

# Física Experimental III e IV

## Estatística

Página da disciplina:


<https://edisciplinas.usp.br/course/view.php?id=66863>

2019

# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$



Revido alguns conceitos sobre incertezas

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

# O método científico

- A verificação e falsificação - Einstein: “No amount of experimentation can ever prove me right; a single experiment can prove me wrong.”



[http://en.wikipedia.org/wiki/Scientific\\_method](http://en.wikipedia.org/wiki/Scientific_method)

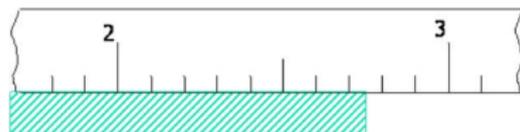
<http://www.unicamp.br/~chibeni/textosdidaticos/metodocientifico.pdf>

# O método científico

- Uma medida é sempre uma comparação com um padrão
- Sujeita a imperfeições e limitações
- Algarismos significativos
  - ▶ Todos que tenho certeza + primeiro duvidoso (estimado)

# O método científico


- Uma medida é sempre uma comparação com um padrão
- Sujeita a imperfeições e limitações
- Algarismos significativos
  - ▶ Todos que tenho certeza + primeiro duvidoso (estimado)



$$L = 2,74$$

# O método científico

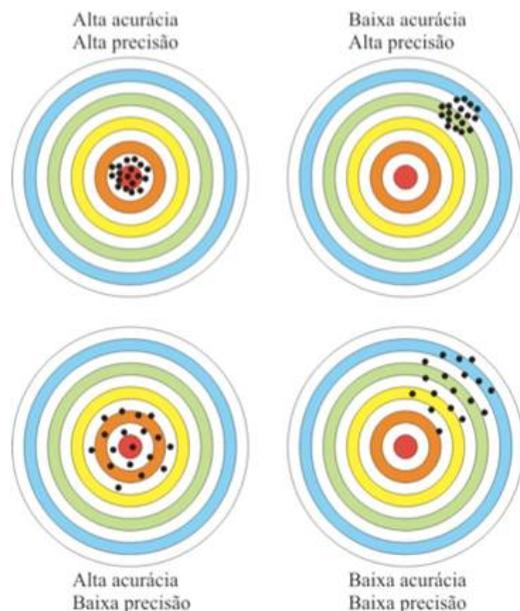
- Uma medida é sempre uma comparação com um padrão
- Sujeita a imperfeições e limitações
- Algarismos significativos
  - ▶ Todos que tenho certeza + primeiro duvidoso (estimado)



$$L = 2,74$$

- 2 e 7 tenho “certeza”
- 4 é uma estimativa → duvidoso

- **Precisão:** Relacionada à flutuação entre uma medida e outra
- **Acurácia:** Quão próximo você está do valor verdadeiro



- **Erro = valor verdadeiro - valor medido**
  - ▶ Toda medida experimental apresenta um erro
  - ▶ O valor do erro não pode ser conhecido
  - ▶ Existem dois tipos de erro, um relacionado à precisão e outro, à acurácia
- **Incerteza = melhor estimativa do valor do erro**

# Representando uma medida

- Faz-se a medida e avalia-se a incerteza
- **Escreve-se a incerteza com, no máximo, 2 algarismos significativos**
- A grandeza acompanha a precisão da incerteza
- Exemplo:
  - ▶ Obtive estes valores na calculadora

$$\text{Tempo médio} = 2,8764536952 \text{ s}$$

$$\text{Incerteza} = 0,0456485323 \text{ s}$$

- ▶ Escrevo o resultado como:

# Representando uma medida

- Faz-se a medida e avalia-se a incerteza
- **Escreve-se a incerteza com, no máximo, 2 algarismos significativos**
- A grandeza acompanha a precisão da incerteza
- Exemplo:
  - ▶ Obtive estes valores na calculadora

$$\text{Tempo médio} = 2,8764536952 \text{ s}$$

$$\text{Incerteza} = 0,0456485323 \text{ s}$$

- ▶ Escrevo o resultado como:

$$\text{Tempo médio} = (2,876 \pm 0,046) \text{ s}$$

ou

$$\text{Tempo médio} = (2,88 \pm 0,05) \text{ s}$$

# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

- Repetição de um experimento como ferramenta de avaliação da sua precisão
- Quanto mais eu repito, mais preciso se torna o valor médio
- Lei dos grandes números: se  $n$  tende ao infinito, o valor médio ( $\bar{y}$ ) tende ao valor verdadeiro ( $\tilde{y}$ )
  - ▶ Não havendo problemas de acurácia

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$$

$$\text{se } n \rightarrow \infty, \bar{y} \rightarrow \tilde{y}$$

- Avaliação da flutuação dos dados em torno da média da amostra (por não conhecermos o valor verdadeiro)
- Não reflete problemas de acurácia
- O desvio padrão é o correspondente à incerteza estatística de uma única medida realizada
- Cada medida, além da incerteza instrumental, possui uma incerteza estatística dada pelo desvio padrão

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y})^2} \sim \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2}$$

- De um conjunto de medidas, obtemos o seu valor médio
- Agora suponha que possamos repetir esse conjunto de medidas  $k$  vezes e, em cada caso, obtém-se um valor médio
- Incerteza estatística (precisão) do **valor médio** de uma amostra

$$\sigma_m = \sqrt{\frac{1}{k} \sum_{i=1}^k (\bar{y}_i - \tilde{y})^2}$$

$$\sigma_m = \frac{\sigma}{\sqrt{n}}$$

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

# Revendo a análise de queda livre do Pelletron


- Medida de tempo de queda de balões de água
- Quase quinhentas medidas
- Análise estatística
- A aceleração obtida é compatível com a gravidade?

$$g_{IAG} = 9.7864 \text{ m/s}^2$$





# Medidas realizadas

Medida	Tempo (s)	Aceleração ( $m/s^2$ )
1	2,46	11,2
2	2,61	9,98
...	...	...
~500	2,73	9,12



# Histogramas



# Desvio padrão das medidas

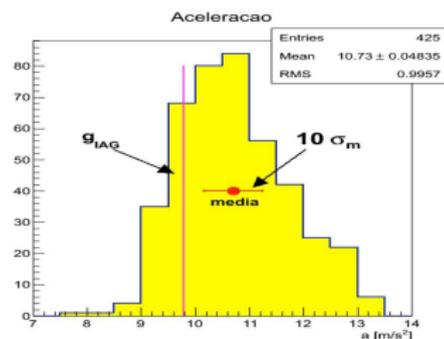
- O desvio padrão é uma estimativa de quanto cada medida flutua em torno do valor médio da amostra
- Estimativa da incerteza de cada medida

$$\sigma_{tempo} = 0,12 \text{ s}$$

$$\sigma_{acel} = 1,0 \text{ m/s}^2$$

Medida	Tempo (s)	Aceleração (m/s <sup>2</sup> )
1	2,46	11,2
2	2,61	9,98
...	...	...
~500	2,73	9,12

- Os valores de aceleração são precisos e acurados?
- Precisão:**
  - ▶ Desvio padrão:  $\sigma_{acel} = 1,0 \text{ m/s}^2$
  - ▶  $\sim 10 \%$  do valor de  $g$
  - ▶  $g_{IAG} = 9,7864 \text{ m/s}^2$
  - ▶  $g_{medio} = 10,73 \pm 0,05 \text{ m/s}^2$

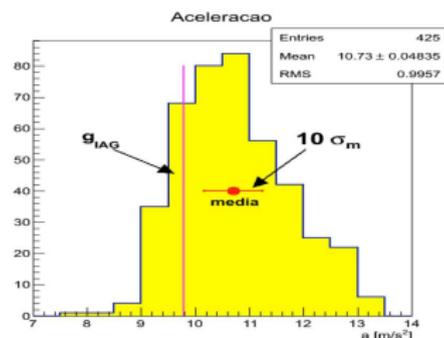


# Acurácia e precisão da medida

- Os valores de aceleração são precisos e acurados?
- Precisão:**
  - ▶ Desvio padrão:  $\sigma_{acel} = 1,0 \text{ m/s}^2$
  - ▶  $\sim 10 \%$  do valor de  $g$
  - ▶  $g_{IAG} = 9,7864 \text{ m/s}^2$
  - ▶  $g_{medio} = 10,73 \pm 0,05 \text{ m/s}^2$

- Acurácia:**

$$\frac{g_{medio} - g_{IAG}}{\sigma_m} = 19$$



- Como investigar a diferença entre o valor médio e o valor do IAG?
- **Hipóteses teóricas**
  - ▶ Desprezamos a resistência do ar
    - ★ Se fosse importante iria diminuir a aceleração e não aumentar

- Como investigar a diferença entre o valor médio e o valor do IAG?

- **Hipóteses teóricas**

- ▶ Desprezamos a resistência do ar
  - ★ Se fosse importante iria diminuir a aceleração e não aumentar
- ▶ Velocidade inicial diferente de zero
  - ★ Equação horária

$$y = v_0 t + \frac{1}{2} g t^2$$

- ★ Para a aceleração ser igual ao valor do IAG, teríamos que ter

$$v_0 = 1,1 \text{ m/s}$$

- ★ Valor muito elevado se comparado ao método utilizado para lançar as bolas

- Como investigar a diferença entre o valor médio e o valor do IAG?

- **Hipóteses teóricas**

- ▶ Desprezamos a resistência do ar
  - ★ Se fosse importante iria diminuir a aceleração e não aumentar
- ▶ Velocidade inicial diferente de zero
  - ★ Equação horária

$$y = v_0 t + \frac{1}{2} g t^2$$

- ★ Para a aceleração ser igual ao valor do IAG, teríamos que ter

$$v_0 = 1,1 \text{ m/s}$$

- ★ Valor muito elevado se comparado ao método utilizado para lançar as bolas
- ▶ A revisão das hipóteses teóricas não parece resolver a discrepância

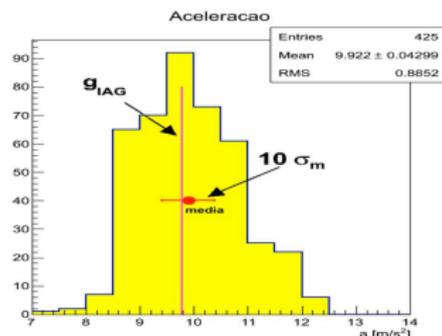
- Como investigar a diferença entre o valor médio e o valor do IAG?
- **Rever o procedimento experimental**
  - ▶ O disparo do cronômetro foi auditivo
    - ★ Som tem velocidade de  $\sim 340$  m/s
    - ★ Torre tem altura de 34 metros
    - ★ Ouvimos o som 0,1 segundo depois que a bola começa a cair

- Como investigar a diferença entre o valor médio e o valor do IAG?
- **Rever o procedimento experimental**
  - ▶ O disparo do cronômetro foi auditivo
    - ★ Som tem velocidade de  $\sim 340$  m/s
    - ★ Torre tem altura de 34 metros
    - ★ Ouvimos o som 0,1 segundo depois que a bola começa a cair
    - ★ Ou seja, o tempo medido é sistematicamente menor que o tempo de queda por aproximadamente 0,1 segundo
    - ★ O que acontece se somarmos 0,1 segundo em todos os tempos de queda?

# Tentando corrigir problemas de acurácia

- Acrescentando 0,1 segundo em todos os tempos
- **Precisão:**
  - ▶ Desvio padrão:  $\sigma_{acel} = 0,9 \text{ m/s}^2$
  - ▶  $\sim 10 \%$  do valor de  $g$
  - ▶  $g_{IAG} = 9,7864 \text{ m/s}^2$
  - ▶  $g_{medio} = 9,92 \pm 0,04 \text{ m/s}^2$
- **Acurácia:**

$$\frac{g_{medio} - g_{IAG}}{\sigma_m} = 3$$



- A repetição exaustiva do experimento permitiu realizar uma análise estatística que evidenciava um problema no procedimento adotado para analisar os dados
- Isso só foi possível porque essa repetição permitiu avaliar as incertezas envolvidas, principalmente a incerteza na aceleração medida
- Em muitas situações não podemos repetir o experimento à exaustão
  - ▶ custa caro, leva muito tempo, etc.
- Como proceder se fizemos apenas uma medida de tempo?
- Qual a incerteza no tempo e aceleração?

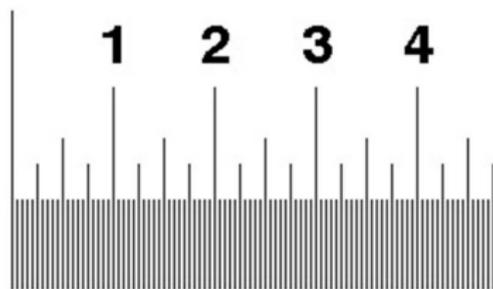
# E se não for possível repetir?

- Nas medidas diretas, tente estimar qual seria a flutuação obtida caso você repetisse o experimento



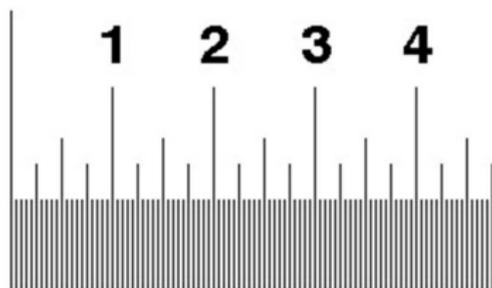
# E se não for possível repetir?

- Nas medidas diretas, tente estimar qual seria a flutuação obtida caso você repetisse o experimento
- Em instrumentos com escalas simples desenhadas, como réguas, em geral utiliza-se metade da menor divisão




# E se não for possível repetir?

- Nas medidas diretas, tente estimar qual seria a flutuação obtida caso você repetisse o experimento
- Em instrumentos com escalas simples desenhadas, como réguas, em geral utiliza-se metade da menor divisão
- Para instrumentos digitais a acurácia é fornecida no manual do instrumento



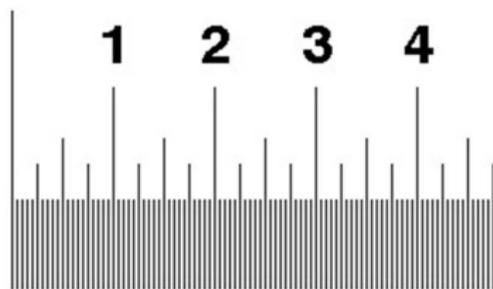
# E se não for possível repetir?

- Nas medidas diretas, tente estimar qual seria a flutuação obtida caso você repetisse o experimento
- Em instrumentos com escalas simples desenhadas, como réguas, em geral utiliza-se metade da menor divisão
- Para instrumentos digitais a acurácia é fornecida no manual do instrumento
- Avalie a precisão humana
  - ▶ Por exemplo, o tempo de reação para disparar e parar um cronômetro



# E se não for possível repetir?

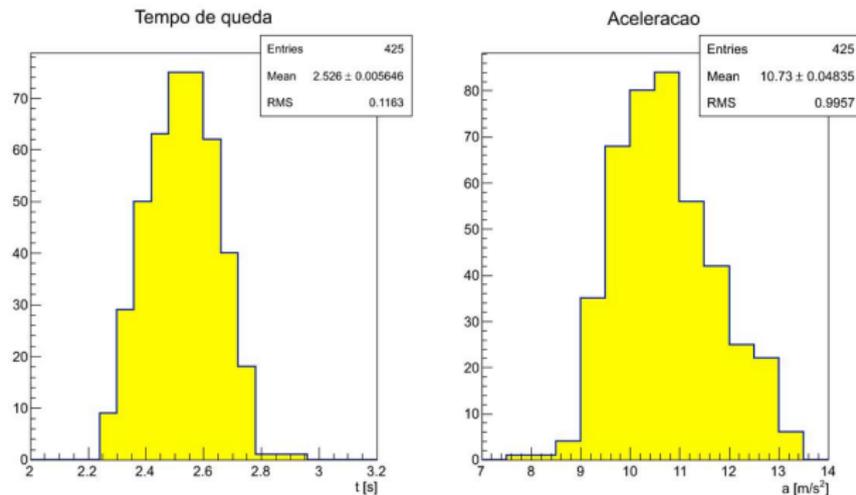
- Nas medidas diretas, tente estimar qual seria a flutuação obtida caso você repetisse o experimento
- Em instrumentos com escalas simples desenhadas, como réguas, em geral utiliza-se metade da menor divisão
- Para instrumentos digitais a acurácia é fornecida no manual do instrumento
- Avalie a precisão humana
  - ▶ Por exemplo, o tempo de reação para disparar e parar um cronômetro
- E grandezas derivadas?
  - ▶ Propagação de incertezas



# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

# Repetição de um experimento



- Mede-se a grandeza várias vezes. Neste caso, o tempo de queda.
- Calcula-se a grandeza derivada para cada medida e estuda-se sua distribuição

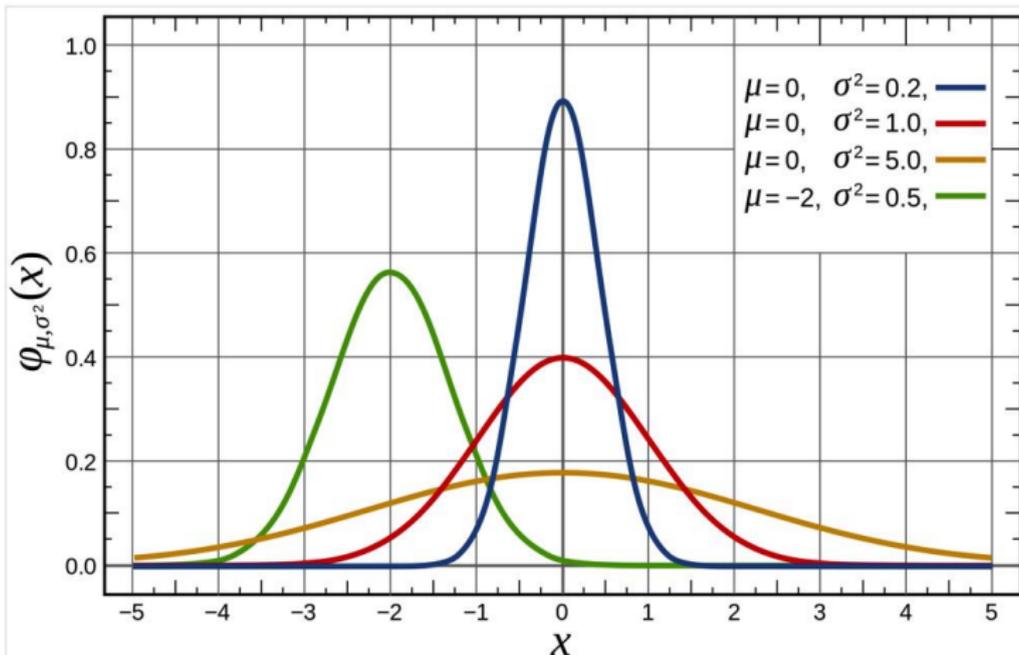
$$g = 2 \frac{h}{t^2}$$

- ... não pudermos repetir este experimento de modo a calcular desvios padrão?

- ... não pudermos repetir este experimento de modo a calcular desvios padrão?
- ... a grandeza derivada depender de muitas outras grandezas diferentes?

# A gaussiana

$$G_{\mu,\sigma}(x) = G(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp \left[ -\frac{1}{2} \left( \frac{x - \mu}{\sigma} \right)^2 \right]$$



- Cálculo de valores médios

$$\langle (x - \mu)^n \rangle = \int_{-\infty}^{\infty} (x - \mu)^n G(x) dx$$

# Uma propriedade importante

- Cálculo de valores médios

$$\langle (x - \mu)^n \rangle = \int_{-\infty}^{\infty} (x - \mu)^n G(x) dx$$

- Fazendo uma mudança de variável

$$y = \frac{x - \mu}{\sigma}$$

- Cálculo de valores médios

$$\langle (x - \mu)^n \rangle = \int_{-\infty}^{\infty} (x - \mu)^n G(x) dx$$

- Fazendo uma mudança de variável

$$y = \frac{x - \mu}{\sigma} \Rightarrow \langle (x - \mu)^n \rangle = \frac{1}{\sqrt{2\pi}} \sigma^n \int_{-\infty}^{\infty} y^n \exp \left[ -\frac{1}{2} y^2 \right] dy$$

# Uma propriedade importante

- Definindo

$$I_n = \int_{-\infty}^{\infty} y^n \exp \left[ -\frac{1}{2}y^2 \right] dy$$

# Uma propriedade importante

- Definindo

$$I_n = \int_{-\infty}^{\infty} y^n \exp\left[-\frac{1}{2}y^2\right] dy$$

- Consultando uma tabela de integrais

$$I_0 = \sqrt{2\pi}$$

$$I_n = 0 \text{ se } n \text{ for ímpar}$$

$$\frac{I_n}{I_{n-2}} = (n-1) \text{ para } n \text{ par e } n > 1$$

- Substituindo

$$\langle (x - \mu)^n \rangle = \frac{I_n}{I_0} \sigma^n$$

# Uma propriedade importante

- Substituindo

$$\langle (x - \mu)^n \rangle = \frac{I_n}{I_0} \sigma^n$$

- Exemplo:

$$\langle (x - \mu)^2 \rangle = \frac{I_2}{I_0} \sigma^2 = (2 - 1) \sigma^2 = \sigma^2$$

# Uma propriedade importante

- Substituindo

$$\langle (x - \mu)^n \rangle = \frac{l_n}{l_0} \sigma^n$$

- Exemplo:

$$\langle (x - \mu)^2 \rangle = \frac{l_2}{l_0} \sigma^2 = (2 - 1) \sigma^2 = \sigma^2$$

$$\langle (x - \mu)^4 \rangle = \frac{l_4}{l_0} \sigma^4 = \frac{l_4}{l_2} \frac{l_2}{l_0} \sigma^4 = (4 - 1)(2 - 1) \sigma^4 = 3 \sigma^4$$

# Propagação de incertezas

- Considere um exemplo simples onde se quer calcular

$$z = x + y$$

# Propagação de incertezas

- Considere um exemplo simples onde se quer calcular

$$z = x + y$$

$$\sigma_z^2 = \langle (z - \mu_z)^2 \rangle$$

- Considere um exemplo simples onde se quer calcular

$$z = x + y$$

$$\sigma_z^2 = \langle (z - \mu_z)^2 \rangle$$

- Substituindo a fórmula no cálculo da variância:

$$\sigma_z^2 = \langle [x + y - (\mu_x + \mu_y)]^2 \rangle$$

- Considere um exemplo simples onde se quer calcular

$$z = x + y$$

$$\sigma_z^2 = \langle (z - \mu_z)^2 \rangle$$

- Substituindo a fórmula no cálculo da variância:

$$\sigma_z^2 = \langle [x + y - (\mu_x + \mu_y)]^2 \rangle$$

$$\sigma_z^2 = \langle [(x - \mu_x) + (y - \mu_y)]^2 \rangle$$

- Considere um exemplo simples onde se quer calcular

$$z = x + y$$

$$\sigma_z^2 = \langle (z - \mu_z)^2 \rangle$$

- Substituindo a fórmula no cálculo da variância:

$$\sigma_z^2 = \langle [x + y - (\mu_x + \mu_y)]^2 \rangle$$

$$\sigma_z^2 = \langle [(x - \mu_x) + (y - \mu_y)]^2 \rangle$$

$$\sigma_z^2 = \langle (x - \mu_x)^2 \rangle + \langle (y - \mu_y)^2 \rangle + 2 \langle (x - \mu_x)(y - \mu_y) \rangle$$

