, pre-3, etc, esses nomes podem ser alterados pelo usuário.

VARIÁVEIS CATEGÓRICAS X CATEGÓRICAS

COMO VERIFICAR A EXISTÊNCIA DE ASSOCIAÇÃO ENTRE VARIÁVEIS CATEGÓRICAS: Teste Qui - Quadrado

O banco **GSS93.sav**, será utilizado para obter a tabela de contingência e estudar a associação entre **Sexrace e Income4** (salário em categorias). Procede-se da seguinte forma:

a) Clicar em **Analyze**, **Descriptive Statistics**, **Crosstabs;**
b) Definir a variável da linha **Row - Sexrace**;
c) Definir a variável da coluna **Column – Income4**;
d) Clicar em **Statistics;**
e) Escolher o tratamento estatístico desejado, no caso, **Chi-Square**;
f) Clicar em **Continue**;
g) Clicar em **Cell** - veremos a janela **Crosstabs: Cell Display**;
h) Assinalar as opções **Observed**; etc, de acordo com o desejado;
i) Clicar em **Continue**; **OK.**

O valor esperado de cada casela na tabela pode ser obtido na janela **Crosstabs: Cell Display** assinalando-se também a opção **Expected.**

RESULTADOS:

Case Processing Summary

	Cases					
	Valid		Missing		Total	
	N	Percent	N	Percent	N	Percent
SEXRACE * Total Family Income	1500	100,0%	0	,0%	1500	100,0%

A leitura das caselas na 1ª linha (count) informa a freqüência bruta e a 2ª linha (expected count) corresponde ao valor esperado, isto é, o número de pessoas que seria esperado caso não houvesse nenhuma

associação entre as variáveis em estudo, ou seja, se as variáveis fossem independentes.

OBSERVAÇÃO: Valor Esperado sob hipótese de independência para o Teste Qui-Quadrado, para cada casela ij é obtido com a fórmula a seguir:

$$\frac{(TL_i \times TC_j)}{TG}$$

TL - total da linha i
TC - total da coluna j
TG - total geral

Quando se deseja obter o percentual correspondente à linha (**Row**) procede-se como anteriormente só que, em **Cell**, abre-se a janela **Crosstabs: Cell Display** e assinala-se a opção **Row** em **Percentages**, obtendo-se a seguinte tabela:

RESULTADOS:

SEXRACE * Total Family Income Crosstabulation

			Total Family Income				
			24,999 or less	25,000 to 39,999	40,000 to 59,999	60,000 or more	Total
SEXRACE	1,00	Count	181	130	104	137	552
		Expected Count	215,3	110,4	84,6	141,7	552,0
		% within SEXRACE	32,8%	23,6%	18,8%	24,8%	100,0%
	2,00	Count	285	125	99	196	705
		Expected Count	275,0	141,0	108,1	181,0	705,0
		% within SEXRACE	40,4%	17,7%	14,0%	27,8%	100,0%
	3,00	Count	30	10	12	14	66
		Expected Count	25,7	13,2	10,1	16,9	66,0
		% within SEXRACE	45,5%	15,2%	18,2%	21,2%	100,0%
	4,00	Count	58	22	5	17	102
		Expected Count	39,8	20,4	15,6	26,2	102,0
		% within SEXRACE	56,9%	21,6%	4,9%	16,7%	100,0%
	5,00	Count	13	3	2	5	23
		Expected Count	9,0	4,6	3,5	5,9	23,0
		% within SEXRACE	56,5%	13,0%	8,7%	21,7%	100,0%
	6,00	Count	18	10	8	16	52
		Expected Count	20,3	10,4	8,0	13,3	52,0
		% within SEXRACE	34,6%	19,2%	15,4%	30,8%	100,0%
Total		Count	585	300	230	385	1500
		Expected Count	585,0	300,0	230,0	385,0	1500,0
		% within SEXRACE	39,0%	20,0%	15,3%	25,7%	100,0%

Os percentuais relativos à coluna (**Column)** e ao total (**Total**) podem ser obtidos da mesma forma que para o cálculo da percentagem da linha. Cada casela poderia ter até 5 valores, descritos a seguir:

1ª linha: valor observado;
2ª linha: valor esperado;
3ª linha: percentual da linha;
4ª linha: percentual da coluna;
5ª linha: percentual total.

OBSERVAÇÃO:
Sugere-se que num relatório final de pesquisa seja selecionado apenas o valor observado e um destes percentuais.

RESULTADO:

Chi-Square Tests

	Value	df	Asymp. Sig. (2-sided)
Pearson Chi-Square	42,956[a]	15	,000
Likelihood Ratio	44,902	15	,000
Linear-by-Linear Association	6,226	1	,013
N of Valid Cases	1500		

a. 2 cells (8,3%) have expected count less than 5. The minimum expected count is 3,53.

INTERPRETAÇÃO: Considerando que $p < 0,001$, rejeita-se H_0, conclui-se que há associação entre **Sexrace** e **Income4**.

As hipótese do teste Qui-Quadrado (Chi-Square) são:

- **Hipótese Nula (H_0): As variáveis são independentes.**
- **Hipótese Alternativa (H_1): As variáveis são dependentes.**

COMO CALCULAR OS RESÍDUOS AJUSTADOS

Verificada a associação global entre as variáveis pode-se verificar se há associação local entre categorias, calculando-se os resíduos ajustados. O resíduo ajustado tem distribuição normal com média zero e desvio padrão igual a 1. Desta forma, caso o resíduo ajustado seja **>1,96**, em valor absoluto, pode-se dizer que há evidências de associação significante entre as duas categorias (p. ex. homem branco e salário alto) naquela casela. Quanto maior for o resíduo ajustado, maior a associação entre as categorias.

Para obter os resíduos ajustados procede-se da seguinte maneira:

a) Selecionar **Analyze**, **Descriptive Statistics**, **Crosstabs;**
b) Clicar em **Cells**, abre-se a janela **Crosstabs: Cell Display**;
c) Assinalar a opção **Observed** e **Adj. standardized**;
d) Clicar em **Continue**; **OK.**

RESULTADOS:

SEXRACE * Total Family Income Crosstabulation

			Total Family Income				
			24,999 or less	25,000 to 39,999	40,000 to 59,999	60,000 or more	Total
SEXRACE	1,00	Count	181	130	104	137	552
		Adjusted Residual	-3,8	2,6	2,9	-,6	
	2,00	Count	285	125	99	196	705
		Adjusted Residual	1,1	-2,1	-1,3	1,8	
	3,00	Count	30	10	12	14	66
		Adjusted Residual	1,1	-1,0	,7	-,8	
	4,00	Count	58	22	5	17	102
		Adjusted Residual	3,8	,4	-3,0	-2,2	
	5,00	Count	13	3	2	5	23
		Adjusted Residual	1,7	-,8	-,9	-,4	
	6,00	Count	18	10	8	16	52
		Adjusted Residual	-,7	-,1	,0	,9	
Total		Count	585	300	230	385	1500

CONCLUSÃO: A associação entre **sex** (sexo) e **income4** (salário em categorias) já foi considerada significativa. Agora a pergunta é: Quais

categorias estão associadas localmente? Olhando os resíduos ajustados vemos que os maiores valores (positivos) indicam forte associação entre homem-branco e salário alto, bem como há forte associação entre mulher-negra e salário baixo. Há outras associações locais interessantes na tabela, identifique.

VARIÁVEIS QUANTITATIVAS X CATEGÓRICAS

Neste caso os tratamentos estatísticos possíveis são os mesmos utilizados para duas variáveis qualitativas, desde que as variáveis quantitativas sejam categorizadas, logo, procede-se da seguinte forma:

- Categoriza-se a variável quantitativa em classes apropriadas;
- Mede-se a associação aplicando-se o teste Qui-Quadrado e a Análise dos Resíduos;
- Também podemos utilizar gráficos de colunas por estratos da segunda variável e o gráfico **BOX-PLOT** por categorias da segunda variável para apresentação dos dados de forma descritiva, exploratória.