- Considere um exemplo simples onde se quer calcular

$$z = x + y$$

$$\sigma_z^2 = \langle (z - \mu_z)^2 \rangle$$

- Substituindo a fórmula no cálculo da variância:

$$\sigma_z^2 = \langle [x + y - (\mu_x + \mu_y)]^2 \rangle$$

$$\sigma_z^2 = \langle [(x - \mu_x) + (y - \mu_y)]^2 \rangle$$

$$\sigma_z^2 = \langle (x - \mu_x)^2 \rangle + \langle (y - \mu_y)^2 \rangle + 2 \langle (x - \mu_x)(y - \mu_y) \rangle$$

$$\sigma_z^2 = \sigma_x^2 + \sigma_y^2 + 2\text{COV}_{xy} \quad \text{COV}_{xy} = \langle (x - \mu_x)(y - \mu_y) \rangle$$

# Fórmula geral

- Seja uma grandeza calculada através de uma função qualquer

$$y = f(x_1, x_2, \dots, x_n) = f(\tilde{x})$$

# Fórmula geral

- Seja uma grandeza calculada através de uma função qualquer

$$y = f(x_1, x_2, \dots, x_n) = f(\tilde{x})$$

$$\sigma_y^2 = \langle [f(\tilde{x}) - f(\mu_x)]^2 \rangle$$

# Fórmula geral

- Seja uma grandeza calculada através de uma função qualquer

$$y = f(x_1, x_2, \dots, x_n) = f(\tilde{x})$$

$$\sigma_y^2 = \langle [f(\tilde{x}) - f(\mu_x)]^2 \rangle$$

- Fazendo uma expansão em série de Taylor da função em primeira ordem:

$$f(\tilde{x}) = f(\mu_x) + \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i)$$

# Fórmula geral

- Seja uma grandeza calculada através de uma função qualquer

$$y = f(x_1, x_2, \dots, x_n) = f(\tilde{x})$$

$$\sigma_y^2 = \left\langle [f(\tilde{x}) - f(\mu_x)]^2 \right\rangle$$

- Fazendo uma expansão em série de Taylor da função em primeira ordem:

$$f(\tilde{x}) = f(\mu_x) + \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i)$$

$$\sigma_y^2 = \left\langle \left[ f(\mu_x) + \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) - f(\mu_x) \right]^2 \right\rangle$$

# Fórmula geral

- Seja uma grandeza calculada através de uma função qualquer

$$y = f(x_1, x_2, \dots, x_n) = f(\tilde{x})$$

$$\sigma_y^2 = \left\langle [f(\tilde{x}) - f(\mu_x)]^2 \right\rangle$$

- Fazendo uma expansão em série de Taylor da função em primeira ordem:

$$f(\tilde{x}) = f(\mu_x) + \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i)$$

$$\sigma_y^2 = \left\langle \left[ f(\mu_x) + \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) - f(\mu_x) \right]^2 \right\rangle$$

$$\sigma_y^2 = \left\langle \left[ \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) \right]^2 \right\rangle$$

$$\sigma_y^2 = \left\langle \left[ \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) \right]^2 \right\rangle$$

- Pegando esta equação e abrindo explicitamente o quadrado, podemos reagrupar os termos de tal forma que:

$$\sigma_y^2 = \left\langle \left[ \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) \right]^2 \right\rangle$$

- Pegando esta equação e abrindo explicitamente o quadrado, podemos reagrupar os termos de tal forma que:

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \langle (x_i - \mu_i)^2 \rangle + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \langle (x_i - \mu_i)(x_j - \mu_j) \rangle$$

$$\sigma_y^2 = \left\langle \left[ \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) \right]^2 \right\rangle$$

- Pegando esta equação e abrindo explicitamente o quadrado, podemos reagrupar os termos de tal forma que:

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \langle (x_i - \mu_i)^2 \rangle + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \langle (x_i - \mu_i)(x_j - \mu_j) \rangle$$

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \Gamma^T \Sigma \Gamma$$

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \Gamma^T \Sigma \Gamma$$

$$\Gamma = \begin{pmatrix} \partial_{x_1} \\ \partial_{x_2} \\ \dots \\ \partial_{x_n} \end{pmatrix} \quad \text{com } \partial_{x_i} = \frac{\partial f}{\partial x_i}$$

# Fórmula geral

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \Gamma^T \Sigma \Gamma$$

$$\Gamma = \begin{pmatrix} \partial_{x_1} \\ \partial_{x_2} \\ \dots \\ \partial_{x_n} \end{pmatrix} \quad \text{com } \partial_{x_i} = \frac{\partial f}{\partial x_i} \quad \Sigma = \begin{pmatrix} \sigma_1^2 & \text{COV}_{12} & \dots & \text{COV}_{1n} \\ \text{COV}_{21} & \sigma_2^2 & \dots & \text{COV}_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \text{COV}_{n1} & \text{COV}_{n2} & \dots & \sigma_n^2 \end{pmatrix}$$

# Fórmula geral

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \Gamma^T \Sigma \Gamma$$

$$\Gamma = \begin{pmatrix} \partial_{x_1} \\ \partial_{x_2} \\ \dots \\ \partial_{x_n} \end{pmatrix} \quad \text{com } \partial_{x_i} = \frac{\partial f}{\partial x_i} \quad \Sigma = \begin{pmatrix} \sigma_1^2 & \text{COV}_{12} & \dots & \text{COV}_{1n} \\ \text{COV}_{21} & \sigma_2^2 & \dots & \text{COV}_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \text{COV}_{n1} & \text{COV}_{n2} & \dots & \sigma_n^2 \end{pmatrix}$$

$\Sigma$  é chamada de matriz de covariância

- Mediu-se o tempo de queda de um balão de uma altura  $h = 34,0 \pm 0,5$  m e obteve-se  $t = 2,65 \pm 0,20$  s. Qual a aceleração?

- Mediu-se o tempo de queda de um balão de uma altura  $h = 34,0 \pm 0,5$  m e obteve-se  $t = 2,65 \pm 0,20$  s. Qual a aceleração?

$$a = 2\frac{h}{t^2}$$

- Mediu-se o tempo de queda de um balão de uma altura  $h = 34,0 \pm 0,5$  m e obteve-se  $t = 2,65 \pm 0,20$  s. Qual a aceleração?

$$a = 2 \frac{h}{t^2}$$

$$\sigma_a^2 = \left( \frac{\partial f}{\partial h} \right)^2 \sigma_h^2 + \left( \frac{\partial f}{\partial t} \right)^2 \sigma_t^2$$

- Mediu-se o tempo de queda de um balão de uma altura  $h = 34,0 \pm 0,5$  m e obteve-se  $t = 2,65 \pm 0,20$  s. Qual a aceleração?

$$a = 2\frac{h}{t^2}$$

$$\sigma_a^2 = \left(\frac{\partial f}{\partial h}\right)^2 \sigma_h^2 + \left(\frac{\partial f}{\partial t}\right)^2 \sigma_t^2 = \left(\frac{2}{t^2}\right)^2 \sigma_h^2 + \left(-\frac{4h}{t^3}\right)^2 \sigma_t^2$$

- Mediu-se o tempo de queda de um balão de uma altura  $h = 34,0 \pm 0,5$  m e obteve-se  $t = 2,65 \pm 0,20$  s. Qual a aceleração?

$$a = 2\frac{h}{t^2}$$

$$\sigma_a^2 = \left(\frac{\partial f}{\partial h}\right)^2 \sigma_h^2 + \left(\frac{\partial f}{\partial t}\right)^2 \sigma_t^2 = \left(\frac{2}{t^2}\right)^2 \sigma_h^2 + \left(-\frac{4h}{t^3}\right)^2 \sigma_t^2$$

- Substituindo os valores

$$a = 9,7 \pm 1,5 \text{ m/s}^2$$

# E a covariância?

- A covariância é dada por

$$\text{COV}_{xy} = \langle (x - \mu_x)(y - \mu_y) \rangle$$

# E a covariância?

- A covariância é dada por

$$\text{COV}_{xy} = \langle (x - \mu_x)(y - \mu_y) \rangle$$


- Se as variáveis  $x$  e  $y$  são totalmente independentes, elas podem flutuar de maneira independente e a somatória tende a se anular, de modo que:

$$\text{COV}_{xy} = 0$$

# Quando grandezas são dependentes entre si?

- A situação mais comum é no ajuste de uma curva.
  - ▶ Os parâmetros ajustados possuem, em geral, covariância, pois estão vinculados entre si através dos pontos experimentais.
  - ▶ Se eu forçar o coeficiente linear para um valor maior eu devo diminuir o coeficiente angular para continuar passando pelos pontos experimentais.

dados  $f(x) = ax + b$



# Um exemplo: a curva característica da pilha

- Matriz de covariância do ajuste

$$y = [0] + [1] * x = a + bx$$

### Resultados do ajuste


Número de parâmetros	2
Chi <sup>2</sup>	3.42626
Número de graus de liberdade	5

parâmetro	Valor	Incerteza
0	1.4856	0.00837212
1	-0.292165	0.0186493

### Matriz de covariância

$$\begin{bmatrix} 7.00924\text{E-}05 & -0.000139318 \\ -0.000139318 & 0.000347797 \end{bmatrix}$$

Curva característica da pilha



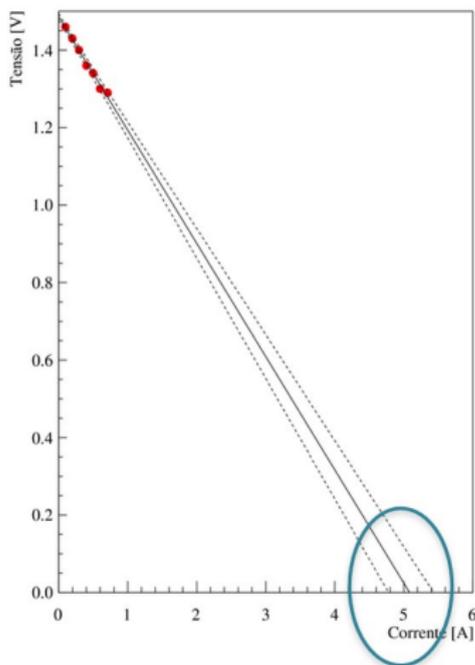
# Um exemplo: a curva característica da pilha

- Qual a corrente máxima?
  - ▶ Extrapola para tensão = 0

$$i_{max} = -\frac{a}{b} = -\frac{[0]}{[1]}$$

- Qual a incerteza na corrente máxima?

Curva característica da pilha



## Um exemplo: a curva característica da pilha

- Qual a incerteza na corrente máxima?

$$i_{max} = -\frac{a}{b}$$

## Um exemplo: a curva característica da pilha

- Qual a incerteza na corrente máxima?

$$i_{max} = -\frac{a}{b}$$

$$\sigma_{i_{max}}^2 = \left(\frac{\partial i_{max}}{\partial a}\right)^2 \sigma_a^2 + \left(\frac{\partial i_{max}}{\partial b}\right)^2 \sigma_b^2 + 2\frac{\partial i_{max}}{\partial a} \frac{\partial i_{max}}{\partial b} \text{COV}_{ab}$$

- Calculando as derivadas, temos:

$$\sigma_{i_{max}}^2 = \frac{1}{b^2} \sigma_a^2 + \frac{a^2}{b^4} \sigma_b^2 - 2\frac{a}{b^3} \text{COV}_{ab}$$

- E é só substituir os valores

# Faz diferença utilizar a covariância?

- Depende da situação
- Vamos estudar a covariância em detalhes mais tarde
  - ▶ Por enquanto vamos nos acostumar com a existência dela e utilizar quando necessário.
  - ▶ Sempre que formos utilizar parâmetros de um ajuste para fazer contas, fiquem atentos à covariância.

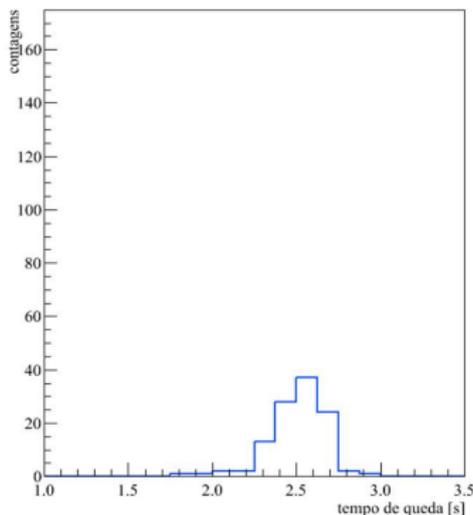
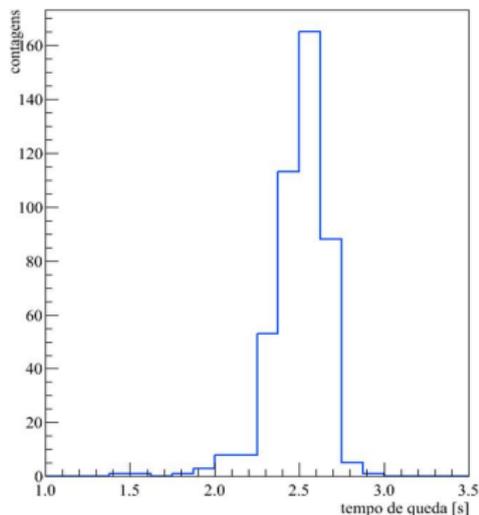
- Consideramos que todas as grandezas envolvidas possuem distribuições gaussianas
  - ▶ E se não possuírem?
    - ★ Veremos como lidar com isto em breve
- Fizemos uma expansão em Taylor de primeira ordem.
  - ▶ Esta expansão é sempre razoável?
  - ▶ E se não for? O que devemos fazer?
    - ★ Respostas em um futuro próximo

# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 **Tratamento estatístico**
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

# Repetição de um experimento

- Histogramas simples de contagens não são interessantes pois a comparação entre dois conjuntos de dados diferentes nem sempre é possível de forma direta
  - ▶ Depende do número de entradas no histograma



- Define-se a probabilidade de se obter um determinado resultado como sendo a relação entre o número de vezes que esse resultado é obtido dividido pelo número total de dados, quando este é suficientemente grande

$$P(R) = \lim_{N \rightarrow \infty} \frac{N(R)}{N}$$

- Define-se a probabilidade de se obter um determinado resultado como sendo a relação entre o número de vezes que esse resultado é obtido dividido pelo número total de dados, quando este é suficientemente grande

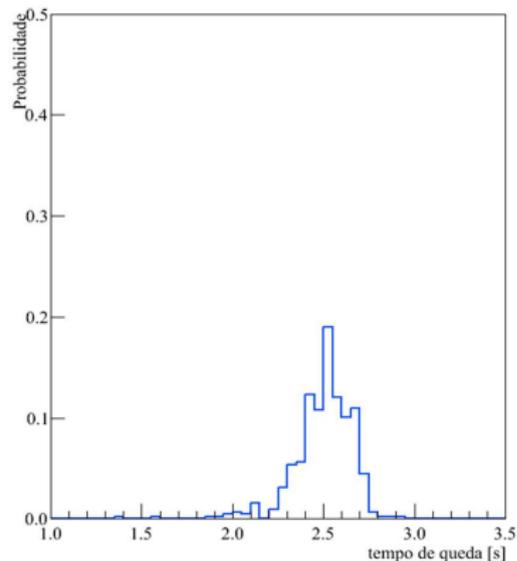
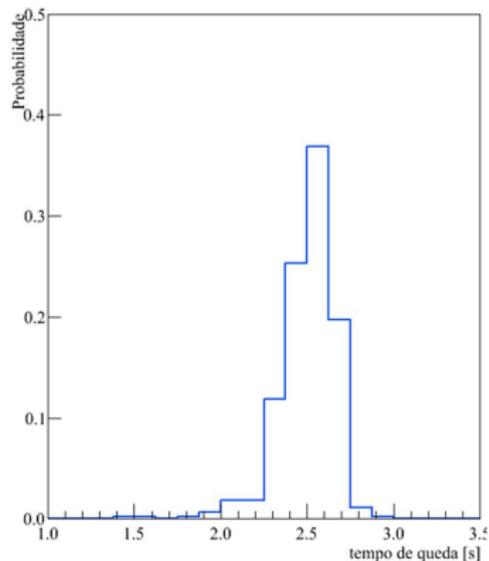
$$P(R) = \lim_{N \rightarrow \infty} \frac{N(R)}{N}$$

- Em um histograma definem-se canais e contam-se quantas ocorrências tem-se naquele canal

$$N(R) = N(x, x + \Delta x)$$

- ▶ Em um histograma a probabilidade depende da escolha do tamanho do canal do histograma

# Histogramas de probabilidade



- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

- A Função Densidade de Probabilidade (FDP) é definida de tal forma que a probabilidade de encontrar um resultado em um intervalo é tal que



$$P(x, x + \Delta x) = \int_x^{x+\Delta x} H(x') dx'$$

- Ou seja

$$H(x) = \lim_{\Delta x \rightarrow 0} \frac{P(x, x + \Delta x)}{\Delta x}$$

- ▶ A densidade de probabilidade não depende da escolha do tamanho do canal em um histograma
  - ★ A menos de flutuações por conta da amostra ser limitada

# Histogramas de densidade de probabilidade



- Por ter significado de uma densidade é sempre positiva

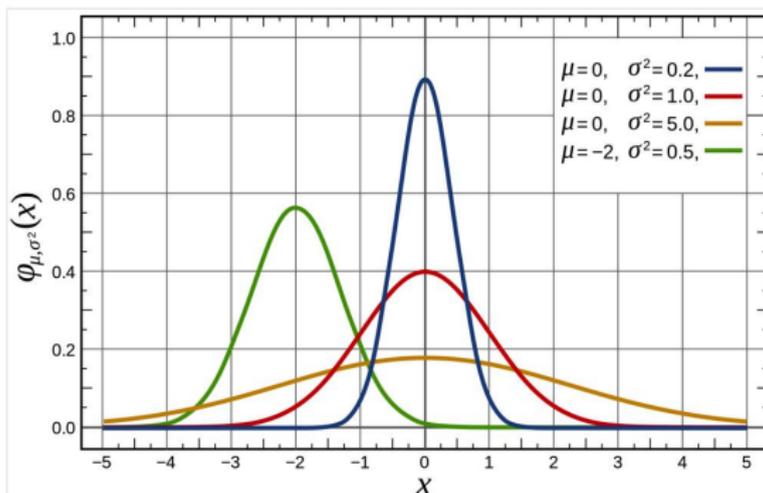
- Por ter significado de uma densidade é sempre positiva
- Como a probabilidade é sempre um número entre 0 e 1, a integral da densidade de probabilidade em todo o espaço deve ser a probabilidade de ter um evento, quaisquer que sejam suas características, ou seja, 100%. Deste modo

$$\int_{-\infty}^{\infty} H(x') dx' = 1$$

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

# A gaussiana

$$H(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$



- Será que tudo que é derivado de uma grandeza gaussiana também possui FDP gaussiana?

- Seja uma grandeza qualquer ( $x$ ) que possua FDP gaussiana de valor verdadeiro  $\mu$  e variância  $\sigma_\mu$  conhecidos.

# Experimento virtual

- Seja uma grandeza qualquer ( $x$ ) que possua FDP gaussiana de valor verdadeiro  $\mu$  e variância  $\sigma_\mu$  conhecidos.
- Realiza-se um experimento no qual são tomadas  $\nu$  medidas independentes desta grandeza e o resultado do experimento é o valor médio dessas medidas

$$\bar{x} = \frac{1}{\nu} \sum_{i=1}^{\nu} x_i$$

- Seja uma grandeza qualquer ( $x$ ) que possua FDP gaussiana de valor verdadeiro  $\mu$  e variância  $\sigma_\mu$  conhecidos.
- Realiza-se um experimento no qual são tomadas  $\nu$  medidas independentes desta grandeza e o resultado do experimento é o valor médio dessas medidas

$$\bar{x} = \frac{1}{\nu} \sum_{i=1}^{\nu} x_i$$

- Calcula-se também a variância “experimental” destas medidas em relação ao valor verdadeiro

$$\sigma^2 = \frac{1}{\nu} \sum_{i=1}^{\nu} (x_i - \mu)^2$$

# Experimento virtual

- Seja uma grandeza qualquer ( $x$ ) que possua FDP gaussiana de valor verdadeiro  $\mu$  e variância  $\sigma_\mu$  conhecidos.
- Realiza-se um experimento no qual são tomadas  $\nu$  medidas independentes desta grandeza e o resultado do experimento é o valor médio dessas medidas

$$\bar{x} = \frac{1}{\nu} \sum_{i=1}^{\nu} x_i$$

- Calcula-se também a variância “experimental” destas medidas em relação ao valor verdadeiro

$$\sigma^2 = \frac{1}{\nu} \sum_{i=1}^{\nu} (x_i - \mu)^2$$

- Como são as FDPs do valor médio e da variância? São gaussianas? O valor médio da variância experimental coincide com a variância real? Qual a dependência dessas FDPs com o número de medidas realizadas,  $\nu$ ?



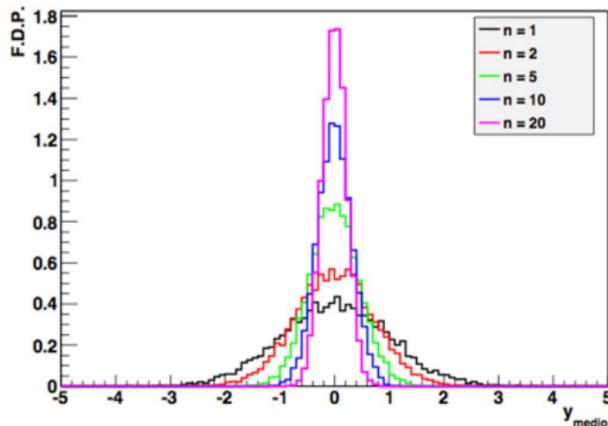
- Considere que um experimentador repita, diariamente, o experimento descrito anteriormente e calcule, para cada dia, o valor da média e o valor de  $\chi^2$  e coloque os resultados em um histograma. No final da vida dele ele vai ter repetido isso tantas vezes que é possível conhecer as FDPs dessas duas grandezas.
- Para facilitar, vamos considerar  $\mu = 0$  e  $\sigma_\mu = 1$ . Não há perda de generalidade pois sempre podemos fazer uma mudança de variáveis do tipo:

$$\frac{x - \mu}{\sigma_\mu} \rightarrow y$$

- Por sorte existem computadores e pode-se simular este experimento computacionalmente, bem como a repetição do mesmo indefinidamente.