COMO FAZER O BOX-PLOT

a) Clicar em **Graphs / Boxplot**;
b) Selecione **Simple / Summaries for groups of cases**;
c) Clicar em **Define**;
d) Em **Variable** selecionar uma variável quantitativa (por exemplo, **Babymort**);
e) Em **Category Axis**, selecionar uma variável categórica (por exemplo, **Region**);
f) Clicar em **OK**.

RESULTADO:

Explore

Region or economic group

Case Processing Summary

		Cases					
		Valid		Missing		Total	
	Region or economic group	N	Percent	N	Percent	N	Percent
Infant mortality (deaths per 1000 live births)	OECD	21	100,0%	0	,0%	21	100,0%
	East Europe	14	100,0%	0	,0%	14	100,0%
	Pacific/Asia	17	100,0%	0	,0%	17	100,0%
	Africa	19	100,0%	0	,0%	19	100,0%
	Middle East	17	100,0%	0	,0%	17	100,0%
	Latn America	21	100,0%	0	,0%	21	100,0%

INTERPRETAÇÃO: A tabela acima apresenta o número de casos válidos (**valid**), o número de não respostas (**missing**) e o número total das observações de cada categoria.

Infant mortality (deaths per 1000 live births)

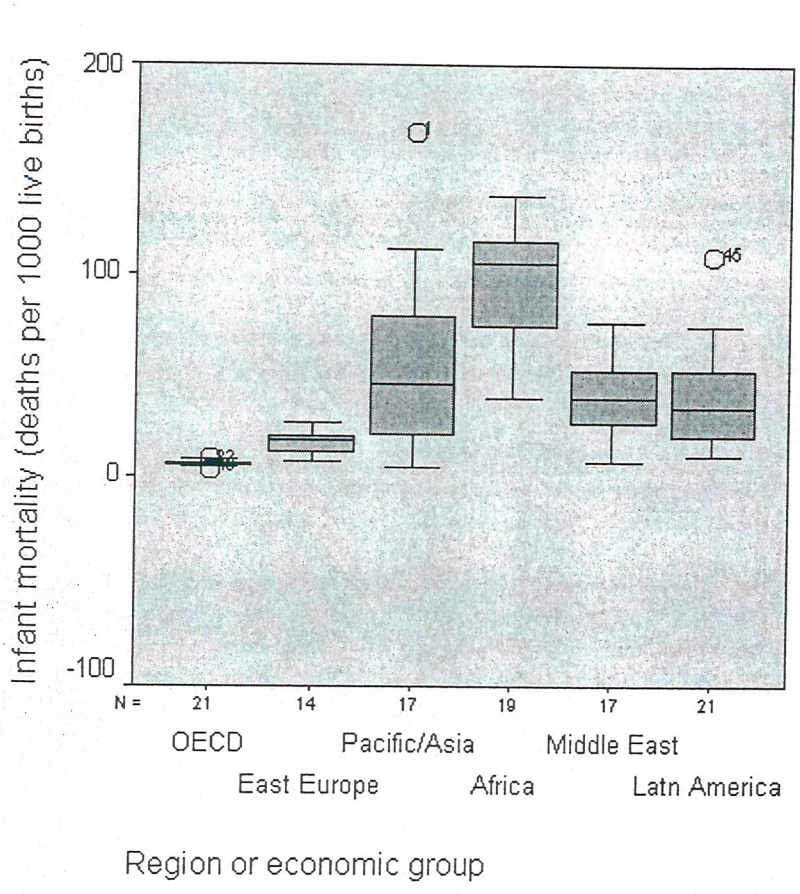

INTERPRETAÇÃO:

Através do Box-plot pode-se observar como as variáveis estão distribuídas em relação à homogeneidade dos dados, valores de tendência central, valores máximos e mínimos e valores atípicos se existirem. Quando a caixinha (box) é muito pequena, significa que os dados são muito concentrados em torno da mediana, e se a caixinha for grande, significa que os dados são mais hetereogêneos.

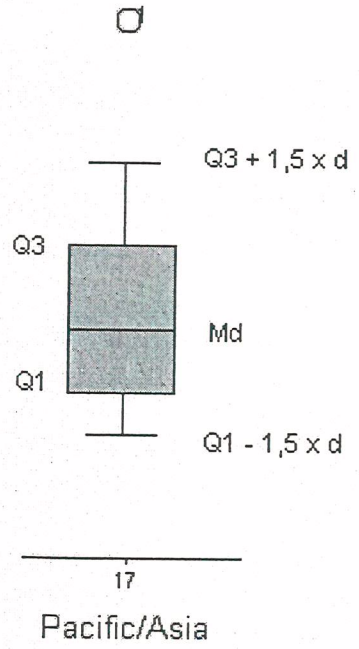

LEGENDA:

Md: Mediana (linha horizontal escura dentro do box)

Q1: Quartil inferior - 1°quartil (limite inferior do box)

Q3: Quartil superior - 3°quartil (limite superior do box)

d: diferença interquartílica (d = Q3 – Q1)

o : outlier (valores acima de 1,5 x d)

x : outlier (valores acima de 3,0 x d)

6. COMPARAÇÃO DE MÉDIAS

COMO COMPARAR MÉDIAS ENTRE DOIS GRUPOS: Teste t para Amostras Independentes.

O teste **t** é apropriado para comparar as médias de uma variável quantitativa entre dois grupos independentes.

EXEMPLO: Comparar a média de salários entre os sexos masculino e feminino na empresa.

a) Sexo (masculino, feminino) - Dois grupos (variável que define os grupos).
b) Idade no 1º. Casamento (Agewed) - Variável resposta ou de teste.

Para a aplicação do teste **t** nesta situação procede-se da seguinte forma:

a) Clicar em **Analyze**, **Compare Means**, **Independent Samples t test;**
b) Clicar sobre a variável de teste (Test Variables): **Agewed** ou, conforme o caso em estudo, clicar na variável correspondente;
c) Clicar sobre a variável de grupo (Grouping Variable) **Gender**;
d) Clicar em: **Define Group**;
e) Abre-se uma janela, na qual se define a categoria correspondente ao **Group 1** (no caso masculino) – digitando-se o código da categoria atribuída quando da construção do Banco de Dados, nesse caso **1** e **Group 2** (no caso feminino) digitando-se o código **2.** (*Observação*: No caso de se desejar confirmar os valores atribuídos às variáveis, abrir a janela **Utilities, Variables**)
f) Clicar em **Continue** e **OK**.

RESULTADO:

T-Test

Group Statistics

	Respondent's Sex	N	Mean	Std. Deviation	Std. Error Mean
Age When First Married	Male	492	24,16	4,87	,22
	Female	710	21,84	4,93	,18

Independent Samples Test

		Levene's Test for Equality of Variances		t-test for Equality of Means						
									95% Confidence Interval of the Difference	
		F	Sig.	t	df	Sig. (2-tailed)	Mean Difference	Std. Error Difference	Lower	Upper
Age When First Married	Equal variances assumed	,342	,559	8,066	1200	,000	2,32	,29	1,76	2,88
	Equal variances not assumed			8,085	1064,66	,000	2,32	,29	1,76	2,88

INTERPRETAÇÃO: Ao serem analisados os dados do exemplo acima vemos o seguinte:

a) Observa-se o resultado do teste para variâncias iguais (Teste de Levene). Neste exemplo, o valor de p para o teste Levene é 0,559, não se rejeita a hipótese de variâncias iguais.

b) O teste t a ser utilizado é o que aparece na primeira linha (Equal variances assumed), considerando que $p < 0,001$ (Sig 2-tailed), rejeita-se a hipótese nula (H_0) de igualdade das médias dos dois grupos, logo, pode-se concluir que as médias da variável **agewed** são significativamente diferentes entre os dois grupos de sexo.