# Distribuição do valor médio

- Continua sendo uma gaussiana
  - ▶ A média não se altera com  $\nu$  ( $n$  na figura)
  - ▶ Na medida em que  $\nu$  ( $n$  na figura) aumenta, a gaussiana fica mais estreita

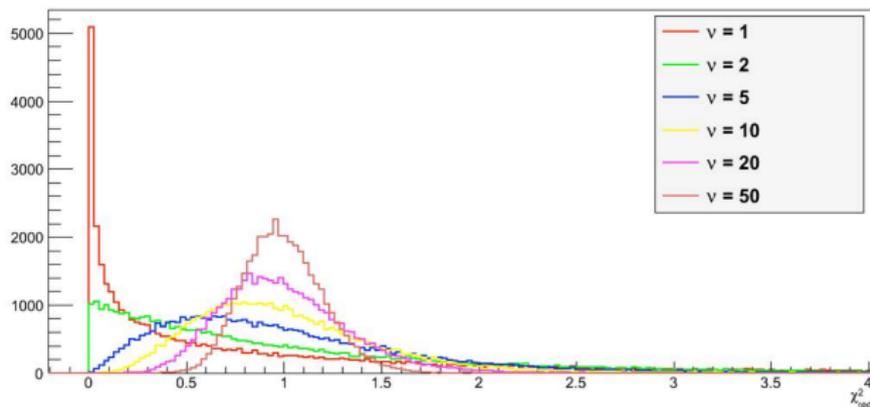


$$\sigma^2 = \frac{1}{\nu} \sum_{i=1}^{\nu} (x_i - \mu)^2 = \frac{1}{\nu} \sum_{i=1}^{\nu} y_i^2$$

- Como os termos da somatória são sempre positivos não é esperado que ela tenha média zero.
- O valor médio da variância é 1 (um), como esperado para o seu valor verdadeiro?

# A distribuição da variância “experimental”

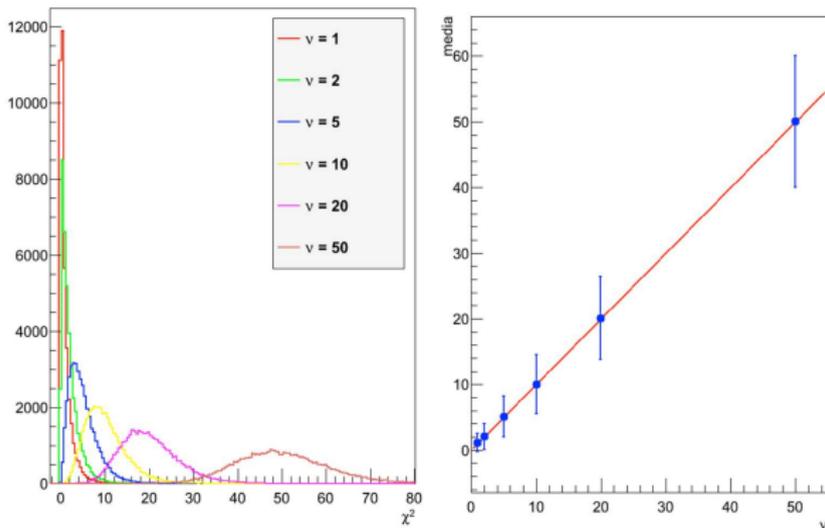
- Para um número pequeno de pontos a distribuição claramente não é gaussiana
- Para poucos pontos tem-se a tendência de SUBESTIMAR a variância dos dados



# Distribuição de $\chi^2$

$$\chi^2 = \sum_{i=1}^{\nu} \left( \frac{x_i - \mu}{\sigma_{\mu}} \right)^2 = \sum_{i=1}^{\nu} y_i^2$$

- A FDP do  $\chi^2$  não é gaussiana
- O valor médio da distribuição de  $\chi^2$  é  $\nu$ .

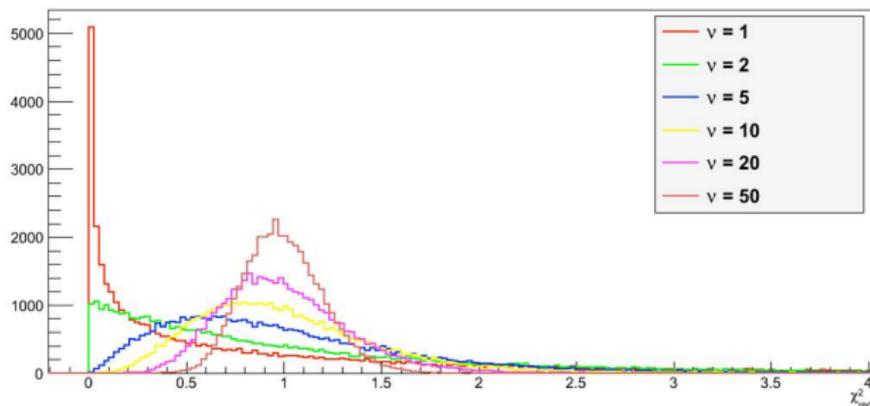


# O $\chi^2$ reduzido

- $\chi^2$  reduzido tem a mesma distribuição da variância!!!!

$$\sigma^2 = \frac{1}{\nu} \sum_{i=1}^{\nu} (x_i - \mu)^2 = \frac{1}{\nu} \sum_{i=1}^{\nu} y_i^2$$

$$\chi_{red}^2 = \frac{1}{\nu} \sum_{i=1}^{\nu} \left( \frac{x_i - \mu}{\sigma_{\mu}} \right)^2 = \frac{1}{\nu} \sum_{i=1}^{\nu} y_i^2$$



- Relembrando, “... Imagine um experimento no qual se realizam  $\nu$  medidas independentes desta grandeza e o resultado do experimento é o valor médio dessas medidas..”
  - ▶  $\nu$  é o número de medidas estatisticamente independentes no experimento. É chamado de **número de graus de liberdade** da amostra.
    - ★ Número de graus de liberdade corresponde à quantidade de valores independentes que podem variar livremente no cálculo de uma grandeza estatística.
    - ★ O que é independente em uma amostra?

- Toma-se um conjunto de dados e calcula-se a sua variância

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$$

- Considere a situação na qual o valor verdadeiro da amostra não é conhecido
  - ▶ A melhor estimativa do valor verdadeiro da amostra corresponde ao valor médio da mesma
  - ▶ A variância seria calculada como:

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$$

- ▶ Note que  $N \rightarrow N - 1$  na expressão acima. Porque disso?

# Número de graus de liberdade

- No momento em que a média é calculada, somente  $N - 1$  pontos são totalmente livres para variar. O último ponto da amostra necessariamente deve ter o valor:

$$x_n = N\bar{x} - \sum_{i=1}^{N-1} x_i$$

- Um dos dados da amostra não é independente dos outros. Ele está vinculado aos demais por conta do valor médio calculado.
- O número de graus de liberdade disponíveis é  $\mathbf{N - 1}$ . Esta é uma interpretação pela qual aparece o  $N - 1$  no cálculo da variância quando não se conhece o valor verdadeiro da amostra.

$$\sigma^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$$

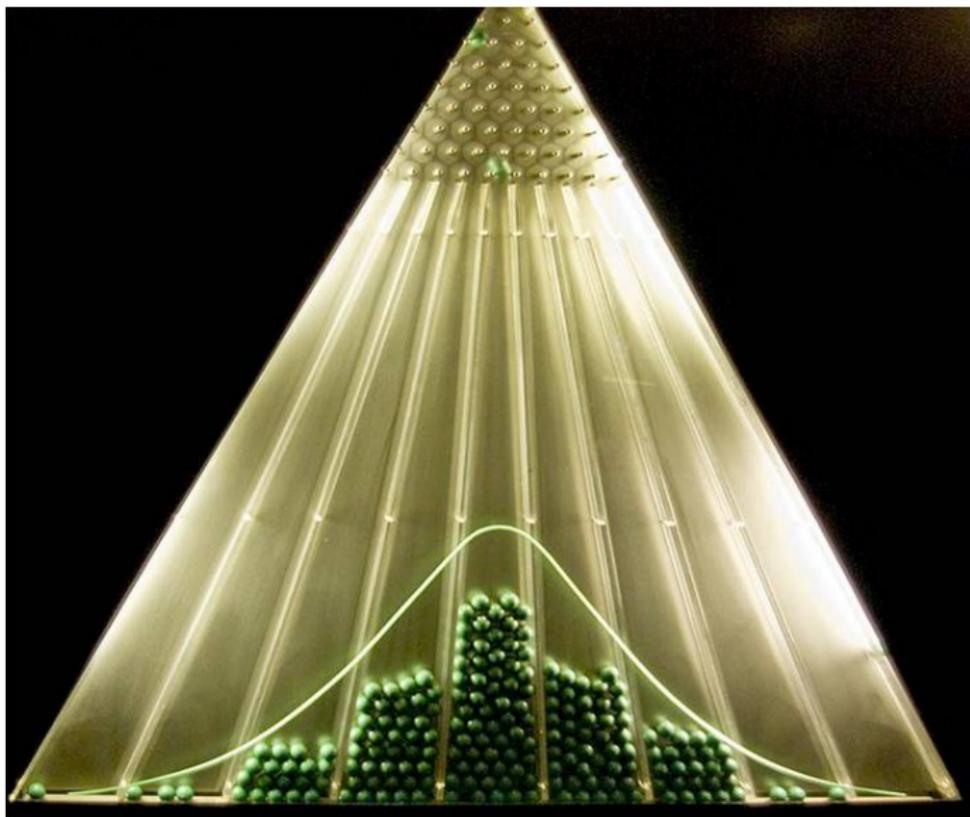
# Porque distribuições de probabilidade são importantes?

- Quando é feita uma medida, ou um conjunto de medidas, queremos saber quão provável é o resultado obtido ou quão confiável é a análise realizada.
  - ▶ A medida é compatível com o valor teórico esperado?
  - ▶ Duas medidas são compatíveis entre si?
  - ▶ O número de pontos neste gráfico é suficiente?
  - ▶ O ajuste de reta que foi feito é bom?
- Para responder estas perguntas precisamos conhecer as distribuições de probabilidade das muitas grandezas envolvidas.

# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

# Caixa de Galton



# Uma pergunta recorrente

- Quando eu sei que o  $\chi^2$  de um ajuste é bom ou ruim?


- Quando eu sei que o  $\chi^2$  de um ajuste é bom ou ruim?
  - ▶  $\chi_{red}^2 \sim 1$ 
    - ★ Ordem de grandeza apenas ou tem algum intervalo numérico definido?

- Quando eu sei que o  $\chi^2$  de um ajuste é bom ou ruim?
  - ▶  $\chi_{red}^2 \sim 1$ 
    - ★ Ordem de grandeza apenas ou tem algum intervalo numérico definido?
  - ▶ E se o  $\chi^2$  for muito grande ou muito pequeno?

# Funções de densidade de probabilidade (FDPs)

- Normal ou gaussiana

$$p(y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{1}{2}\left(\frac{y-\mu}{\sigma}\right)^2}$$



- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

- Vamos realizar um experimento virtual, no qual simularemos a obtenção da amostra  $X_{ngl} = \{x_i\}$

- Vamos realizar um experimento virtual, no qual simularemos a obtenção da amostra  $X_{ngl} = \{x_i\}$
- A partir dessa amostra vamos calcular a variável de interesse (no nosso caso, o  $\chi^2$ )

- Vamos realizar um experimento virtual, no qual simularemos a obtenção da amostra  $X_{ngl} = \{x_i\}$
- A partir dessa amostra vamos calcular a variável de interesse (no nosso caso, o  $\chi^2$ )
- Vamos repetir esse experimento virtual um número muito grande de vezes de modo a obter as FDPs das variáveis estudadas.

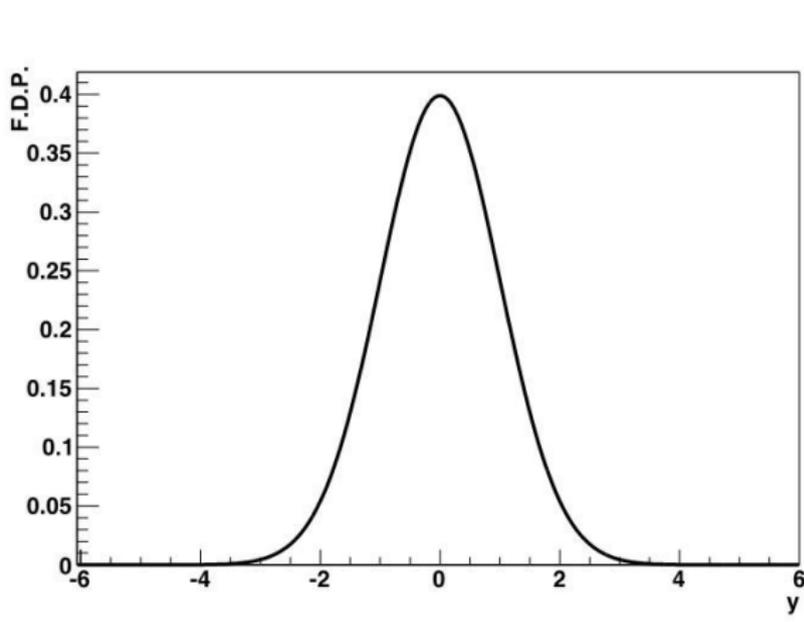
- Ao invés de usar a amostra  $X$ , vamos fazer uma mudança de variável tal que

$$Y = \{y_i\} \longrightarrow y_i = \frac{x_i - \mu}{\sigma_\mu}$$

- Ou seja, vamos estudar uma amostra de valor verdadeiro 0 e variância 1.
  - ▶ Para FDP com médias e variâncias diferentes, basta uma mudança de escala

- $Y$  segue uma distribuição normal de valor verdadeiro 0 e variância 1

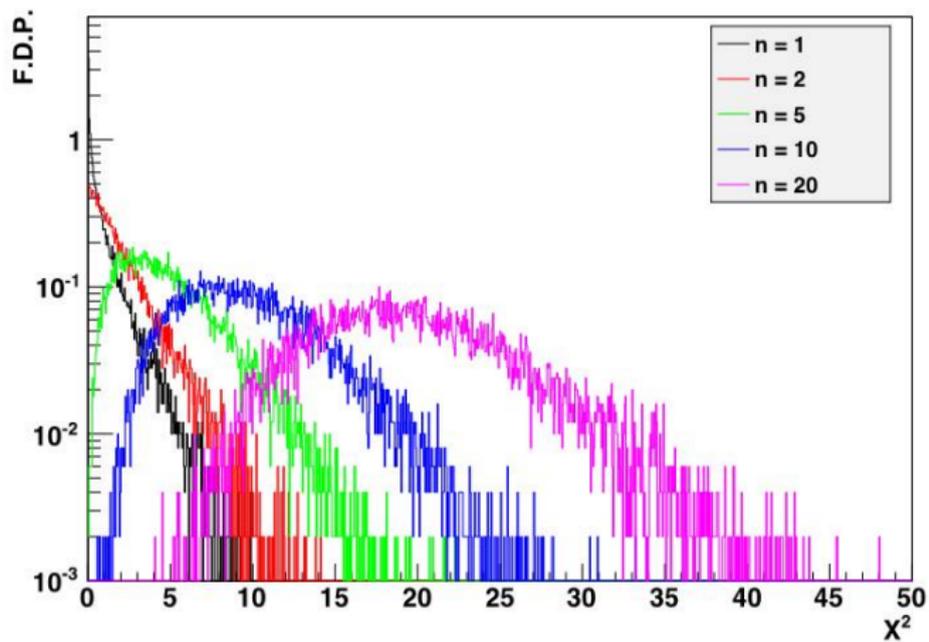
$$p(y) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y^2}$$



- A função  $\chi^2$  é definida como:

$$\chi^2 = \sum_{i=1}^n \left( \frac{x_i - \mu}{\sigma_\mu} \right)^2 = \sum_{i=1}^n y_i^2$$

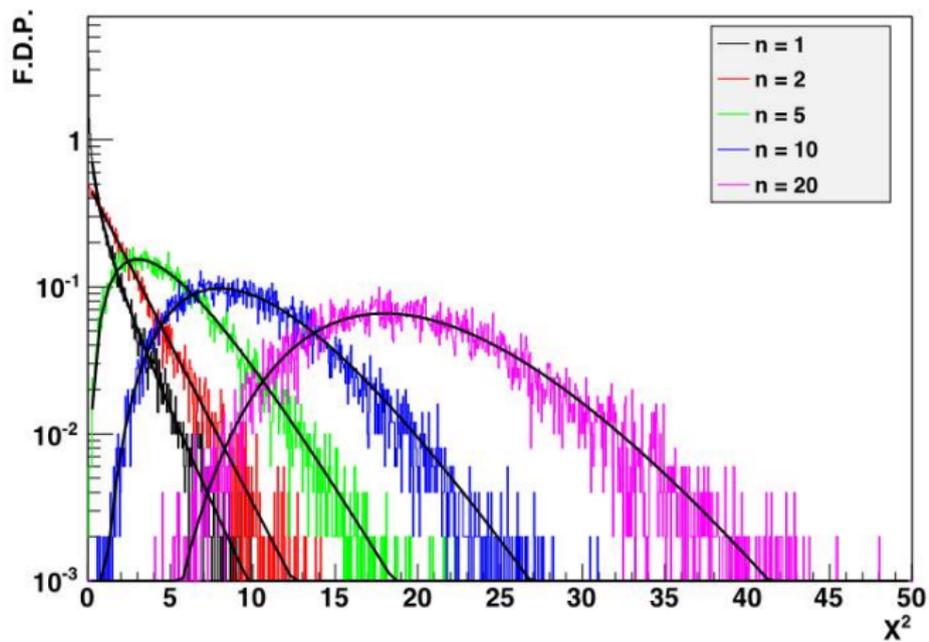
- A FDP é obtida calculando o valor de  $\chi^2$  para cada conjunto de dados simulado



- A FDP não segue mais uma distribuição normal, mas sim:

$$p(\xi) = \frac{1}{2^{\frac{n}{2}} \Gamma\left(\frac{n}{2}\right)} \xi^{\frac{n}{2}-1} e^{-\frac{\xi}{2}}$$

- Onde  $\Gamma$  é a função gama,  $n$  é o número de graus de liberdade e  $\xi$ , o valor de  $\chi^2$ .



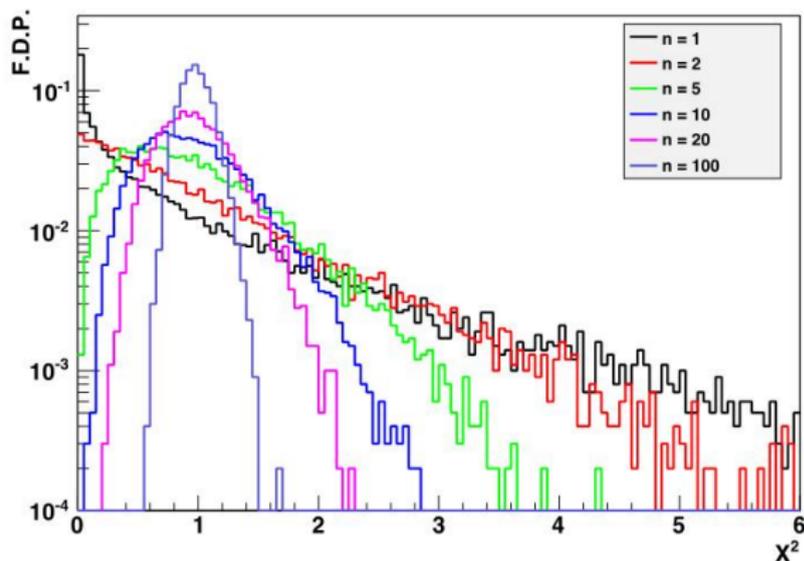
- A função  $\chi_{red}^2$  é definida como:

$$\chi_{red}^2 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \mu}{\sigma_\mu} \right)^2 = \frac{1}{n} \sum_{i=1}^n y_i^2$$

- Por outro lado, a variância de um conjunto de medidas é:

$$\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2 = \frac{1}{n} \sum_{i=1}^n y_i^2$$

- Ou seja, essas grandezas são muito similares e seguem a mesma FDP



- Note que quanto maior o número de graus de liberdade, mais estreita é a distribuição.

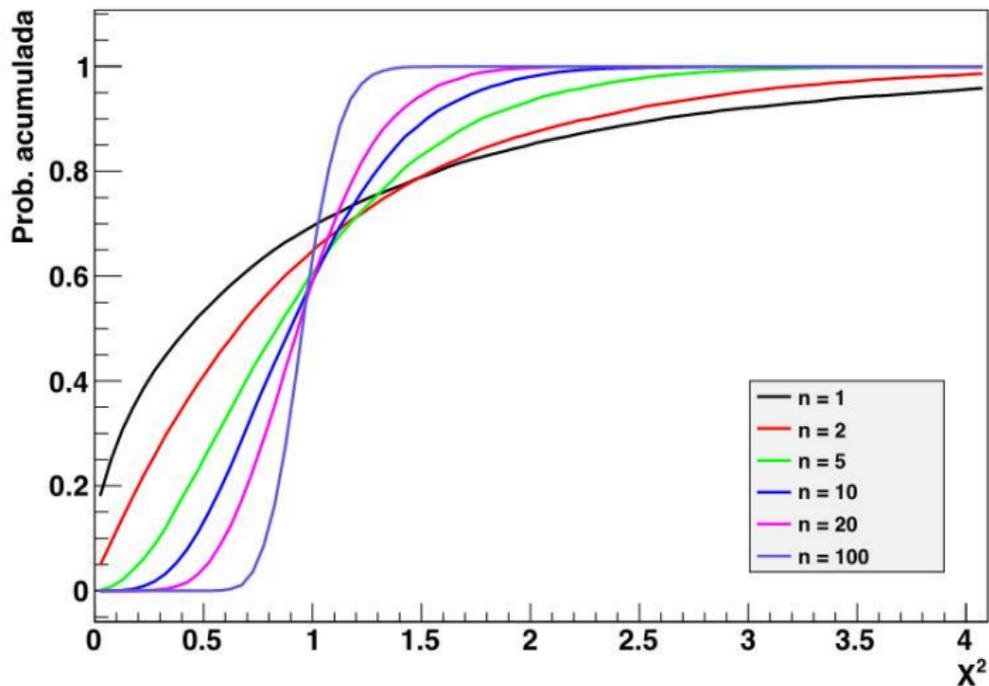
- $\chi_{red}^2$  e  $\sigma$  são importantes em testes de significância
  - ▶ A função  $\chi_{red}^2$  é calculada quando se faz um ajuste de curvas. Como avaliar se o ajuste é bom?
  - ▶ Em uma medida estatística, como saber se a variância que estou obtendo é representativa?

- Podemos definir como probabilidade acumulada a grandeza:


$$P(x) = \int_{-\infty}^x p(t) dt \longrightarrow \left\{ \begin{array}{l} \text{Probabilidade da variável } t \\ \text{assumir um valor menor ou} \\ \text{igual a } x \end{array} \right.$$

- Essa grandeza é particularmente útil para definir intervalos de confiança
  - Ex: qual o intervalo de 90% de confiança para a distribuição de  $\chi_{red}^2$  de um ajuste com 5 graus de liberdade?