As hipóteses do teste Levene de igualdade de variâncias são:

- **Hipótese Nula (H_0): As variâncias dos dois grupos são iguais.**
- **Hipótese Alternativa (H_1): As variâncias dos dois grupos são diferentes.**

As hipóteses do teste t para igualdade de médias entre Amostras Independentes são:

- **Hipótese Nula (H_0): As médias dos dois grupos são iguais.**
- **Hipótese Alternativa (H_1): As médias dos dois grupos são diferentes**

COMO COMPARAR AS MÉDIAS DE TRES OU MAIS GRUPOS: Análise de Variância – ANOVA para um fator

Para comparar a média de três ou mais grupos procede-se da seguinte maneira:

a) Clicar em **Analyze, Compare Means, One-Way Anova**;
b) Assinalar a variável dependente em **Dependent List,** clicar sobre a seta correspondente (pode-se realizar mais de um teste incluindo outras variáveis na lista, o teste será repetido para cada variável incluída na lista), neste caso utilize **Infant mortality;**
c) Assinalar a variável independente **Factor**, no caso **Region,** clicar na flecha correspondente;
d) Clicar o botão **Options.**
e) Clicar na alternativa do quadro **Statistics Descriptive** e depois **Continue;**
f) Clicar no botão **Post Hoc.** Aparece uma tela **One-Way Anova: Post Hoc Multiple Comparisons,** assinalar a alternativa **Tukey** ou outro teste conforme a escolha;
g) Clicar em **Continue, OK.**

RESULTADOS:

Oneway

Descriptives

Infant mortality (deaths per 1000 live births)

	N	Mean	Std. Deviation	Std. Error	95% Confidence Interval for Mean		Minimum	Maximum
					Lower Bound	Upper Bound		
OECD	21	6,91	1,17	,26	6,38	7,44	4,0	9,2
East Europe	14	16,89	5,48	1,47	13,73	20,06	8,7	27,0
Pacific/Asia	17	53,88	46,44	11,26	30,00	77,76	4,4	168,0
Africa	19	94,18	28,65	6,57	80,37	107,99	39,3	137,0
Middle East	17	41,39	19,18	4,65	31,53	51,25	8,6	76,4
Latn America	21	39,11	24,52	5,35	27,95	50,28	10,2	109,0
Total	109	42,31	38,08	3,65	35,08	49,54	4,0	168,0

ANOVA

Infant mortality (deaths per 1000 live births)

	Sum of Squares	df	Mean Square	F	Sig.
Between Groups	88983,515	5	17796,703	27,108	,000
Within Groups	67619,443	103	656,499		
Total	156602,958	108			

INTERPRETAÇÃO: No exemplo acima o valor p (Sig) da ANOVA é $p<0,001$, então, rejeita-se a hipótese nula (H_0) de igualdade das médias dos seis grupos, logo, pelo menos duas médias de mortalidade infantil diferem entre si. Um teste de comparações múltiplas (post-hoc) permite identificar qual(is) grupo(s) diferem.

As hipóteses da Análise de Variância para um fator (ANOVA – One-Way) são:

- **Hipótese Nula (H_0): As médias de todos os grupos são iguais.**
- **Hipótese Alternativa (H_1): Pelo menos duas médias diferem entre si.**

Post Hoc Tests

Multiple Comparisons

Dependent Variable: Infant mortality (deaths per 1000 live births)
Dunnett T3

(I) Region or economic group	(J) Region or economic group	Mean Difference (I-J)	Std. Error	Sig.	95% Confidence Interval	
					Lower Bound	Upper Bound
OECD	East Europe	-9,983*	8,841	,000	-15,109	-4,857
	Pacific/Asia	-46,972*	8,359	,010	-85,018	-8,927
	Africa	-87,269*	8,113	,000	-109,134	-65,404
	Middle East	-34,484*	8,359	,000	-50,215	-18,753
	Latn America	-32,204*	7,907	,000	-49,788	-14,620
East Europe	OECD	9,983*	8,841	,000	4,857	15,109
	Pacific/Asia	-36,989	9,247	,060	-75,025	1,046
	Africa	-77,286*	9,025	,000	-99,390	-55,182
	Middle East	-24,501*	9,247	,001	-40,604	-8,399
	Latn America	-22,221*	8,841	,008	-40,163	-4,280
Pacific/Asia	OECD	46,972*	8,359	,010	8,927	85,018
	East Europe	36,989	9,247	,060	-1,046	75,025
	Africa	-40,297	8,554	,064	-81,986	1,393
	Middle East	12,488	8,788	,991	-27,291	52,267
	Latn America	14,768	8,359	,972	-25,556	55,092
Africa	OECD	87,269*	8,113	,000	65,404	109,134
	East Europe	77,286*	9,025	,000	55,182	99,390
	Pacific/Asia	40,297	8,554	,064	-1,393	81,986
	Middle East	52,785*	8,554	,000	27,463	78,107
	Latn America	55,065*	8,113	,000	28,621	81,508
Middle East	OECD	34,484*	8,359	,000	18,753	50,215
	East Europe	24,501*	9,247	,001	8,399	40,604
	Pacific/Asia	-12,488	8,788	,991	-52,267	27,291
	Africa	-52,785*	8,554	,000	-78,107	-27,463
	Latn America	2,280	8,359	1,000	-19,841	24,400
Latn America	OECD	32,204*	7,907	,000	14,620	49,788
	East Europe	22,221*	8,841	,008	4,280	40,163
	Pacific/Asia	-14,768	8,359	,972	-55,092	25,556
	Africa	-55,065*	8,113	,000	-81,508	-28,621
	Middle East	-2,280	8,359	1,000	-24,400	19,841

*. The mean difference is significant at the .05 level.

As variâncias da variável mortalidade infantil dos diferentes grupos são muito heterogêneas, por esta razão utilizamos um teste de comparações múltiplas que leva em conta esta desigualdade de variâncias, por exemplo, o teste T3 de Dunnet.

7. ESTATÍSTICA NÃO PARAMÉTRICA

TESTE DE KOLMOGOROV-SMIRNOV

Para verificar se uma variável segue determinada distribuição procede-se da seguinte maneira:

a) Clicar em **Analyze, Non-Parametric Tests, 1-Sample KS**;
b) Assinalar a variável dependente em **Dependent List,** clicar sobre a seta correspondente (pode-se realizar mais de um teste incluindo outras variáveis na lista, o teste será repetido para cada variável incluída na lista), neste caso utilize **Infant mortality;**
c) Assinalar a distribuição em relação a qual a variável será testada em **Test Distribution.** Neste caso, distribuição Normal;
d) Clicar o botão **Options.**
e) Clicar na alternativa do quadro Statistics **Descriptive**;
f) Clicar em **Continue, OK.**

RESULTADO:

NPar Tests

Descriptive Statistics

	N	Mean	Std. Deviation	Minimum	Maximum
Infant mortality (deaths per 1000 live births)	109	42,313	38,079	4,0	168,0

One-Sample Kolmogorov-Smirnov Test

		Infant mortality (deaths per 1000 live births)
N		109
Normal Parameters[a,b]	Mean	42,313
	Std. Deviation	38,079
Most Extreme Differences	Absolute	,169
	Positive	,169
	Negative	-,157
Kolmogorov-Smirnov Z		1,769
Asymp. Sig. (2-tailed)		,004

a. Test distribution is Normal.

b. Calculated from data.

INTERPRETAÇÃO: Ao analisarmos os dados obtidos, rejeita-se H_0 (hipótese nula) de que **a variável Infant mortality segue distribuição Normal**, uma vez que o valor de **p** (Asymp. Sig. 2-tailed) é menor que 0,004 (muito pequena, neste caso) e conclui-se em favor da hipótese alternativa de que a distribuição da mortalidade infantil não deve ser Normal.