# Probabilidade acumulada de $\chi^2_{red}$ (ou $\sigma$ )

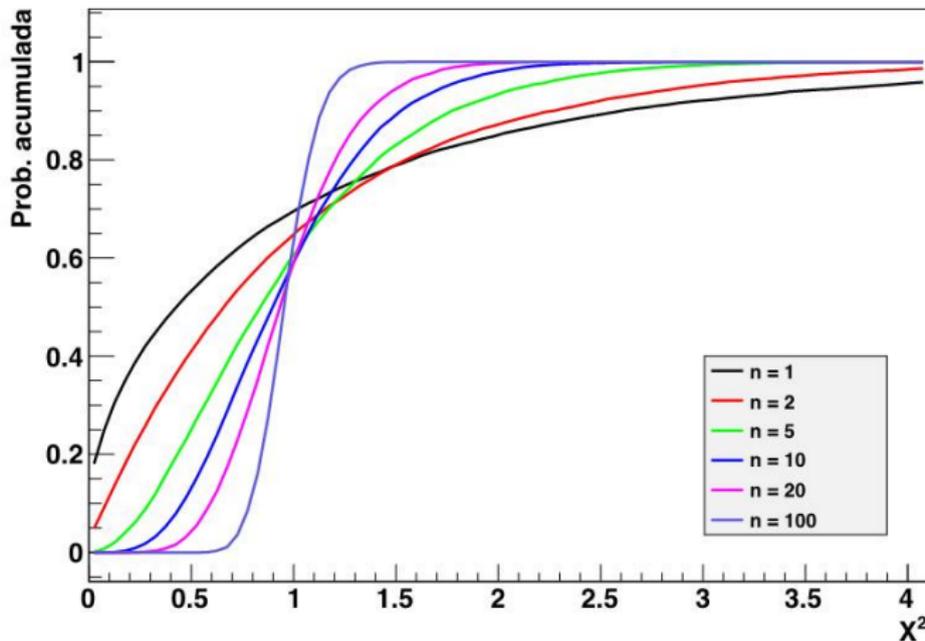


# Probabilidade acumulada de $\chi^2_{red}$ (ou $\sigma$ )



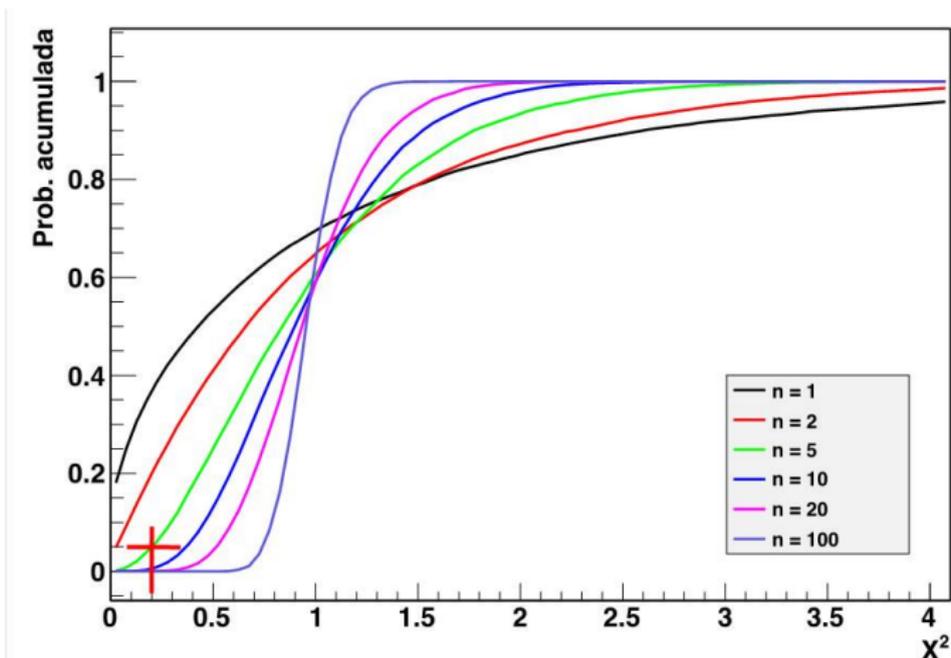
# Probabilidade acumulada de $\chi_{red}^2$ (ou $\sigma$ )

- Se fizermos um ajuste de **5 graus de liberdade**, qual o intervalo esperado de  $\chi_{red}^2$  com 90% de confiança?



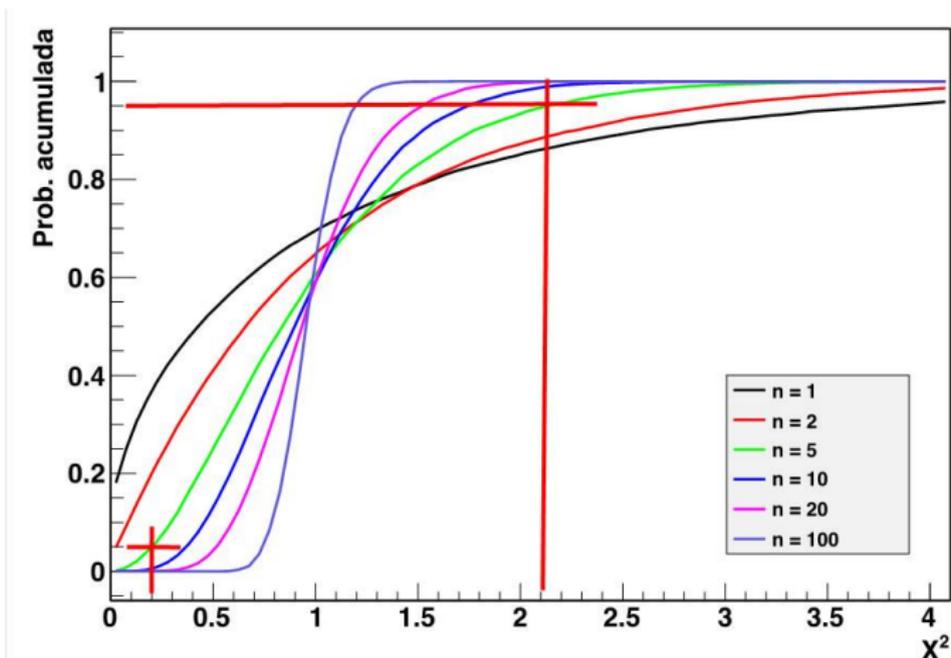
# Probabilidade acumulada de $\chi_{red}^2$ (ou $\sigma$ )

- Se fizermos um ajuste de **5 graus de liberdade**, qual o intervalo esperado de  $\chi_{red}^2$  com 90% de confiança?



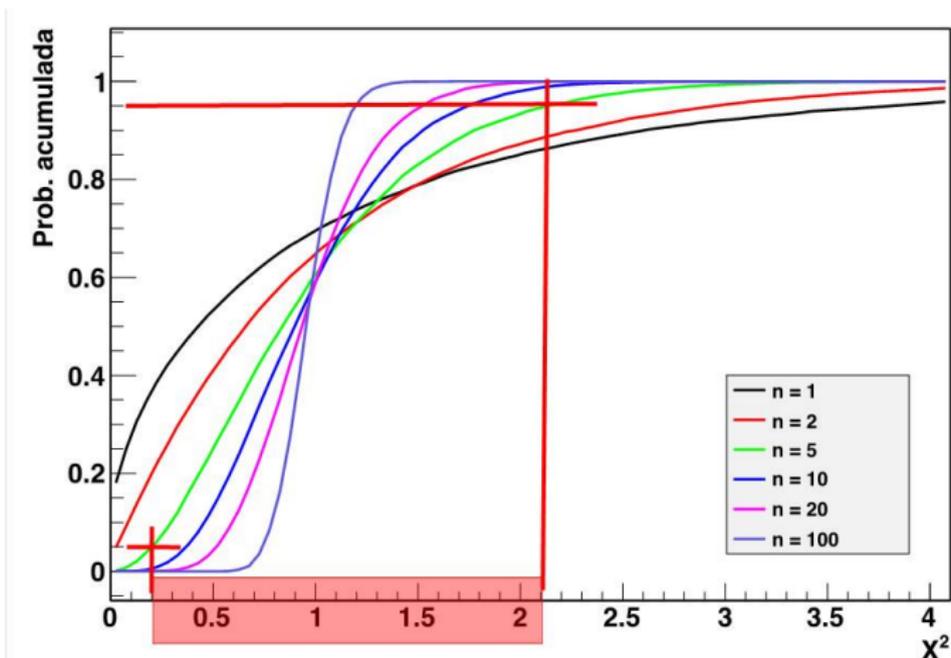
# Probabilidade acumulada de $\chi_{red}^2$ (ou $\sigma$ )

- Se fizermos um ajuste de **5 graus de liberdade**, qual o intervalo esperado de  $\chi_{red}^2$  com 90% de confiança?



# Probabilidade acumulada de $\chi_{red}^2$ (ou $\sigma$ )


- Se fizermos um ajuste de **5 graus de liberdade**, qual o intervalo esperado de  $\chi_{red}^2$  com 90% de confiança?



# Probabilidade acumulada de $\chi_{red}^2$ (ou $\sigma$ )

- Se fizermos um ajuste de **5 graus de liberdade**, qual o intervalo esperado de  $\chi_{red}^2$  com 90% de confiança?

$$0,2 < \chi_{red}^2 < 2,1$$



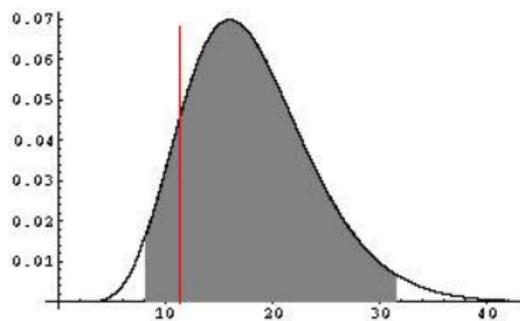


- Testes de  $\chi^2$  e análise de resíduos (análise mesmo, não apenas fazer um gráfico) constituem ferramentas poderosas na validação de resultados experimentais
- Cálculo de intervalo de confiança para  $\chi^2$ , teste-z, teste-t, etc.
  - ▶ No WebROOT → Calculadoras
- E se o valor de  $\chi^2$  estiver fora do intervalo de significância?
  - ▶ Em geral:
    - ★ Incertezas super/subestimadas
    - ★ Modelo teórico não se aplica aos dados

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$



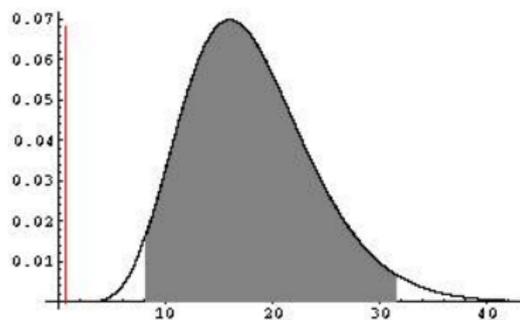
# Um bom ajuste

- $\chi^2 = 11,45$
- $ngl = 18$
- 95% CL =  $8,2 < \chi^2 < 32$



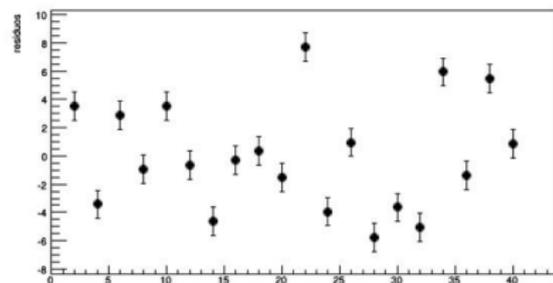
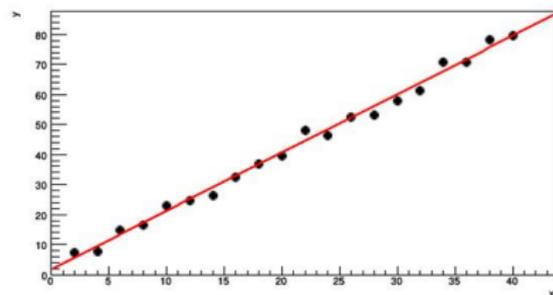
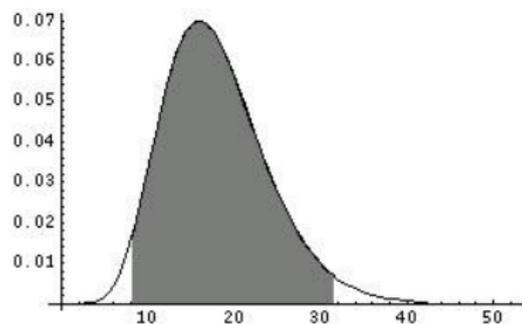
# Incertezas superestimadas

- $\chi^2 = 0,45$
- $ngl = 18$
- 95% CL =  $8,2 < \chi^2 < 32$



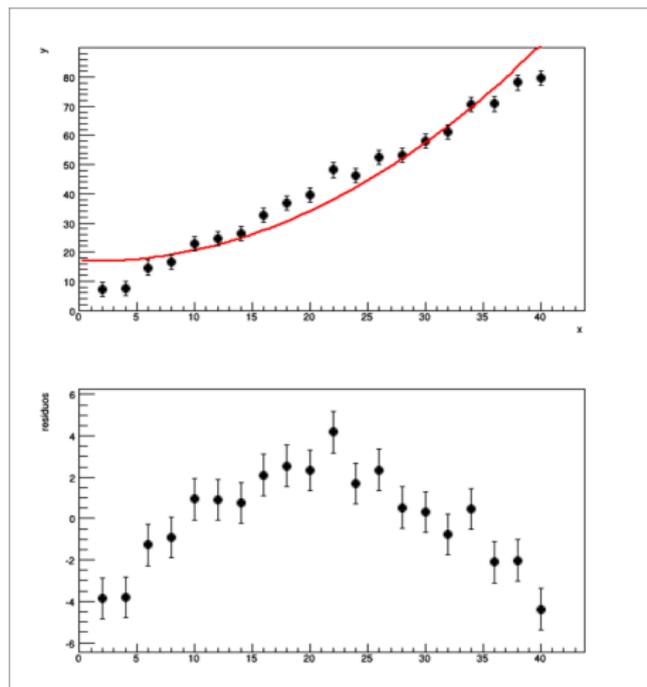

# Incertezas subestimadas

- $\chi^2 = 286$
- $n_{gl} = 18$
- 95% CL =  $8,2 < \chi^2 < 32$



# Função incorreta

- $\chi^2 = 105$
- $n_{gl} = 18$
- 95% CL =  $8,2 < \chi^2 < 32$



# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

- Fórmula “geral”

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Fórmula “geral”

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Exemplo (sem covariância)

▶  $a = 5.0 \pm 1.0$  e  $b = 1.0 \pm 0.5$

$$y = \frac{a}{b}$$

- Fórmula “geral”

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Exemplo (sem covariância)

▶  $a = 5.0 \pm 1.0$  e  $b = 1.0 \pm 0.5$

$$y = \frac{a}{b} \Rightarrow y = 5.0 \pm 2.7$$

- Supomos que  $a$  e  $b$  seguem uma FDP gaussiana

## O que está por trás desta conta

- Supomos que  $a$  e  $b$  seguem uma FDP gaussiana
- Supomos que  $y$  também será gaussiana

# O que está por trás desta conta

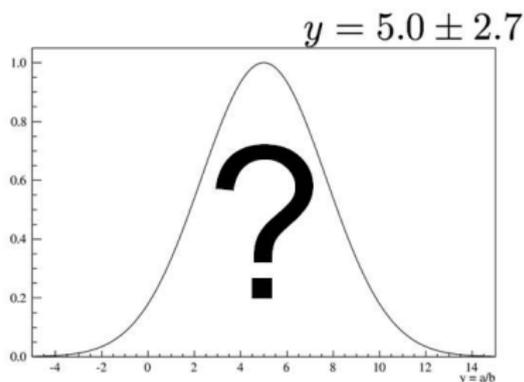


- Supomos que  $a$  e  $b$  seguem uma FDP gaussiana
- Supomos que  $y$  também será gaussiana
- De fato, tomar uma expansão de Taylor de primeira ordem apenas faz transformações lineares de  $a, b \rightarrow y$ 
  - ▶ Valor médio de  $y$  calculado a partir dos valores médios de  $a$  e  $b$
  - ▶ Variância de  $y$  calculada a partir da propagação de incertezas

# O que está por trás desta conta

- Supomos que  $a$  e  $b$  seguem uma FDP gaussiana
- Supomos que  $y$  também será gaussiana
- De fato, tomar uma expansão de Taylor de primeira ordem apenas faz transformações lineares de  $a, b \rightarrow y$ 
  - ▶ Valor médio de  $y$  calculado a partir dos valores médios de  $a$  e  $b$
  - ▶ Variância de  $y$  calculada a partir da propagação de incertezas
- Isto é válido sempre?  $y$  será sempre gaussiano, se  $a$  e  $b$  forem?

- Somente estatística por enquanto
- Aprendemos que incerteza é uma estimativa do erro da medida
- Uma forma de obter a incerteza é repetir o experimento muitas vezes, tomar os dados e estudar a flutuação destes dados em torno da média
  - ▶ Desvio padrão dos dados!

# O que está por trás no nosso exemplo? Isto é válido?




- Método de Monte Carlo
  - ▶ Conjunto de métodos computacionais, baseados na repetição, dependente de números aleatórios, para calcular um determinado resultado.

## Exemplo: cálculo de pi



- Seja um quadrado de lado 2.
- Sorteia-se um par de números, aleatórios e uniformes,  $x$  e  $y$  entre -1 e 1
- Se  $x^2 + y^2 < R$  com  $R = 1$ , o par está dentro de um círculo inscrito ao quadrado
- Conta-se quantos pares estão inscritos ( $n$ ) e quantos são sorteados ( $N$ ).

$$\frac{n}{N} = \frac{A_{circ}}{A_{quad}} = \frac{\pi R^2}{L^2} = \frac{\pi}{4}$$



- O método “simula” a repetição de um experimento virtual
- Quanto maior a repetição, menor a incerteza no resultado
- Ex: cálculo de  $\pi$ 
  - ▶  $N = 100 \rightarrow \pi = 3.4$
  - ▶  $N = 10000000 \rightarrow \pi = 3.14143$
- Repetir o cálculo não deve dar o mesmo resultado
  - ▶  $N = 100 \rightarrow \pi = 3.4, 3.0, 3.3, \text{etc.}$
  - ▶  $N = 10000000 \rightarrow \pi = 3.14143, 3.14119, 3.14215, \text{etc.}$
  - ▶ Note que a incerteza diminui.

# Incertezas de $\pi$

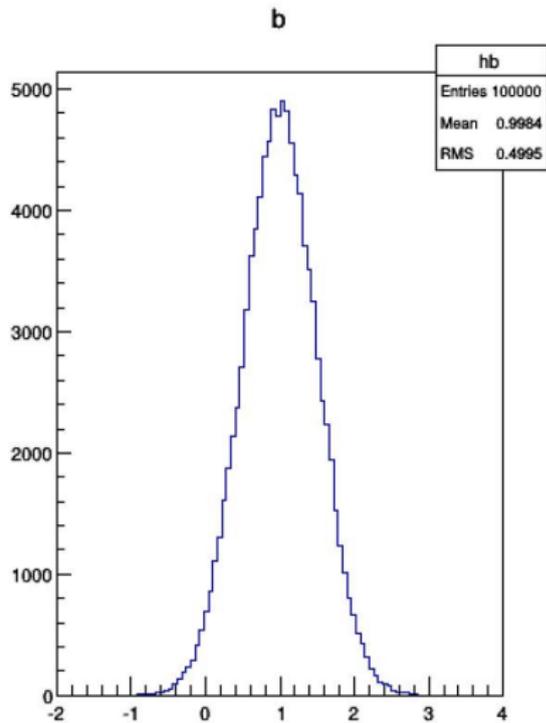
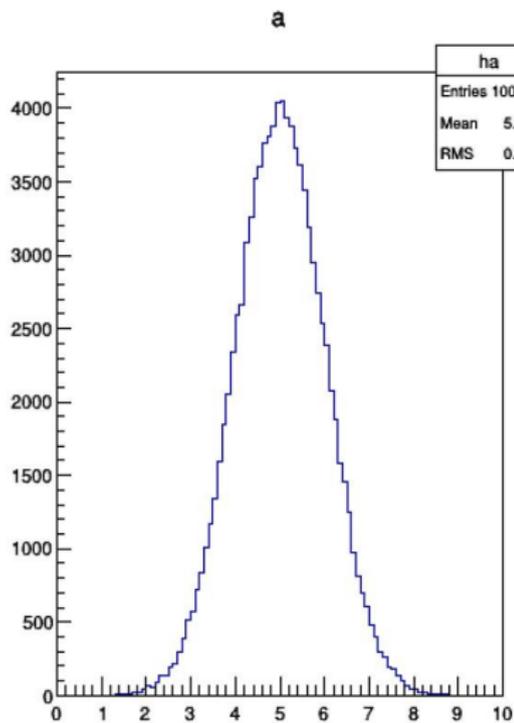


Note a diferença dos resultados!

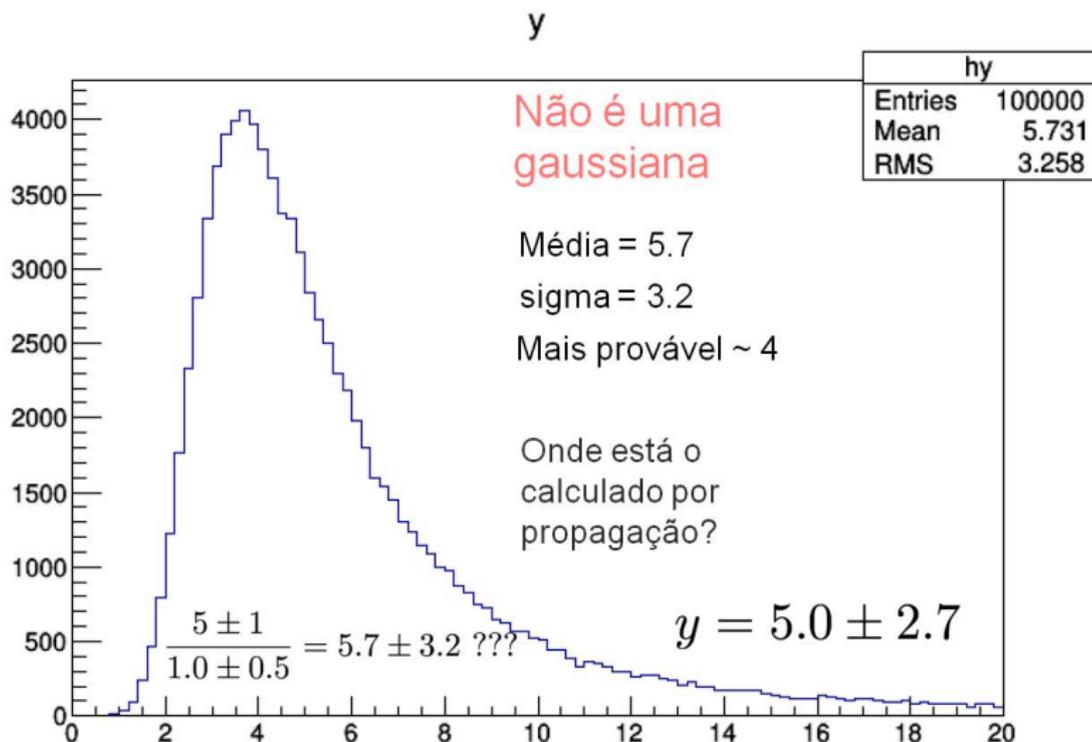
# Como achar a FDP de $y$ ?