As hipótese do Teste de Kolmogorov-Smirnov são:

- **Hipótese Nula (H_0): A variável segue distribuição Normal.**
- **Hipótese Alternativa (H_1): A variável não segue distribuição Normal.**

8. MANIPULAÇÃO DE DADOS

SORT CASES

Uma das necessidades na hora da manipulação dos dados no dia-a-dia é a ordenação dos casos segundo uma ou mais variáveis. Para fazer isso no *SPSS for Windows*, usar o procedimento **Sort Cases** presente no menu **Data**.

Após clicar em **Data** opção **Sort Cases**, uma janela é aberta. Movemos para o quadro **Sort by** a variável segundo a qual o arquivo deve ser ordenado. Podemos mover para esse quadro mais do que uma variável. Nesse caso, o arquivo é ordenado, em primeiro lugar, pelos valores da primeira variável no quadro e, em segundo lugar, pela segunda variável no quadro; a segunda ordenação é feita para os valores comuns da primeira variável.

Podemos escolher também entre ordem crescente ou decrescente de ordenação para cada uma das variáveis. Isso é feito através do quadro **Sort Order** opções **Descending** (decrescente) ou **Ascending** (crescente).

Vamos fazer uma ordenação segundo idade (ordem decrescente) **dentro** dos códigos de sexo (ordem crescente). Para isso movemos a variável sexo para ao quadro **Sort Cases** e escolhemos a opção **Ascending** no quadro **Sort Order**. Movemos em seguida a variável idade para o quadro **Sort Cases** e escolhemos a opção **Descending** no quadro **Sort Order**. Agora, basta clicar **OK** para executar a ordenação.

Note que após a execução deste comando a posição dos indivíduos nas linhas fica completamente alterada, pois o indivíduo na linha 1 do banco de dados após ordenado pode não ser o primeiro caso digitado. Para que esta informação não se perca é essencial que exista uma variável com o número do indivíduo.

SELECT CASES

Uma outra necessidade é a seleção (temporária ou permanente) de parte do arquivo de dados. Digamos que estamos interessados em estudar um segmento específico da amostra. O SPSS possui várias formas de seleção de dados. Falaremos nessa seção de todas elas, mas discutiremos detalhadamente a mais usada de todas. Para maiores detalhes sobre as demais formas de seleção, recomenda-se que o leitor use o manual do *SPSS for Windows*.

Para fazer qualquer tipo de seleção, devemos clicar o menu **Data** opção **Select Cases**.

No quadro central **Select**, estão presentes cinco opções diferentes para seleção:

- **All cases** – opção usada por *default*, utiliza todas as observações do banco de dados;
- **If condition is satisfied** – através dessa opção, podemos definir expressões condicionais para seleção de casos;
- **Random sample of cases** – podemos selecionar uma porcentagem ou número exato de casos; a seleção é feita aleatoriamente;
- **Based on time or case range** – usamos essa opção quando estamos interessados em selecionar uma faixa específica de valores, por exemplo, os casos do número 100 ao 200; também utilizada para fazer seleções baseadas em datas;
- **User filter variable** – uma variável é escolhida no banco de dados e usada como filtro; todos os casos para os quais a variável filtro assume o valor 0 não serão selecionados.

Você tem duas opções para o tratamento dos casos que não serão selecionados. É através do quadro **Unselected Cases Are** que podemos fazer a escolha:

- **Filtered** – os casos (linhas) que não são selecionados não são incluídos nas análises posteriores, porém, permanecem na janela de dados; caso você mude de idéia e queira usar os casos não selecionados na mesma sessão do SPSS, basta desligar o filtro;
- **Deleted** – os casos (linhas) não selecionados são apagados da janela de dados; caso você mude de idéia e queira usar os casos não selecionados, você deverá ler novamente o arquivo de dados original. Neste caso deve-se tomar o cuidado de salvar o banco de dados com outro nome (**File...Save As**).