- Vamos usar o método de Monte Carlo
  - ▶ Sorteamos  $a$  com uma distribuição gaussiana de média 5 e desvio padrão 1
  - ▶ Sorteamos  $b$  com uma distribuição gaussiana com média 1 e desvio padrão 0.5
  - ▶ Calculamos  $y = a/b$  e colocamos em um histograma
  - ▶ Repetimos o cálculo  $N$  vezes, com  $N$  grande

# Após muitas iterações



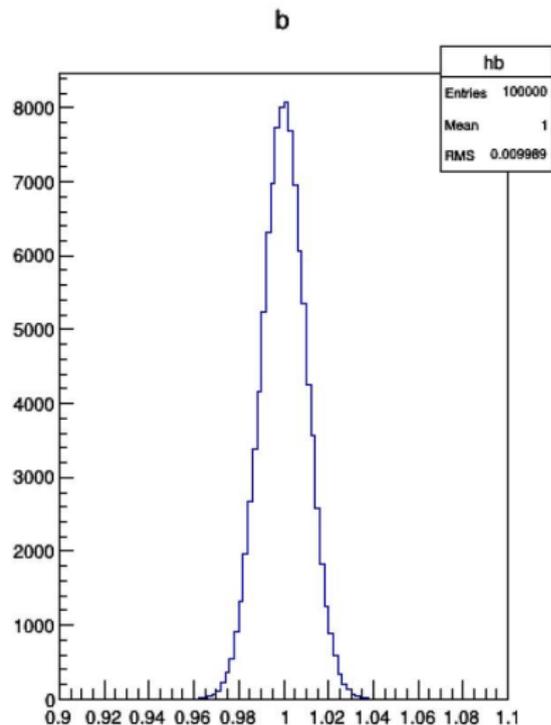
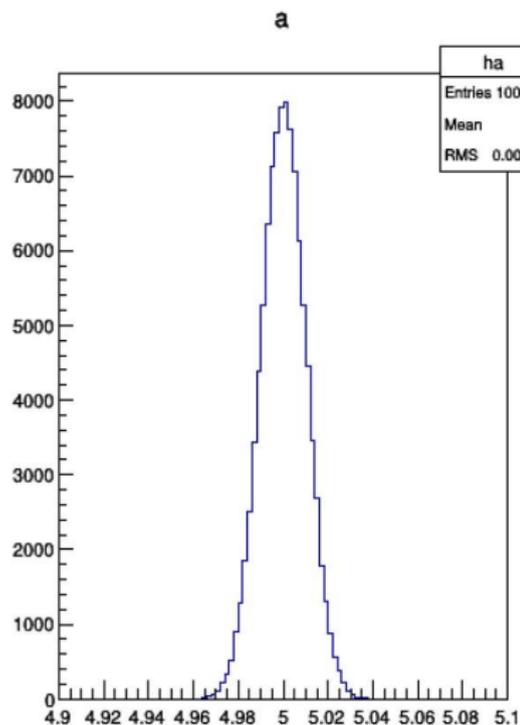
# Após muitas iterações



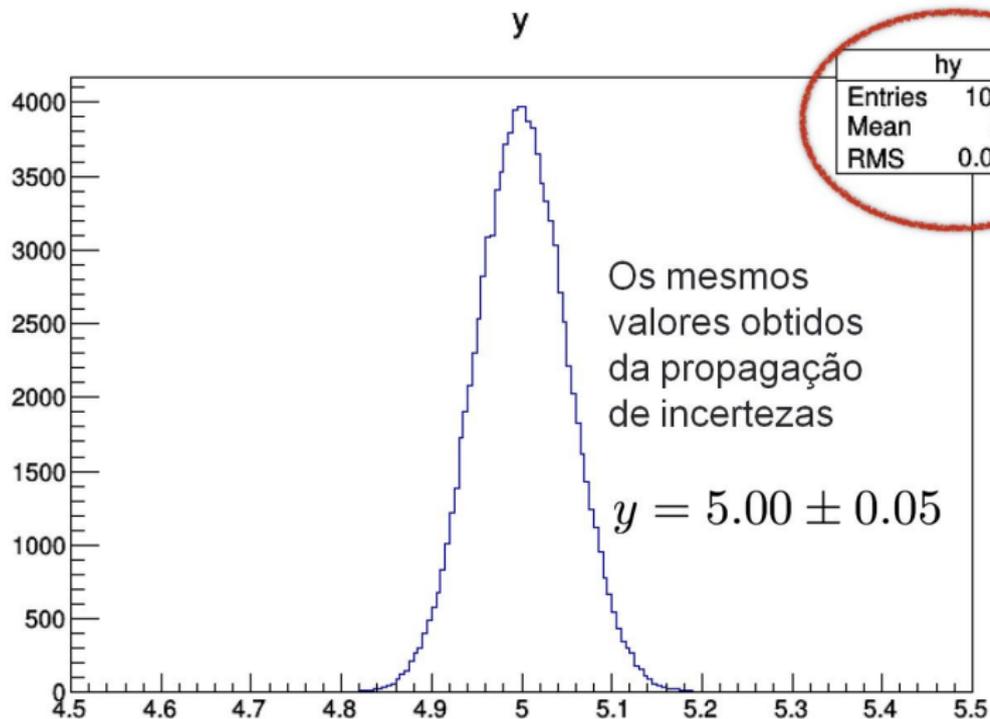
- A fórmula de propagação de incertezas pode dar a falsa impressão de que basta conhecer médias e variâncias e aplicar fórmulas
- A fórmula de propagação vale para incertezas pequenas em torno de uma média (expansão de Taylor de primeira ordem)

- Vamos retomar o mesmo exercício com:
  - ▶  $a = 5.00 \pm 0.01$
  - ▶  $b = 1.00 \pm 0.01$
  - ▶  $y = 5.00 \pm 0.05$  (por propagação)
- Como ficam as distribuições?

# Após muitas iterações



# Após muitas iterações



- O que fizemos é chamado de método de Monte Carlo para propagação de incertezas
- Conhecendo-se as FDPs das variáveis, realizamos sorteios das mesmas, calculamos a variável desconhecida e obtemos a FDP desta
- A análise da FDP fornece informações sobre valores mais prováveis, médias, variâncias, etc.

- Nem sempre obtemos FDPs gaussianas! CUIDADO!
  - ▶ Sendo assim, médias e desvios padrão podem não fornecer toda informação.
- É comum (em algumas áreas) apresentar as FDPs e não apenas números com incertezas.
- **MUITOS físicos passam batido por isto.** É extremamente comum negligenciar isto e assumir que tudo no universo é gaussiano. Não quer dizer que é correto!

- No método que desenvolvemos, supomos que  $a$  e  $b$  são independentes
  - ▶ Sorteamos  $a$  e  $b$  de forma independente
  - ▶ Isto deixa implícito que  $cov_{ab} = 0$
- Como fazer quando houver covariância entre as grandezas? Como sortear os valores?
  - ▶ Vamos abordar covariâncias em detalhe mais adiante

# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados**
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

# Problema básico

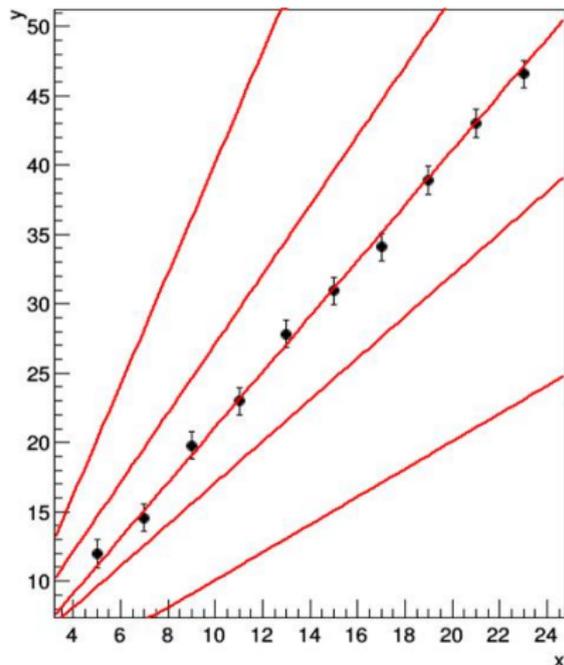
- Imagine um conjunto de dados

$$\{x_i, y_i, \sigma_i\}$$

- E uma função

$$y = f(x, \vec{a})$$

- Onde o vetor  $\vec{a}$  corresponde ao conjunto de parâmetros desta função
- Qual o vetor  $\vec{a}$  que descreve melhor o conjunto de dados?



## Vamos dar um passo para trás

- Imagine um conjunto de medidas realizadas  $y_i$  com valores verdadeiros  $\mu_i$ , cujas funções densidade de probabilidade são:

$$H(y_i, \mu_i)$$

- Os valores verdadeiros podem ser função de outra grandeza,  $x_i$ , ou seja:

$$\mu_i = f(x_i, \vec{a})$$

- Onde os elementos do vetor  $\vec{a}$  são os parâmetros desta função

- Podemos definir uma função batizada de verossimilhança como sendo:

$$L = \prod_i H(y_i, \mu_i) = \prod_i H(y_i, f(x_i, \vec{a}))$$

- Esta função não pode ser obtida pois não conhecemos o vetor  $\vec{a}$
- O método da máxima verossimilhança consiste em encontrar o vetor  $\vec{a}$  de tal forma que  $L$  seja máxima

- Em geral (vai ficar claro porque) trabalha-se com o logaritmo de  $L$

$$L \rightarrow \ln L$$

- Que deve ser maximizado de modo a encontrar o vetor  $\vec{a}$ .

- Vamos assumir que as medidas  $y_i$  tenham distribuições gaussianas de tal modo que:

$$H(y_i, \mu_i) = \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{y_i - f(x_i, \vec{a})}{\sigma_i} \right)^2}$$

- A função de verossimilhança vale (para  $N$  medidas)

$$L = \prod_i \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{y_i - f(x_i, \vec{a})}{\sigma_i} \right)^2}$$

$$L = \prod_i \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{1}{2} \left( \frac{y_i - f(x_i, \vec{a})}{\sigma_i} \right)^2}$$

- Então;

$$\ln L = \sum_i \left( \frac{1}{\sigma_i \sqrt{2\pi}} \right) - \frac{1}{2} \sum_i \left( \frac{y_i - f(x_i, \vec{a})}{\sigma_i} \right)^2$$

- Lembrando da definição de  $\chi^2$ , temos:

$$\ln L = \text{const} - \frac{1}{2} \chi^2$$

- Deste modo, para  $L$  ser máxima

$$\ln L = \text{const} - \frac{1}{2}\chi^2 \quad \text{com} \quad \chi^2 = \sum_i \left( \frac{y_i - f(x_i, \vec{a})}{\sigma_i} \right)^2$$

- O  $\chi^2$ , deve ser mínimo. Encontrar o vetor  $\vec{a}$  que torna o  $\chi^2$  mínimo é resolver um sistema de equações que parte de

$$\frac{\partial \chi^2}{\partial a_j} = 0$$


# Exemplo: $f(x_i, \vec{a}) = ax$

- Resolvendo o problema:

$$\chi^2 = \sum_i \left( \frac{y_i - ax_i}{\sigma_i} \right)^2$$

$$\frac{d\chi^2}{da} = 0 \Rightarrow a = \frac{\sum_i \frac{x_i y_i}{\sigma_i^2}}{\sum_i \frac{x_i^2}{\sigma_i^2}}$$

- Que tem solução única



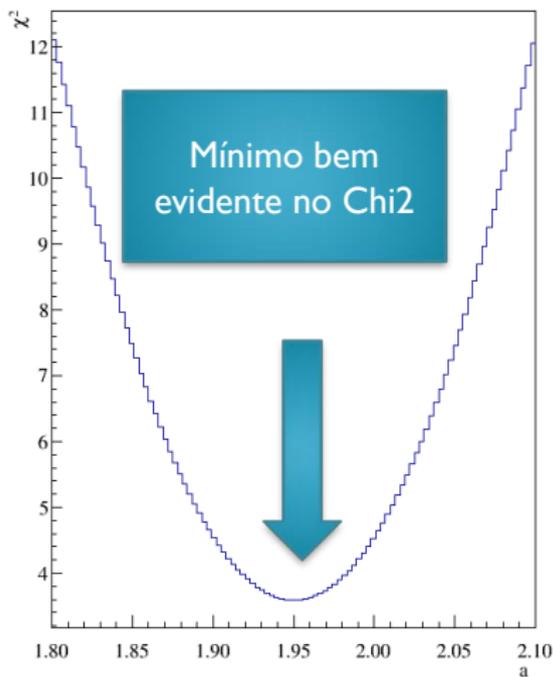
Exemplo:  $f(x_i, \vec{a}) = ax$

- Resolvendo o problema:

$$\chi^2 = \sum_i \left( \frac{y_i - ax_i}{\sigma_i} \right)^2$$

$$\frac{d\chi^2}{da} = 0 \Rightarrow a = \frac{\sum_i \frac{x_i y_i}{\sigma_i^2}}{\sum_i \frac{x_i^2}{\sigma_i^2}}$$

- Que tem solução única



- No caso de funções lineares nos parâmetros

$$f(x, \vec{a}) = \sum_k a_k g_k(x)$$

- Onde  $g_k(x)$  pode ser uma função qualquer, desde que não contenha nenhum parâmetro a ser ajustado
- Neste caso o MMQ tem resolução analítica fechada
  - ▶ Ver, por exemplo, Fundamentos da Teoria de Erros, J. H. Vuolo para fórmula geral

# Para um bom ajuste, quantos pontos e onde medir?

- Vamos supor um experimento virtual onde os dados se comportam segundo o modelo

$$G(\omega) = \frac{1}{\sqrt{1 + \left(\frac{\omega}{\omega_0}\right)^2}}$$

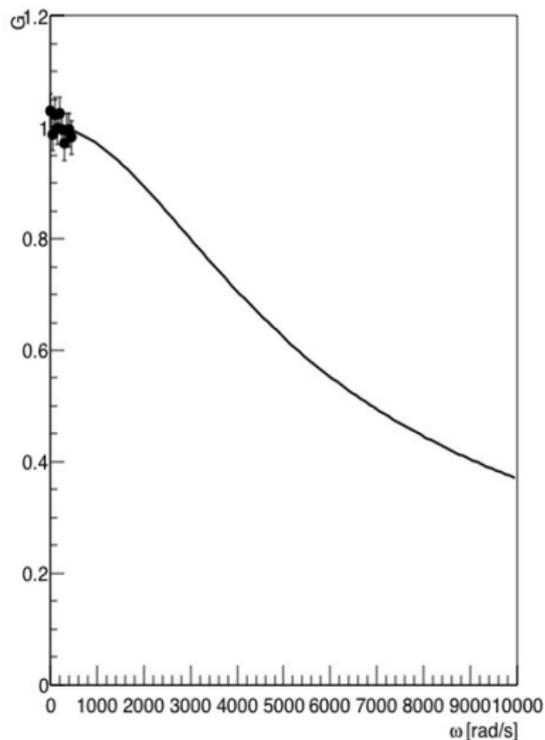
- E o nosso objetivo é determinar, experimentalmente,  $\omega_0$ 
  - ▶ Sabemos, por estimativas, que  $\omega_0 \sim 4000$  rad/s

# Quantos pontos e onde medir?

- Vamos fazer dois experimentos virtuais:
  - ▶ Exp 1
    - ★ Medimos 10 pontos em diferentes regiões de  $\omega$
  - ▶ Exp 2
    - ★ Medimos 5, 10, 15, 20, 25 e 30 pontos na mesma região de  $\omega$
- Como as curvas de  $\chi^2$  se comportam?
- Quão bem determinado é  $\omega_0$  em cada medida?


# Qual região medir?

- Vamos medir sempre 10 pontos em vários intervalos
  - ▶  $\omega = 0 \rightarrow 500$  rad/s
  - ▶  $\omega = 0 \rightarrow 2000$  rad/s
  - ▶  $\omega = 0 \rightarrow 4000$  rad/s
  - ▶  $\omega = 0 \rightarrow 6000$  rad/s
  - ▶  $\omega = 0 \rightarrow 8000$  rad/s
  - ▶  $\omega = 0 \rightarrow 20000$  rad/s




# Qual região medir?

- Vamos medir sempre 10 pontos em vários intervalos
  - ▶  $\omega = 0 \rightarrow 500$  rad/s
  - ▶  $\omega = 0 \rightarrow 2000$  rad/s
  - ▶  $\omega = 0 \rightarrow 4000$  rad/s
  - ▶  $\omega = 0 \rightarrow 6000$  rad/s
  - ▶  $\omega = 0 \rightarrow 8000$  rad/s
  - ▶  $\omega = 0 \rightarrow 20000$  rad/s



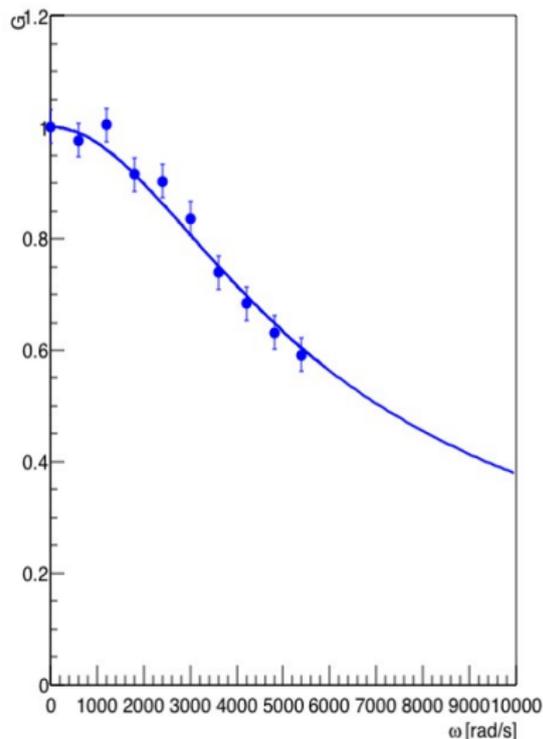
# Qual região medir?

- Vamos medir sempre 10 pontos em vários intervalos
  - ▶  $\omega = 0 \rightarrow 500$  rad/s
  - ▶  $\omega = 0 \rightarrow 2000$  rad/s
  - ▶  $\omega = 0 \rightarrow 4000$  rad/s
  - ▶  $\omega = 0 \rightarrow 6000$  rad/s
  - ▶  $\omega = 0 \rightarrow 8000$  rad/s
  - ▶  $\omega = 0 \rightarrow 20000$  rad/s



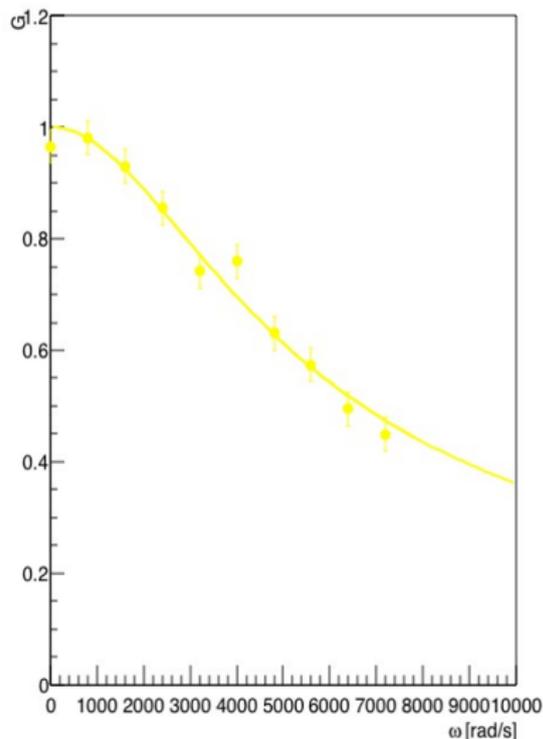
# Qual região medir?

- Vamos medir sempre 10 pontos em vários intervalos
  - ▶  $\omega = 0 \rightarrow 500$  rad/s
  - ▶  $\omega = 0 \rightarrow 2000$  rad/s
  - ▶  $\omega = 0 \rightarrow 4000$  rad/s
  - ▶  $\omega = 0 \rightarrow 6000$  rad/s
  - ▶  $\omega = 0 \rightarrow 8000$  rad/s
  - ▶  $\omega = 0 \rightarrow 20000$  rad/s




# Qual região medir?

- Vamos medir sempre 10 pontos em vários intervalos
  - ▶  $\omega = 0 \rightarrow 500$  rad/s
  - ▶  $\omega = 0 \rightarrow 2000$  rad/s
  - ▶  $\omega = 0 \rightarrow 4000$  rad/s
  - ▶  $\omega = 0 \rightarrow 6000$  rad/s
  - ▶  $\omega = 0 \rightarrow 8000$  rad/s
  - ▶  $\omega = 0 \rightarrow 20000$  rad/s




# Qual região medir?

- Vamos medir sempre 10 pontos em vários intervalos
  - ▶  $\omega = 0 \rightarrow 500$  rad/s
  - ▶  $\omega = 0 \rightarrow 2000$  rad/s
  - ▶  $\omega = 0 \rightarrow 4000$  rad/s
  - ▶  $\omega = 0 \rightarrow 6000$  rad/s
  - ▶  $\omega = 0 \rightarrow 8000$  rad/s
  - ▶  $\omega = 0 \rightarrow 20000$  rad/s



# Como é a curva de $\chi^2$ ?

- Fizemos  $\chi^2_{red}$  para caber tudo no mesmo gráfico




# Como é a curva de $\chi^2$ ?

- Fizemos  $\chi^2_{red}$  para caber tudo no mesmo gráfico
- A escolha do intervalo de medida define quão bem você define a região de mínimo do  $\chi^2$ 
  - ▶ No nosso caso, medir somente o começo da curva (dados “pretos”) não consegue definir o valor do parâmetro
  - ▶ Reflexo na incerteza do parâmetro ajustado
- Parâmetros ajustados
  - ▶  $\omega = (2.5 \pm 1.7) \times 10^3 \text{ rad/s}$
  - ▶  $\omega = (3.72 \pm 0.40) \times 10^3 \text{ rad/s}$
  - ▶  $\omega = (4.32 \pm 0.24) \times 10^3 \text{ rad/s}$
  - ▶  $\omega = (4.09 \pm 0.14) \times 10^3 \text{ rad/s}$
  - ▶  $\omega = (3.87 \pm 0.12) \times 10^3 \text{ rad/s}$
  - ▶  $\omega = (3.86 \pm 0.12) \times 10^3 \text{ rad/s}$


# Quantos pontos medir?

- Vamos medir diferente número de pontos no mesmo intervalo
  - ▶ 5 pontos
  - ▶ 10 pontos
  - ▶ 15 pontos
  - ▶ 20 pontos
  - ▶ 25 pontos
  - ▶ 30 pontos



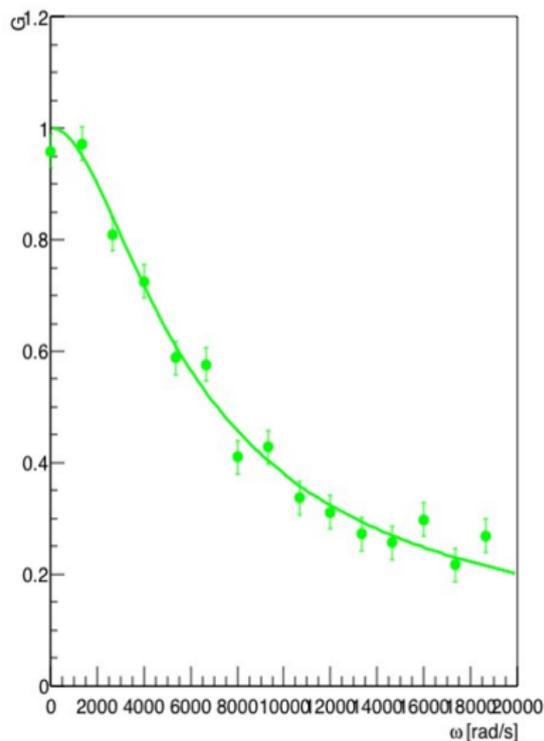
# Quantos pontos medir?