Suponha que estamos interessados em selecionar as pessoas que trabalham pelo menos 40 horas por semana e que têm até 20 horas de lazer. A função condicional para seleção nesse caso é dada por:

trabalho ≥ 40 & lazer ≤ 20

Portanto, o tipo de seleção de dados que faremos deve possibilitar a criação de sentenças matemáticas lógicas para seleção dos casos. Para isso, clicamos em **If condition is satisfied** e entramos no retângulo **If..**

Através da janela que é aberta, usamos o retângulo superior para escrever uma função lógica na qual a seleção vai ser baseada. Para a construção da função, podemos usar todas as variáveis que estão no quadro à esquerda e as funções disponíveis no quadro inferior direito.

Uma vez escrita a função que determina a regra de seleção dos casos, clique **Continue** e você voltará à janela anterior. No quadro inferior (**Unselected cases are**), vamos optar pelo modo **Filtered** (ou seja, os casos não selecionados permanecem na tela de dados, porém, não serão utilizados em análises futuras) e clicar **OK**.

Você pode perceber que, depois de feita a seleção, a janela de dados sofre algumas alterações. As linhas (casos) que não foram

selecionadas apresentam uma listra no canto esquerdo da janela de dados. A barra localizada na parte inferior da janela apresenta a mensagem **Filter On**. Além disso, uma coluna de nome filter_$ é adicionada à janela de dados. Essa nova coluna apresenta valor 0 para as linhas que não foram selecionadas e valor 1 para as linhas que foram selecionadas.

Apesar de você conseguir ver os casos que não foram selecionados, qualquer análise efetuada daí para frente não leva em conta esses casos.

Podemos mudar de idéia e querer usar todas as observações para o cálculo das estatísticas. Temos duas maneiras de cancelar a seleção de casos, se a opção **Filtered** foi usada para efetuar a seleção. A primeira delas é ativar a opção **All Cases** da janela de seleção de casos (menu **Select Cases**) e clicar **OK**. A Segunda maneira é deletar a coluna filter_$ da janela de dados.

SPLIT FILE

Vamos supor que, após uma série de análises, chegamos à conclusão de que o comportamento dos homens e das mulheres é completamente diferente com relação às preferências para horas de lazer. Não faz sentido, portanto, apresentar a análise do questionário de opinião sobre lazer com os homens e mulheres juntos. No fundo, o que pretendemos fazer, daqui para frente, são duas análises idênticas, uma para cada sexo.

Para esse tipo de situação, podemos utilizar o procedimento **Split File**, presente no menu **Data**. Por *default* sempre analisamos todos os casos juntos, sem separação por grupos. Por esse motivo, a opção selecionada na janela é **Analyze all cases**. Para repetir a análise para as categorias de uma determinada variável, clicamos em **Compare groups** ou **Organize output by groups**, e então o quadro **Groups Based on** fica disponível.

Moveremos para esse quadro a variável (ou variáveis) que definirão os grupos para os quais a análise deve ser repetida. Se mais do que uma variável for selecionada, os grupos serão definidos pela combinação das categorias de todas as variáveis. Podemos ainda escolher se o banco de dados deve ser ordenado pela variável que definirá os grupos (**Sort the file by group variables**) ou se o banco de dados já está ordenado pela variável que definirá os grupos (**File is already sorted**).

No nosso caso, selecionamos a variável sexo e a movemos para o quadro **Groups Based on** e clicamos **OK**. A única mudança que acontece na janela de dados é a mensagem **Split File On** na barra inferior, ou a ordenação dos casos pela variável que definiu os grupos, caso o banco de dados ainda não estivesse ordenado. Porém, qualquer análise ou gráfico feitos de agora em diante vão gerar dois resultados, uma para os homens e outro para as mulheres.

Note que os resultados são apresentados em dois blocos, o primeiro para o sexo masculino e o segundo para o sexo feminino se a opção escolhida foi ou **Organize output by groups**.

Podemos mudar de idéia e querer usar todas as observações para o cálculo das estatísticas. Para cancelar o procedimento **Split File** basta ativar a opção **Analyze all cases** presente na janela de definição da opção **Split File** menu **Data**.