- Vamos medir diferente número de pontos no mesmo intervalo
  - ▶ 5 pontos
  - ▶ 10 pontos
  - ▶ 15 pontos
  - ▶ 20 pontos
  - ▶ 25 pontos
  - ▶ 30 pontos




# Quantos pontos medir?

- Vamos medir diferente número de pontos no mesmo intervalo
  - ▶ 5 pontos
  - ▶ 10 pontos
  - ▶ 15 pontos
  - ▶ 20 pontos
  - ▶ 25 pontos
  - ▶ 30 pontos




# Quantos pontos medir?

- Vamos medir diferente número de pontos no mesmo intervalo
  - ▶ 5 pontos
  - ▶ 10 pontos
  - ▶ 15 pontos
  - ▶ 20 pontos
  - ▶ 25 pontos
  - ▶ 30 pontos




# Quantos pontos medir?

- Vamos medir diferente número de pontos no mesmo intervalo
  - ▶ 5 pontos
  - ▶ 10 pontos
  - ▶ 15 pontos
  - ▶ 20 pontos
  - ▶ 25 pontos
  - ▶ 30 pontos



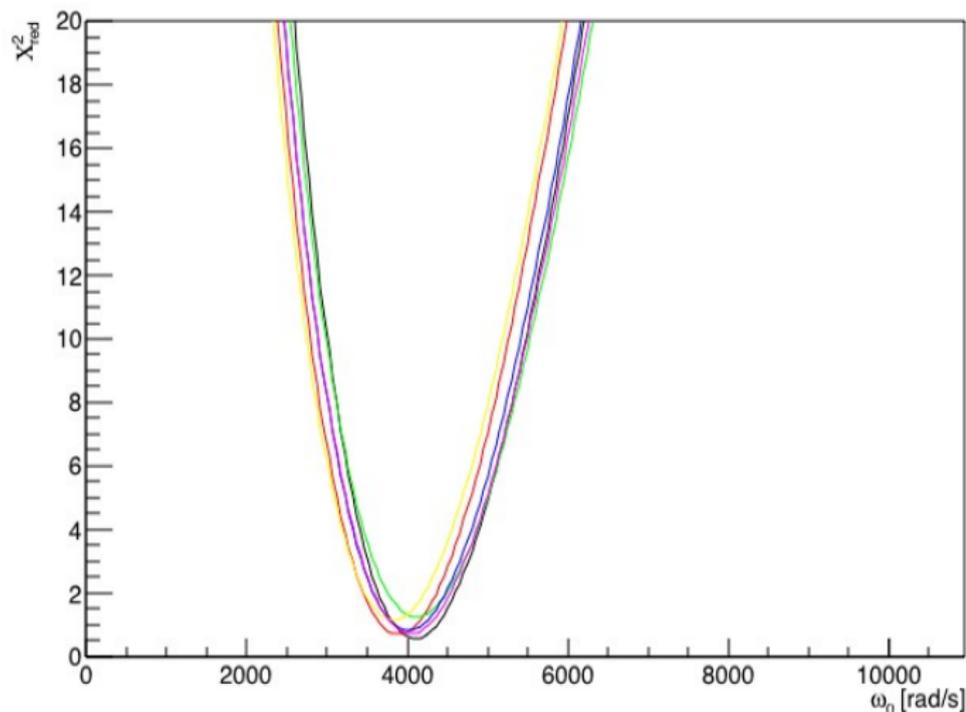
# Quantos pontos medir?

- Vamos medir diferente número de pontos no mesmo intervalo
  - ▶ 5 pontos
  - ▶ 10 pontos
  - ▶ 15 pontos
  - ▶ 20 pontos
  - ▶ 25 pontos
  - ▶ 30 pontos



# Como é a curva de $\chi^2$ ?

- Fizemos  $\chi^2_{red}$  para caber tudo no mesmo gráfico



# Como é a curva de $\chi^2$ ?

- Fizemos  $\chi^2_{red}$  para caber tudo no mesmo gráfico
- Fixando-se o intervalo que se toma os dados a curva de  $\chi^2_{red}$  quase não muda de forma
- Porque é melhor tomar mais dados?

$$\sigma_f \sim \frac{\langle \sigma \rangle}{\sqrt{ngl}}$$

- Parâmetros ajustados

- ▶  $\omega = (4.09 \pm 0.19) \times 10^3 \text{ rad/s}$
- ▶  $\omega = (3.88 \pm 0.13) \times 10^3 \text{ rad/s}$
- ▶  $\omega = (4.11 \pm 0.11) \times 10^3 \text{ rad/s}$
- ▶  $\omega = (4.00 \pm 0.09) \times 10^3 \text{ rad/s}$
- ▶  $\omega = (3.83 \pm 0.08) \times 10^3 \text{ rad/s}$
- ▶  $\omega = (4.03 \pm 0.07) \times 10^3 \text{ rad/s}$

- Intervalo de medida
  - ▶ Define a forma da curva de  $\chi^2$
  - ▶ Define a sensibilidade que temos em definir o valor mínimo de  $\chi^2$  e, conseqüentemente o valor do parâmetro ajustado
    - ★ Isto afeta também a incerteza no parâmetro
- Número de pontos
  - ▶ Define a incerteza no parâmetro ajustado
- A combinação dos dois define a qualidade da sua análise!

# E funções não lineares nos parâmetros?

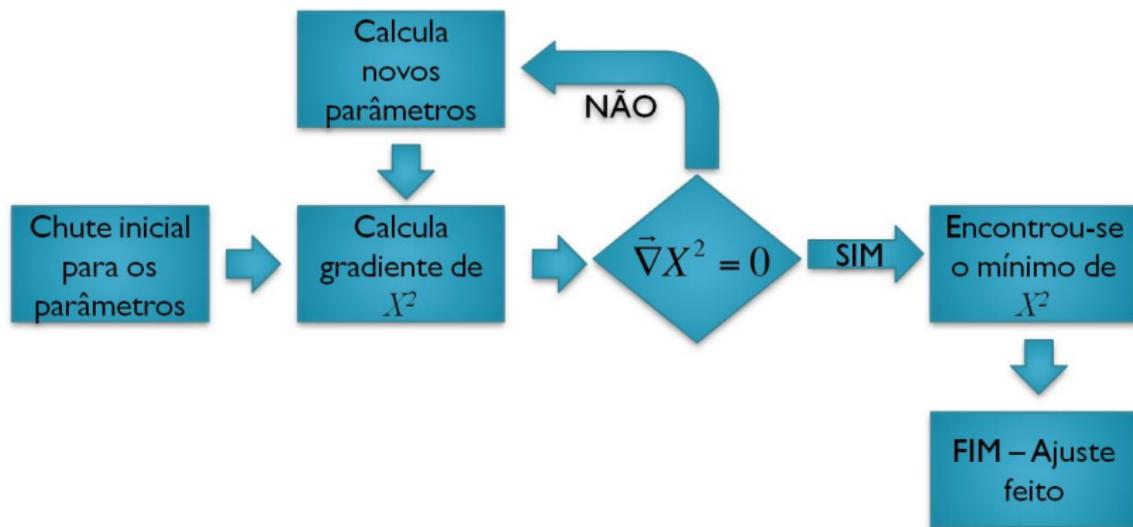
- São aquelas onde os parâmetros aparecem dentro de expressões não lineares, por exemplo

$$f(x, \vec{a}) = a_0 \text{sen}(a_1 x + a_2)$$

- Em geral não dá para resolver analiticamente as expressões de minimização do  $\chi^2$ .
  - ▶ Utilizam-se métodos numéricos para isto

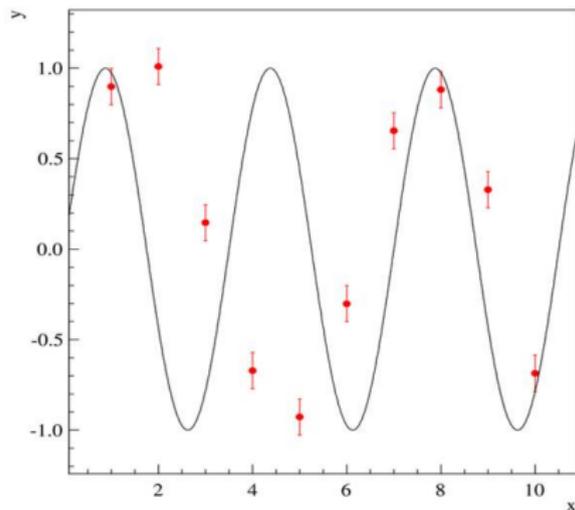
# Método típico de ajuste de funções não lineares

- Em geral utiliza-se algoritmos baseados em gradiente




## Exemplo: $f(x, \vec{a}) = \text{sen}(ax)$

- Quem nunca se deparou com o problema ao lado?
  - ▶ O ajuste não é bom
- Chute inicial  $a = 2$
- Mas o método não encontrou um mínimo de  $\chi^2$ ?
  - ▶ Encontrou sim, e daí?



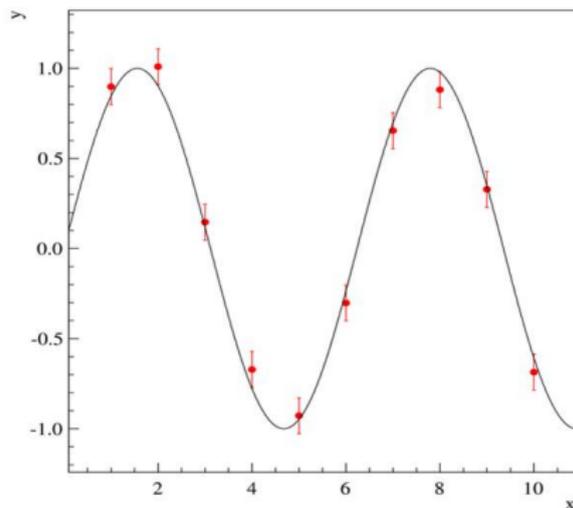
# Exemplo: $f(x, \vec{a}) = \text{sen}(ax)$

- Funções não lineares podem gerar função de  $\chi^2$  com mínimos locais
  - ▶ Dependendo do chute inicial acabamos caindo em um destes mínimos
- Estamos interessados no mínimo global



Exemplo:  $f(x, \vec{a}) = \text{sen}(ax)$

- O chute inicial torna-se muito importante no ajuste de funções não lineares
- Chute inicial  $a = 0.8$
- Encontramos o mínimo geral



- Método de máxima verossimilhança
  - ▶ Maximiza-se a probabilidade com base nas densidades de probabilidade dos pontos
  - ▶ Se forem gaussianas e independentes  $\rightarrow$  máxima verossimilhança resulta em achar o mínimo de  $\chi^2$  (MMQ)
- Ajustes de MMQ com funções não lineares podem ser delicados
  - ▶ Chute inicial dos parâmetros é importante
  - ▶ E as incertezas nos parâmetros ajustados  $\rightarrow$  próxima semana

- Tratamento Estatístico de Dados em Física Experimental, capítulo V, O. Helene e V. Vanin. Ed. Edgard Blücher.
- Fundamentos da Teoria de Erros, capítulo 10, J. H. Vuolo. Ed. Edgard Blücher.

# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados**
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

- Podemos definir uma função batizada de verossimilhança como sendo:

$$L = \prod_i H(y_i, \mu_i) = \prod_i H(y_i, f(x_i, \vec{a}))$$

- Vamos definir

$$\xi = -\ln L$$

- Note o sinal foi mudado, vai ficar óbvio porque

- Maximizar a verossimilhança significa minimizar a grandeza

$$\xi = -\ln L = -\sum_i \ln (H(y_i, f(x_i, \vec{a})))$$

E isto pode ser feito resolvendo um sistema de equações tal que:

$$\frac{\partial \xi}{\partial a_j} = 0$$

- No caso das medidas  $y_i$  terem distribuições gaussianas temos que (note a inversão de sinal)


$$\xi = \text{const.} + \frac{1}{2}\chi^2$$

E minimizar esta grandeza é o mesmo que minimizar o  $\chi^2$ , que é feito através da resolução de um sistema de equações tal que:

$$\frac{\partial \chi^2}{\partial a_j} = 0$$

## Neste caso

- Ajustar uma função de pontos gaussianos significa encontrar o mínimo global do  $\chi^2$  para os parâmetros
- E as incertezas dos parâmetros? De onde elas vêm?



- Vamos iniciar com o método da máxima verossimilhança. Vamos expandir  $\xi$  em uma série de Taylor em torno do mínimo ajustado
  - ▶ Vamos admitir que as incertezas nos parâmetros são pequenas e que podemos truncar esta expansão nos primeiros termos

$$\xi = \xi_0 + \underbrace{\sum_i \frac{\partial \xi}{\partial a_j} (a_j - \bar{a}_j)}_{0 \text{ (ponto de mínimo)}} + \frac{1}{2} \sum_j \frac{\partial^2 \xi}{\partial a_j^2} (a_j - \bar{a}_j)^2 + \frac{1}{2} \sum_j \sum_{k \neq j} \frac{\partial^2 \xi}{\partial a_j \partial a_k} (a_j - \bar{a}_j)(a_k - \bar{a}_k) + \dots$$

- ▶ O termo  $\xi_0$  é o valor de  $\xi$  calculado no mínimo

- Podemos então calcular a função verossimilhança

$$L = e^{-\xi}$$

- Que resulta em

$$L = e^{-\xi_0} \times e^{-\frac{1}{2} \sum_j \frac{\partial^2 \xi}{\partial a_j^2} (a_j - \bar{a}_j)^2} \times e^{-\frac{1}{2} \sum_j \sum_{k \neq j} \frac{\partial^2 \xi}{\partial a_j \partial a_k} (a_j - \bar{a}_j)(a_k - \bar{a}_k)} \times \dots$$

# Incertezas nos parâmetros ajustados

- Se  $\xi$  for suficientemente parabólica em torno do mínimo os termos de ordem superiores são praticamente nulos
  - ▶ Exponencial destes termos  $\sim 1$

$$L \sim e^{-\xi_0} \times \underbrace{e^{-\frac{1}{2} \sum_j \frac{\partial^2 \xi}{\partial a_j^2} (a_j - \bar{a}_j)^2}}_{\text{produto de gaussianas}} \times \underbrace{e^{-\frac{1}{2} \sum_j \sum_{k \neq j} \frac{\partial^2 \xi}{\partial a_j \partial a_k} (a_j - \bar{a}_j)(a_k - \bar{a}_k)}}_{\text{termos de covariância entre parâmetros}}$$

- A função verossimilhança se assemelha a um produto de distribuições de probabilidade gaussianas com covariância

- Por comparação

$$L \sim e^{-\xi_0} \times \underbrace{e^{-\frac{1}{2} \sum_j \frac{\partial^2 \xi}{\partial a_j^2} (a_j - \bar{a}_j)^2}}_{\text{produto de gaussianas}} \times \underbrace{e^{-\frac{1}{2} \sum_j \sum_{k \neq j} \frac{\partial^2 \xi}{\partial a_j \partial a_k} (a_j - \bar{a}_j)(a_k - \bar{a}_k)}}_{\text{termos de covariância entre parâmetros}}$$

$$H(y, \mu) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{1}{2} \left(\frac{y-\mu}{\sigma}\right)^2}$$

- O que faz com que:

$$\sigma_{a_j}^2 = \left( \frac{\partial^2 \xi}{\partial a_j^2} \right)^{-1}$$

- No método dos mínimos quadrados, sabemos que

$$\xi = \text{const.} + \frac{1}{2}\chi^2$$

- De modo que:

$$\sigma_{a_j}^2 = \left( \frac{\partial^2 \xi}{\partial a_j^2} \right)^{-1} = \left( \frac{1}{2} \frac{\partial^2 \chi^2}{\partial a_j^2} \right)^{-1}$$

# Vamos olhar a curva de $\chi^2$


- Expandir em Taylor

$$\chi^2 = \chi_{min}^2 + \frac{1}{2} \frac{\partial^2 \chi^2}{\partial a^2} (a - \bar{a})^2 + \dots$$

$$= \chi_{min}^2 + \frac{1}{\sigma_a^2} (a - \bar{a})^2 + \dots$$

- Ou seja

$$\Delta\chi^2 = \chi^2 - \chi_{min}^2 \sim \frac{1}{\sigma_a^2} (a - \bar{a})^2$$



# Vamos olhar a curva de $\chi^2$

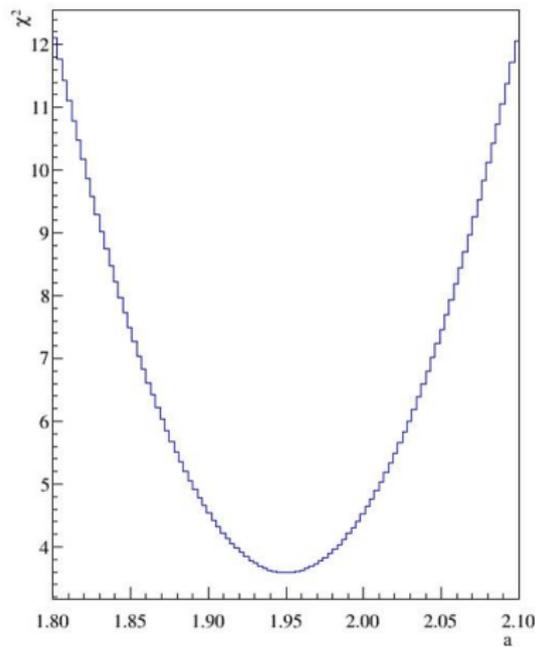
- De modo que

$$\Delta\chi^2 = \chi^2 - \chi^2_{min} \sim \frac{1}{\sigma_a^2}(a - \bar{a})^2$$

- Se

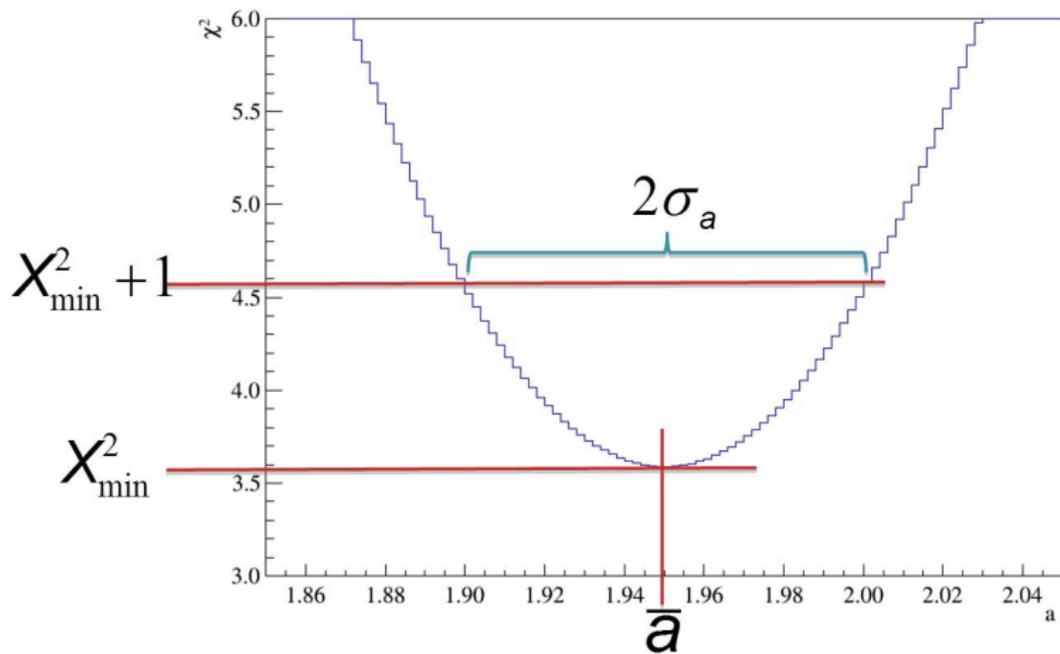
$$(a - \bar{a})^2 = \sigma_a^2 \rightarrow \Delta\chi^2 \sim 1$$

- Posso graficamente estimar a incerteza em  $a$



# Incerteza de parâmetros do MMQ graficamente

$$(a - \bar{a})^2 = \sigma_a^2 \rightarrow \Delta\chi^2 \sim 1$$



- Supomos que a grandeza  $\xi$  seja suficientemente parabólica em torno do seu mínimo
  - ▶ Consequentemente, também o  $\chi^2$  quando o MMQ se aplica
  - ▶ Isto nem sempre é verdade mas em geral dá uma boa “estimativa” das incertezas nos parâmetros ajustados
    - ★ Para fazer direito utiliza-se método de Monte Carlo
- Note que estamos olhando variação no  $\chi^2$  e não no  $\chi_{red}^2$

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade**
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

- Imagine que foi realizada uma medida e queremos compará-la ao seu “valor verdadeiro” - muitas vezes uma previsão teórica - calculamos z

$$z = \frac{\bar{y} - \mu}{\sigma_{\bar{y}}}$$

- y será compatível com  $\mu$  se  $|z| < 3$
- Isso é razoável? Qual a origem do valor 3?

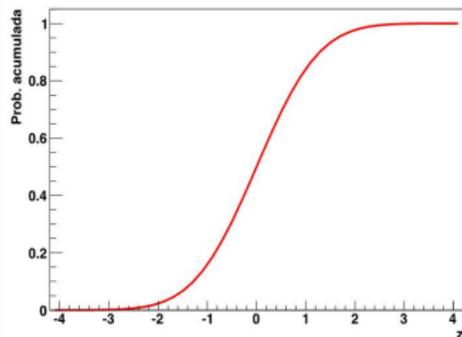
- Podemos definir como probabilidade acumulada a grandeza:

$$P(x) = \int_{-\infty}^x p(t) dt \longrightarrow \left\{ \begin{array}{l} \text{Probabilidade da variável } t \\ \text{assumir um valor menor ou} \\ \text{igual a } x \end{array} \right.$$

- Nesse caso,  $p(t)$  é a função densidade de probabilidade da grandeza estudada


$$z = \frac{\bar{y} - \mu}{\sigma_{\bar{y}}}$$

- No teste-z, assume-se que a variável  $z$  possui FDP normal
- Se a hipótese do teste for verdadeira  $z$  deve possuir valor verdadeiro zero e variância 1



$$z = \frac{\bar{y} - \mu}{\sigma_{\bar{y}}}$$

- No teste-z, assume-se que a variável  $z$  possui FDP normal
- Se a hipótese do teste for verdadeira  $z$  deve possuir valor verdadeiro zero e variância 1




$$|z| < 3 \Rightarrow \sim 99.9\%$$

- No teste-z, 3 significa que  $\sim 99.9\%$  das medidas devem estar nesse intervalo, ou seja, a chance de obter um valor com  $|z| > 3$  é desprezível
- **CUIDADO!** Não use o valor 3 a esmo. Entenda o seu significado


- Mas será que a variável  $z$  assume uma FDP normal?

$$z = \frac{\bar{y} - \mu}{\sigma_{\bar{y}}}$$

F.D.P. para  $y$



F.D.P. para  $\sigma^2$

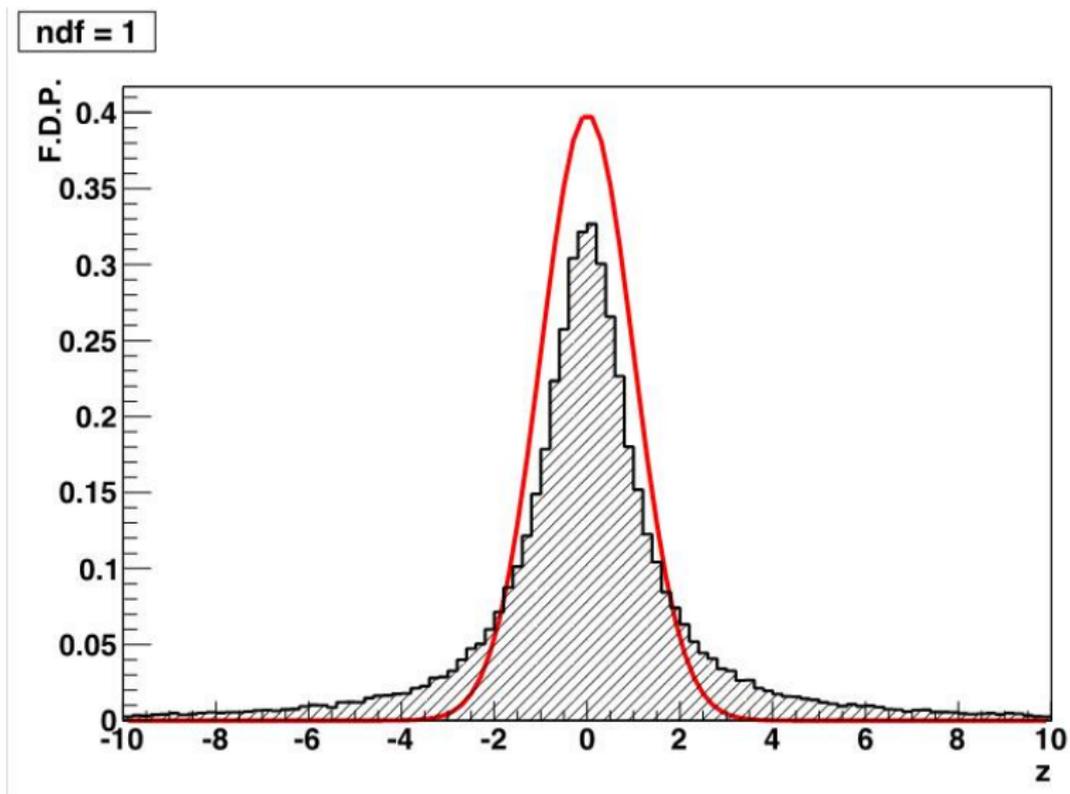


- Vamos realizar o mesmo procedimento (experimentos virtuais) de aulas passadas e obter a FDP de  $z$  para diferentes números de graus de liberdade (ngl)

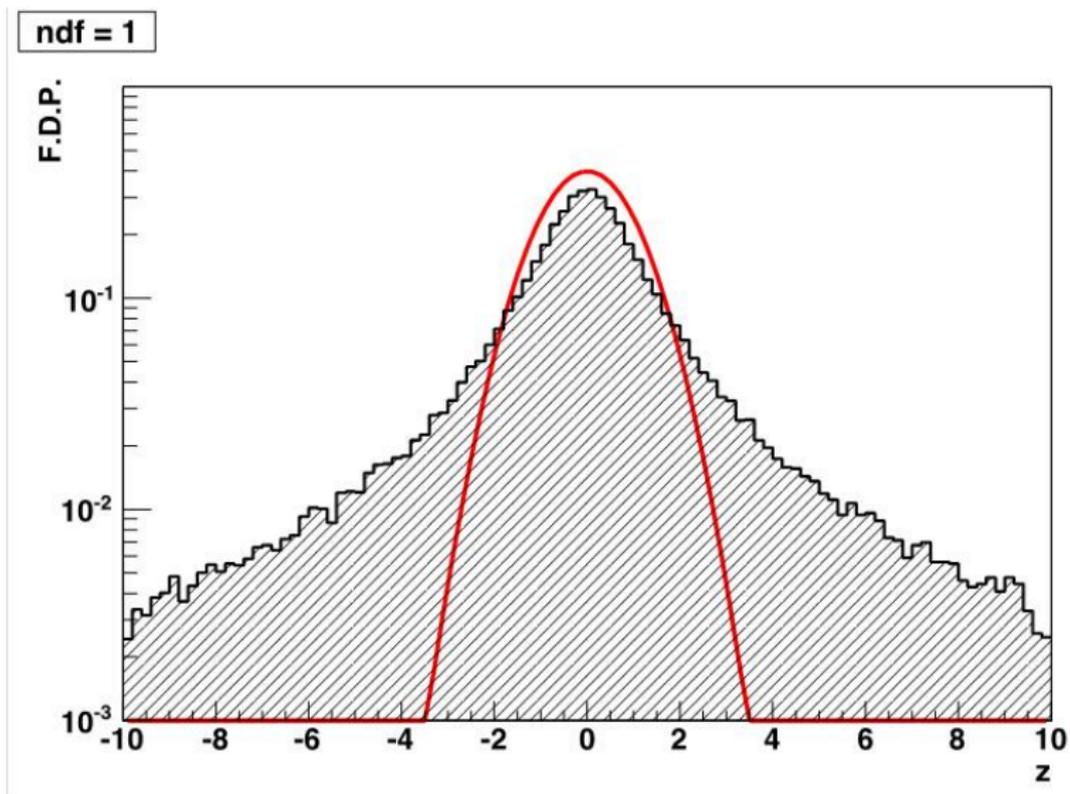
$$z = \frac{\bar{y} - \mu}{\sigma_{\bar{y}}}$$

- Ou seja, vamos simular, para um dado ngl qual é o valor médio de  $y$ , a sua incerteza e calcular  $z$ .
- Vamos comparar a distribuição de  $z$  com uma distribuição normal de média 0 e variância 1.
  - ▶ O teste-z supõe que a variável  $z$  tem distribuição normal de média 0 e desvio padrão 1.


# FDP de $z$ para $n_{gl} = 1$



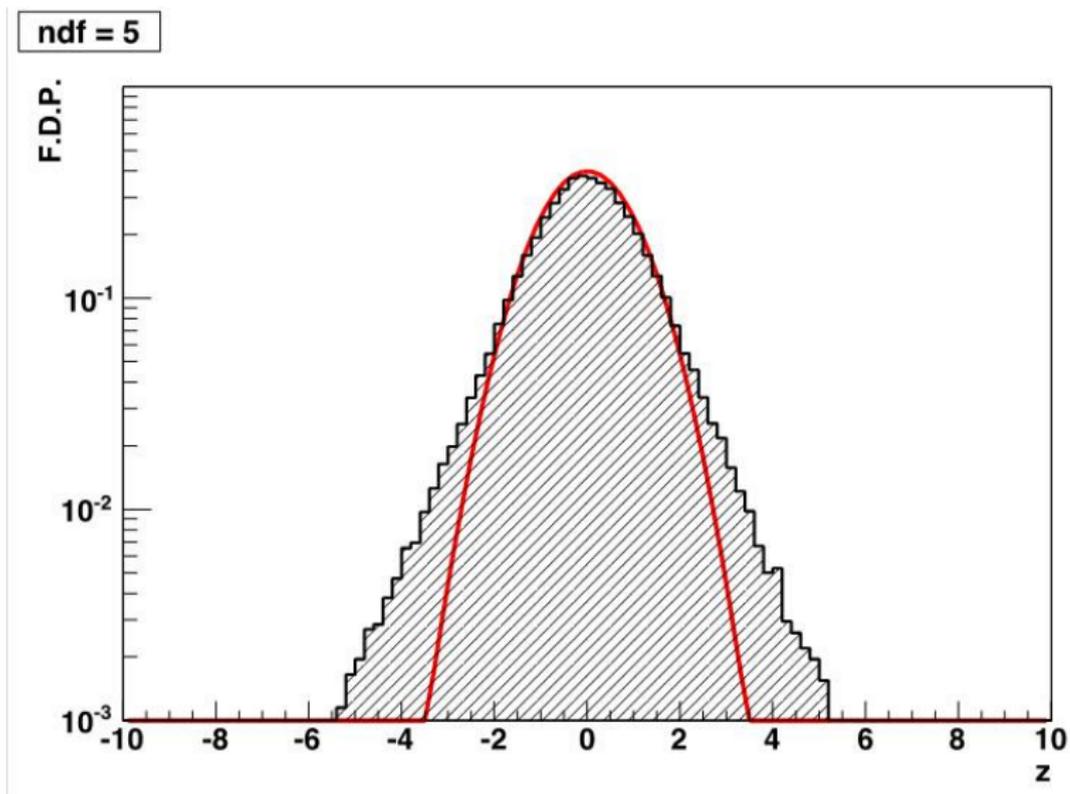
# FDP de $z$ para $n_{gl} = 1$



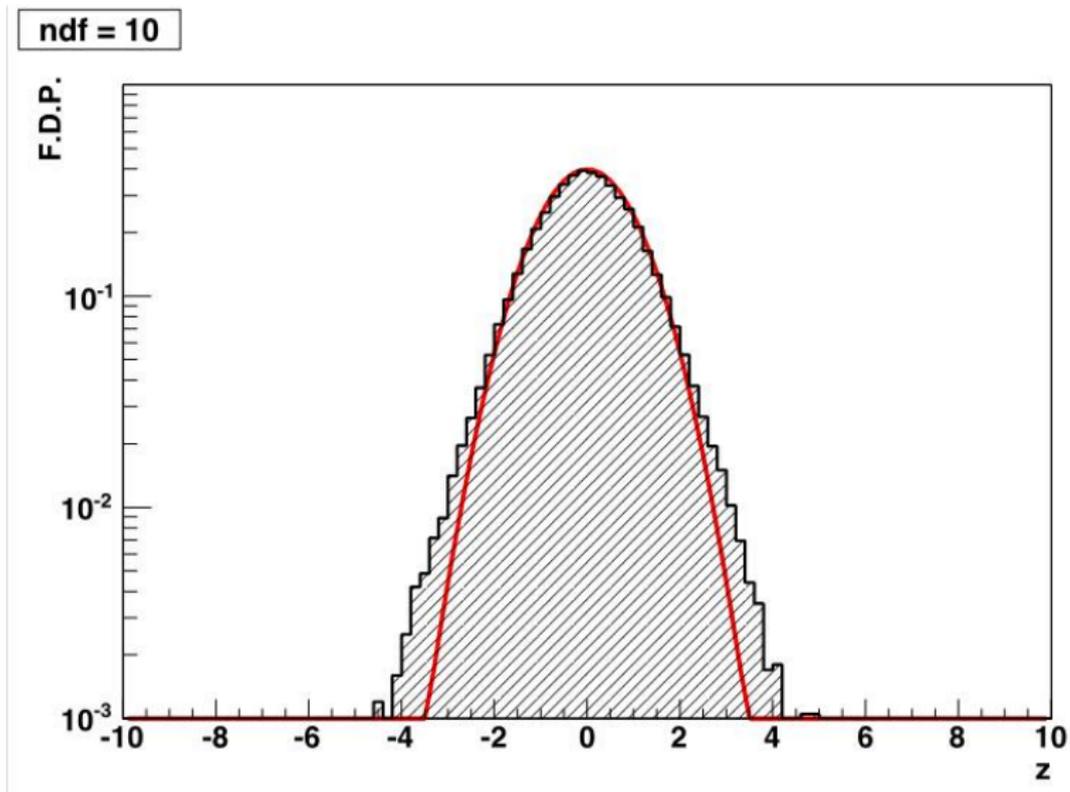
# FDP de $z$ para $n_{gl} = 2$



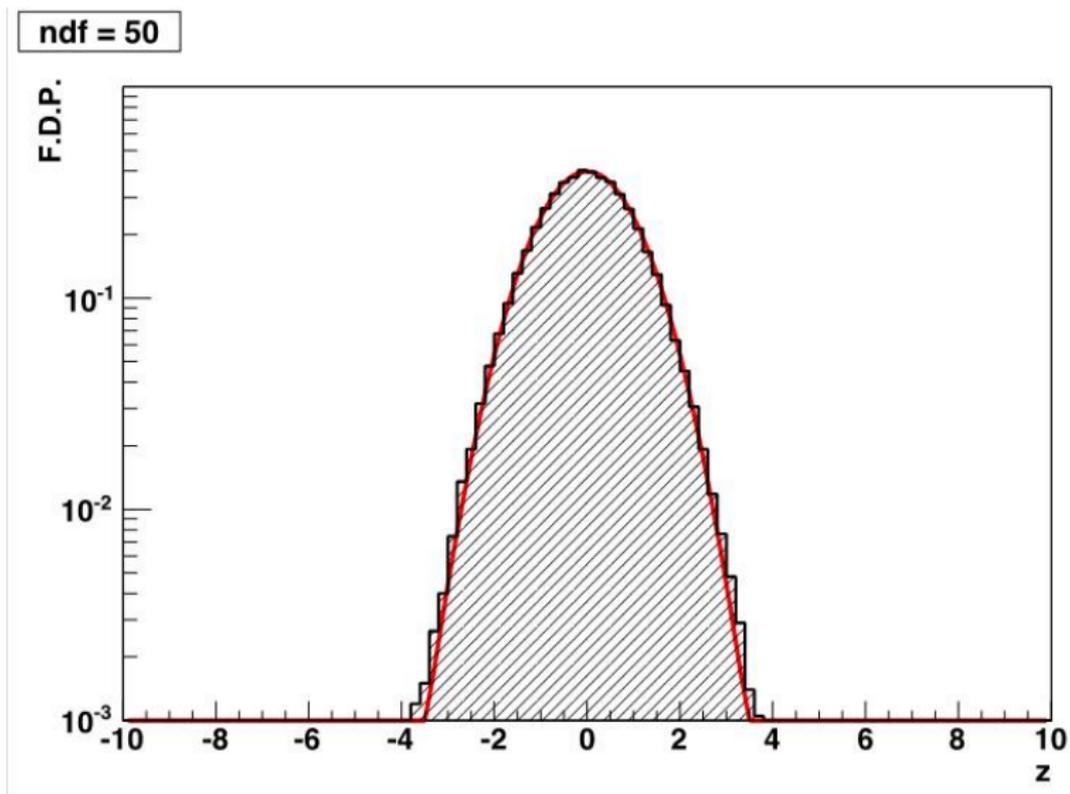
# FDP de $z$ para $n_{gl} = 5$



# FDP de $z$ para $n_{gl} = 10$



# FDP de $z$ para $n_{gl} = 50!!$



- A variável  $z$  somente possui FDP normal para medidas com elevado número de graus de liberdade
  - ▶ Tipicamente  $n_{gl} > 20$  já dá para aproximar com um pouco de ressalva
- Ou seja, o teste- $z$  só pode ser utilizado em situações com grande  $n_{gl}$ 
  - ▶ A situação é crítica para  $n_{gl} \sim 1-2$
- Que tipo de teste utilizar para pequenos valores de  $n_{gl}$ ?


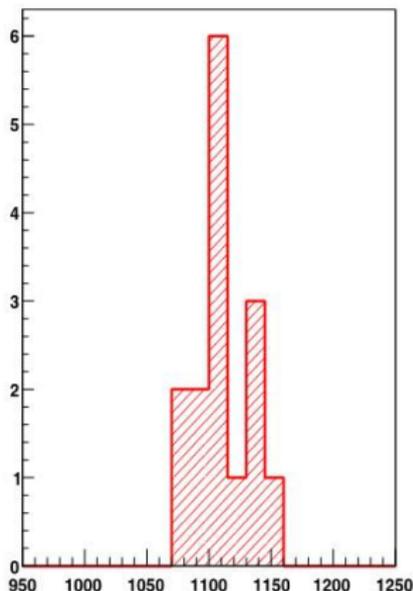
- Willian Gosset (Student) - 1908
  - ▶ Distribuição de probabilidades de Student (ou distribuição  $t$ )
- A distribuição  $t$  surge quando se quer comparar valores médios de distribuições com poucos graus de liberdade. O fato da FDP da variância não seguir uma distribuição normal, nesses casos, faz com que seja necessário utilizar distribuições  $t$  de probabilidade

- Vamos supor que queremos comparar duas amostras diferentes e testar se elas são compatíveis. Cada amostra foi medida com um certo número de graus de liberdade, possui uma média e um desvio padrão estimado da amostra. Define-se a grandeza  $t$ , de modo geral, como sendo:

$$t = \frac{\bar{y}_1 - \bar{y}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \longrightarrow \begin{cases} \bar{y}_i = \text{média da amostra } i \\ \sigma_i = \text{variância da amostra } i \\ n_i = \text{ngl da amostra } i \end{cases}$$

# Exemplo

- Duas turmas mediram uma constante  $C$  e obtiveram as seguintes distribuições. Podemos dizer que os valores médios das salas são compatíveis?



- Queremos comparar o valor médio de uma amostra com uma expectativa para o seu valor verdadeiro (teórico, por exemplo). Nesse caso,  $t$  pode ser escrito como:

$$t = \frac{\bar{y}_1 - \bar{y}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \longrightarrow t = \frac{\bar{y}_1 - \mu}{\frac{\sigma_1}{\sqrt{n_1}}}$$

- Que é a mesma expressão para  $z$

- O teste- $t$  de Student consiste em verificar se a hipótese de igualdade entre valores médios de duas amostras (ou entre o valor médio de uma amostra e uma expectativa “verdadeira”) é válida, ou seja, verificar se:

$$t = \frac{\bar{y}_1 - \bar{y}_2}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \text{ ou } t = \frac{\bar{y}_1 - \mu}{\frac{\sigma_1}{\sqrt{n_1}}}$$

- É compatível com zero
- Contudo, para testar essa compatibilidade, devemos levar em conta que a distribuição de  $t$  não é mais normal
- Qual a FDP de  $t$ ?

# Distribuição $t$ de Student

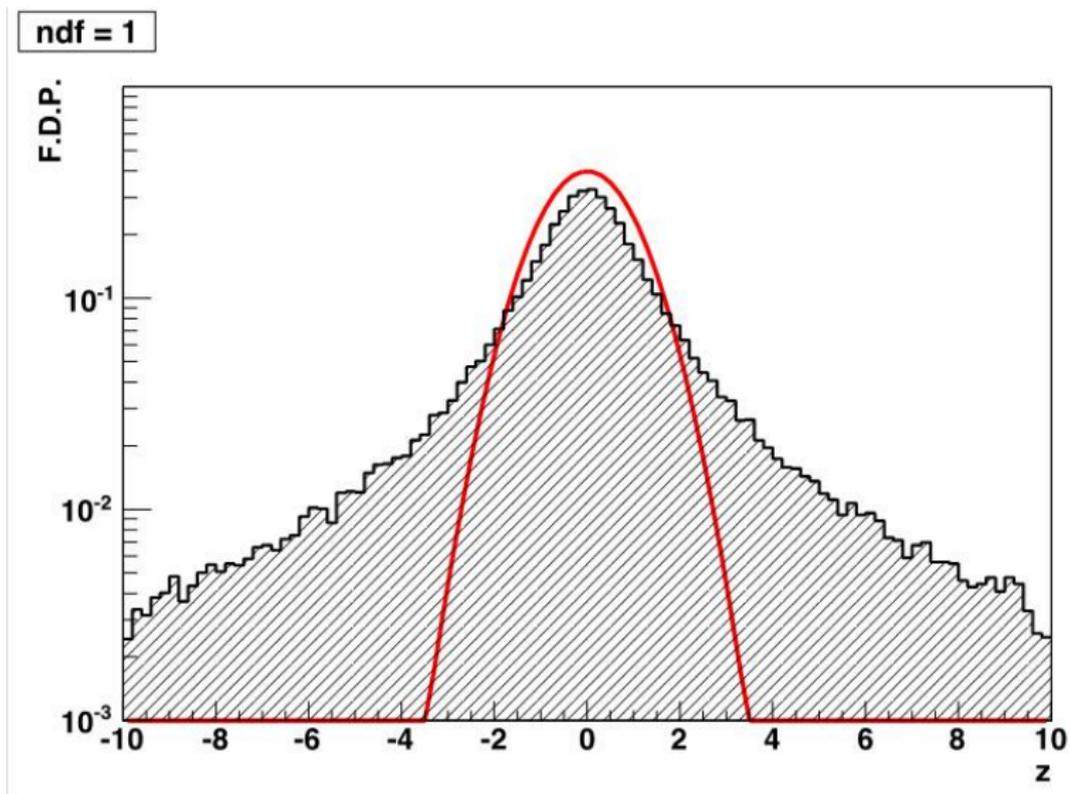
- Grandezas que são obtidas como razões entre uma distribuição normal (valor médio) e uma distribuição de  $\chi^2$  (variância, por exemplo), possuem FDP de Student.
  - ▶ Grandezas  $t$  e  $z$  se enquadram nessa relação

$$p(t) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\Gamma\left(\frac{n}{2}\right) \sqrt{n\pi}} \left(1 + \frac{t^2}{n}\right)^{-\left(\frac{n+1}{2}\right)}$$

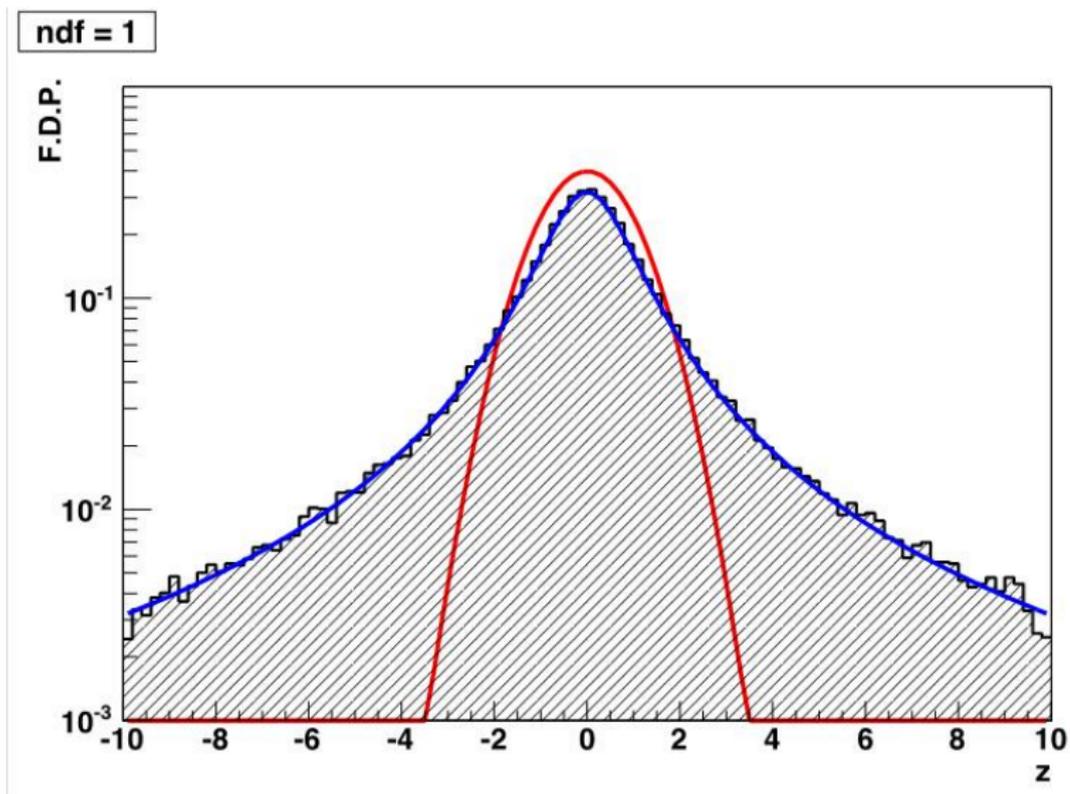
- Sendo  $n$  o número de graus de liberdade da distribuição e  $\Gamma$  a função Gama

<http://en.wikipedia.org/wiki/Student%27s-t-distribution>

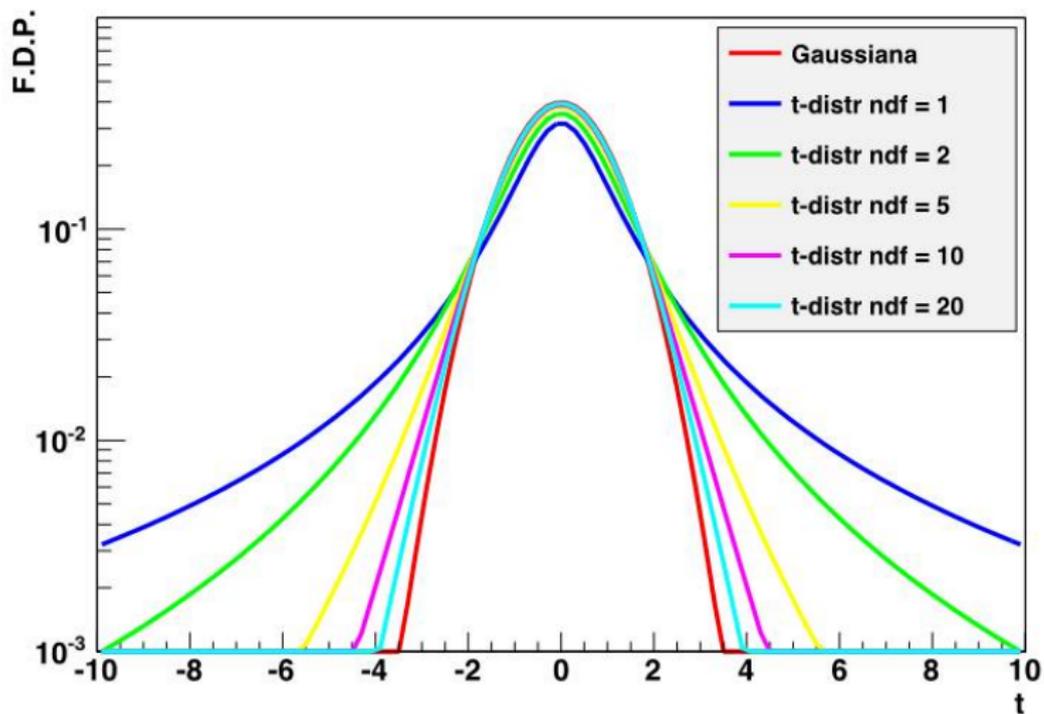
# FDP de $t$ para $n_{gl} = 1$




# FDP de $t$ para $n_{gl} = 1$



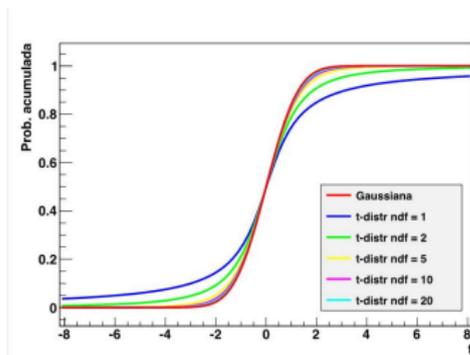
# Distribuições- $t$ para diferentes $n_{gl}$



# Probabilidade acumulada



- Do gráfico de probabilidade acumulada fica claro que, o intervalo de compatibilidade de  $t$  para o mesmo nível de confiança (por exemplo, 99%) depende do número de graus de liberdade da amostra
  - Podemos ter  $|t| < 8$ , em alguns casos, para  $\sim 95\%$  de confiança!



# Teste-z e teste-t no webroot

webROOT - GRIPER (Grupo de Ions Pesados Relativísticos) do Instituto de Física - USP/SP

Bem-vindo Alexandre Suaide

Última conexão em 9/10/2014 - 20:39:27  
Cadastrado desde 29/12/2011 - 10:56:33

## Selecione uma opção abaixo

- Mostra a pasta
  - Minhas aplicações
  - Pasta atual
- Criar um(a) novo(a) ...
  - Gráfico - Gráfico simples (um conjunto de dados) com ajuste de função
  - Combinado de gráficos - Combinar gráficos simples em uma única figura
  - Histograma 1D - Histograma em uma dimensão (x) com ajuste de função
  - Função f(x) - Função de uma variável f(x) com com opção de integral e derivada
  - Mapa de  $\chi^2$  - Analisa mapa de  $\chi^2$  para dois parâmetros de um ajuste de gráfico
  - Propagação de erros - Calcula densidades de probabilidades usando método de Monte Carlo com uma variável independente e parâmetros correlacionados entre si
  - FFT - Transformada rápida de Fourier em 1D com possibilidade de filtragem de sinal

- Calculadoras
  - Cálculo de intervalos de confiança ( $\chi^2$ , gaussina, Student, etc.)
  - Calculadora científica simples
- Alterar senha
- Minhas preferências
- Ajuda
- Sair

## Cálculadora de intervalos de confiança

Função densidade de probabilidade

Nível de confiança

Tipo de cálculo


Número de graus de liberdade

Média

Desvio padrão

## Intervalos de confiança

Limite inferior -5.511  
Limite superior 5.511



- Leva em conta o fato da FDP para  $t$  (ou  $z$ ) desviar de uma distribuição normal para poucos graus de liberdade
  - ▶ Importante para fazer uma comparação justa entre conjuntos de dados
- Para saber mais, olhe em qualquer livro de estatística. Esse é um teste padrão.
  - ▶ [http://en.wikipedia.org/wiki/Student%27s\\_t-test](http://en.wikipedia.org/wiki/Student%27s_t-test)
  - ▶ [http://en.wikipedia.org/wiki/T\\_distribution](http://en.wikipedia.org/wiki/T_distribution)

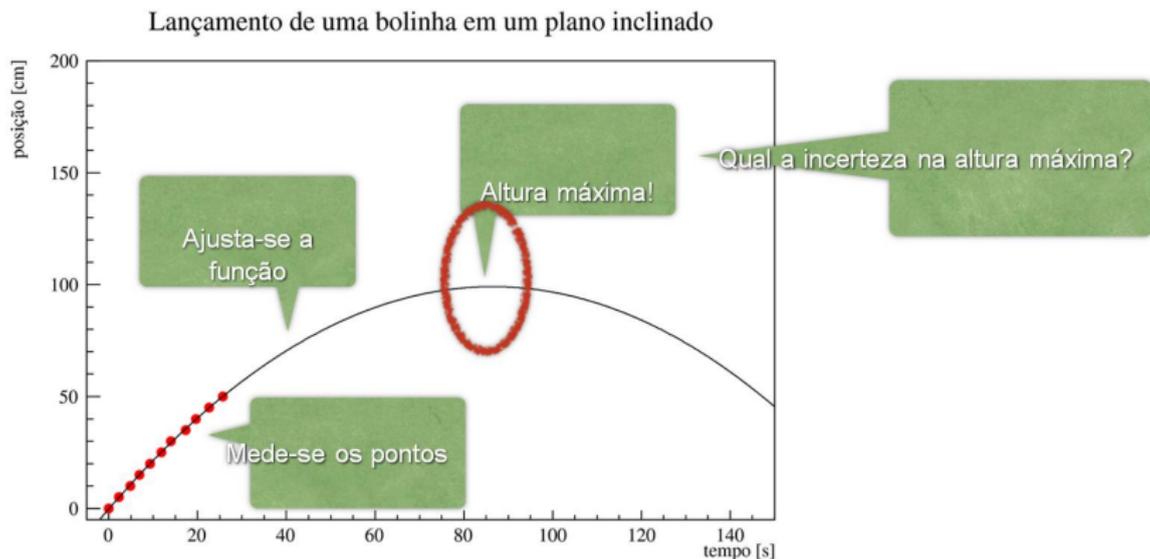
# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

# O problema clássico

- Extrapolações de funções

- ▶ Ex: lançamento de uma bolinha em um plano inclinado. Qual altura máxima ela atinge?



# Fórmula geral de propagação de incertezas

(ver tópicos anteriores)

- Dada uma função

$$y = f(x_1, x_2, \dots, x_n) = f(\tilde{x})$$

# Fórmula geral de propagação de incertezas

(ver tópicos anteriores)

- Dada uma função

$$y = f(x_1, x_2, \dots, x_n) = f(\vec{x})$$

- A variância de  $y$  é dada por

$$\sigma_y^2 = \left\langle \left[ \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) \right]^2 \right\rangle$$

# Fórmula geral de propagação de incertezas

(ver tópicos anteriores)

- Dada uma função

$$y = f(x_1, x_2, \dots, x_n) = f(\tilde{x})$$

- A variância de  $y$  é dada por

$$\sigma_y^2 = \left\langle \left[ \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) \right]^2 \right\rangle$$

- Expandindo  $f$  em Taylor em 1ª ordem

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \langle (x_i - \mu_i)^2 \rangle + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \langle (x_i - \mu_i)(x_j - \mu_j) \rangle$$

# Fórmula geral de propagação de incertezas

(ver tópicos anteriores)

- Dada uma função

$$y = f(x_1, x_2, \dots, x_n) = f(\tilde{x})$$

- A variância de  $y$  é dada por

$$\sigma_y^2 = \left\langle \left[ \sum_i \frac{\partial f}{\partial x_i} (x_i - \mu_i) \right]^2 \right\rangle$$

- Expandindo  $f$  em Taylor em 1ª ordem

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \langle (x_i - \mu_i)^2 \rangle + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \langle (x_i - \mu_i)(x_j - \mu_j) \rangle$$

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

# Fórmula geral de propagação de incertezas

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

# Fórmula geral de propagação de incertezas

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \Gamma^T \Sigma \Gamma$$

# Fórmula geral de propagação de incertezas

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \Gamma^T \Sigma \Gamma$$

$$\Gamma = \begin{pmatrix} \partial_{x_1} \\ \partial_{x_2} \\ \dots \\ \partial_{x_n} \end{pmatrix} \quad \text{com } \partial_{x_i} = \frac{\partial f}{\partial x_i}$$

# Fórmula geral de propagação de incertezas

$$\sigma_y^2 = \sum_i \left( \frac{\partial f}{\partial x_i} \right)^2 \sigma_i^2 + \sum_i \sum_j \frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \text{cov}_{ij}$$

- Esta fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \Gamma^T \Sigma \Gamma$$

$$\Gamma = \begin{pmatrix} \partial_{x_1} \\ \partial_{x_2} \\ \dots \\ \partial_{x_n} \end{pmatrix} \quad \text{com } \partial_{x_i} = \frac{\partial f}{\partial x_i} \quad \Sigma = \begin{pmatrix} \sigma_1^2 & \text{COV}_{12} & \dots & \text{COV}_{1n} \\ \text{COV}_{21} & \sigma_2^2 & \dots & \text{COV}_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \text{COV}_{n1} & \text{COV}_{n2} & \dots & \sigma_n^2 \end{pmatrix}$$


$\Sigma$  é chamada de matriz de covariância

# O significado da covariância


- Considere duas medidas  $x$ ,  $y$
- Considere que podemos repetir o experimento e medir várias vezes  $x$  e  $y$
- Considere que a cada medida, colocamos um ponto no gráfico de  $y$  em função de  $x$ 
  - ▶ Calculamos o valor médio de  $x$  e de  $y$
  - ▶ Calculamos a covariância entre  $x$  e  $y$

$$\text{cov}_{xy} = \langle (x - \mu_x)(y - \mu_y) \rangle$$


# Há três possibilidades



$$\text{COV}_{xy} = 0$$



$$\text{COV}_{xy} > 0$$



$$\text{COV}_{xy} < 0$$

$$\text{COV}_{xy} = \langle (x - \mu_x)(y - \mu_y) \rangle$$


- Muitas vezes é melhor expressar a dependência entre duas grandezas através do coeficiente de correlação, definido como:

$$\rho_{xy} = \frac{\text{COV}_{xy}}{\sigma_x \sigma_y}$$

$$-1 \leq \rho_{xy} \leq 1$$

# Vamos voltar ao problema inicial

- Um bom programa de ajuste fornece a matriz de covariância dos parâmetros ajustados



$$f(x) = [0] + [1]x + [2]x^2$$

## Resultados do ajuste

Número de parâmetros	3
Chi <sup>2</sup>	5.3756
Número de graus de liberdade	8

parâmetro	Valor	Incerteza
0	-0.211885	0.39859
1	2.29672	0.0700687
2	-0.0132831	0.00256606

## Matriz de covariância

0.158874	-0.0232467	0.000711744
-0.0232467	0.00490963	-0.000173525
0.000711744	-0.000173525	6.58469E-06

- Quão correlacionados estão os parâmetros [1] e [2]?

## Resultados do ajuste

Número de parâmetros	3
Chi <sup>2</sup>	5.3756
Número de graus de liberdade	8

parâmetro	Valor	Incerteza
0	-0.211885	0.39859
1	2.29672	0.0700687
2	-0.0132831	0.00256606

## Matriz de covariância


0.158874	-0.0232467	0.000711744
-0.0232467	0.00490963	-0.000173525
0.000711744	-0.000173525	6.58469E-06

$$\rho_{12} = \frac{\text{COV}_{12}}{\sigma_1 \sigma_2} = -0.96$$

- Estes parâmetros estão altamente correlacionados

# Voltando ao problema original

Lançamento de uma bolinha em um plano inclinado



Qual a incerteza na altura máxima?

$$f(x) = [0] + [1]x + [2]x^2 \quad \longrightarrow \quad H_{max} = [0] - \frac{1}{4} \frac{[1]^2}{[2]}$$

## Voltando ao problema original

$$H_{max} = [0] - \frac{1}{4} \frac{[1]^2}{[2]}$$

$$\sigma_{H_{max}}^2 = \Gamma^T \Sigma \Gamma$$

$$\Gamma = \begin{pmatrix} \partial_0 \\ \partial_1 \\ \partial_2 \end{pmatrix} \quad \text{com} \quad \partial_i = \frac{\partial H_{max}}{\partial [i]} \quad \Sigma = \begin{pmatrix} 0.158874 & -0.0232467 & 0.000711744 \\ -0.0232467 & 0.00490963 & -0.000173525 \\ 0.000711744 & -0.000173525 & 6.58469E - 06 \end{pmatrix}$$

Façam esta propagação como exercício!

Façam também considerando  $\text{cov} = 0$  e vejam a diferença.

- Como a matriz de covariância é calculada? O que ela tem a ver com o ajuste de uma função?
  - ▶ O que o  $\chi^2$  tem a ver com isto?
- Como eu sei se duas grandezas estão correlacionadas ou não?
  - ▶ No caso de um ajuste é fácil mas e no caso de duas grandezas medidas em um experimento?

# Sumário

- 1 Incertezas
  - Representação de uma medida
  - Estatística
  - Exemplo
- 2 Propagação de incertezas
- 3 Tratamento estatístico
  - Função densidade de probabilidade
  - Densidade de probabilidade gaussiana
- 4 Mais um pouco de estatística
  - O  $\chi^2$
  - Exemplos
- 5 Propagação de incertezas
- 6 Ajustes de funções e o método dos mínimos quadrados
- 7 Ajustes de funções e o método dos mínimos quadrados
- 8 Testes de compatibilidade
- 9 Covariância - episódio 1 - Alguns conceitos básicos
- 10 Covariância - episódio 2 - Mapa de  $\chi^2$

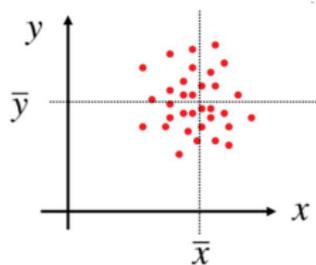
- Fórmula geral de propagação de incertezas pode ser escrita em uma forma matricial do tipo

$$\sigma_y^2 = \Gamma^T \Sigma \Gamma$$


$$\Gamma = \begin{pmatrix} \partial_{x_1} \\ \partial_{x_2} \\ \dots \\ \partial_{x_n} \end{pmatrix} \quad \text{com } \partial_{x_i} = \frac{\partial f}{\partial x_i} \quad \Sigma = \begin{pmatrix} \sigma_1^2 & \text{COV}_{12} & \dots & \text{COV}_{1n} \\ \text{COV}_{21} & \sigma_2^2 & \dots & \text{COV}_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \text{COV}_{n1} & \text{COV}_{n2} & \dots & \sigma_n^2 \end{pmatrix}$$

$\Sigma$  é chamada de matriz de covariância

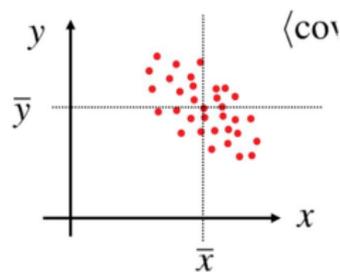
# Covariância e correlação



$$\text{COV}_{xy} = 0$$




$$\text{COV}_{xy} > 0$$



$$\text{COV}_{xy} < 0$$

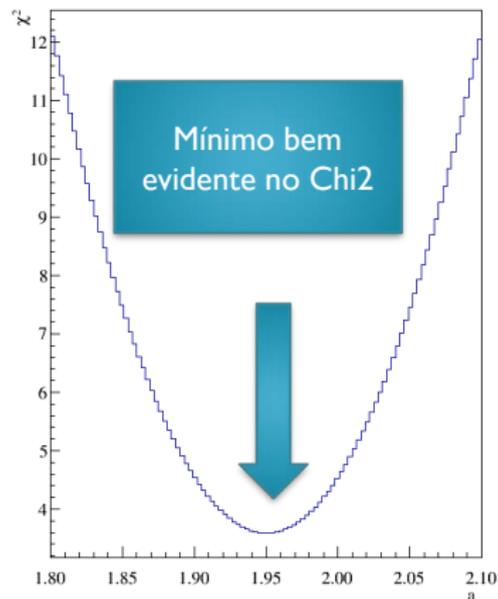
$$\rho_{xy} = \frac{\text{COV}_{xy}}{\sigma_x \sigma_y} \quad -1 \leq \rho_{xy} \leq 1$$

- Método dos mínimos quadrados
- Maximizar a probabilidade da função descrever os dados = minimizar o  $\chi^2$

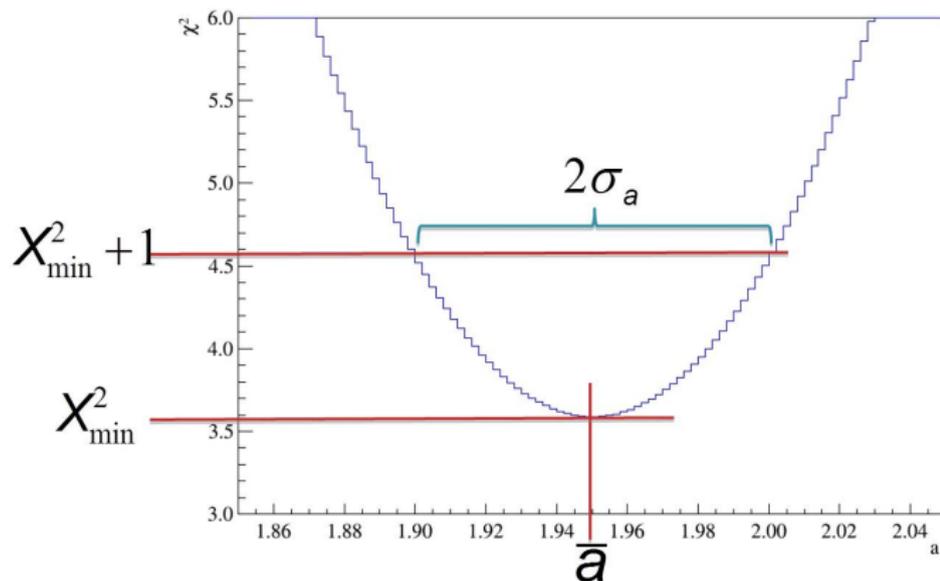


# Mapa de $\chi^2$

- Método dos mínimos quadrados
- Maximizar a probabilidade da função descrever os dados = minimizar o  $\chi^2$

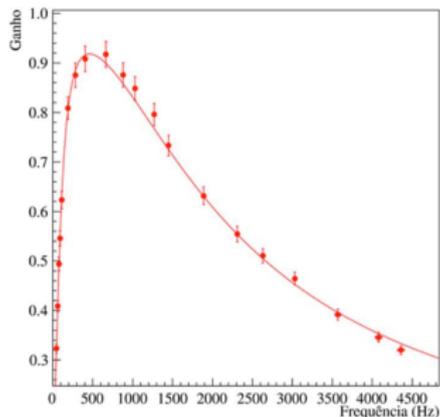


# Incerteza no parâmetro ajustado



# Mapa de $\chi^2$ 2D

## Filtro passa banda



### Resultados do ajuste

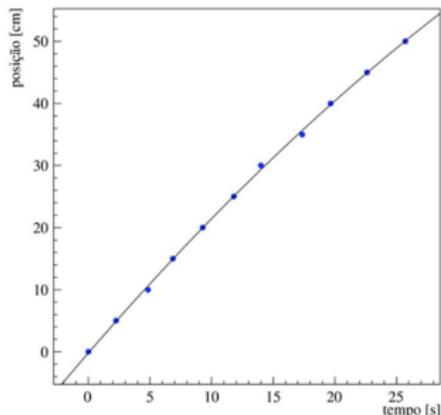
Número de parâmetros	2
Chi <sup>2</sup>	8.48087
Número de graus de liberdade	18

parâmetro	Valor	Incerteza
0	137.519	2.29791
1	1541	20.2911

### Matriz de covariância

$$\begin{bmatrix} 5.28038 & 0.814965 \\ 0.814965 & 411.73 \end{bmatrix}$$

## função horária da esfera metálica em óleo



### Resultados do ajuste

Número de parâmetros	3
Chi <sup>2</sup>	6.77908
Número de graus de liberdade	8


parâmetro	Valor	Incerteza
0	-0.216646	0.362052
1	2.29752	0.062854
2	-0.0133085	0.00228345

### Matriz de covariância

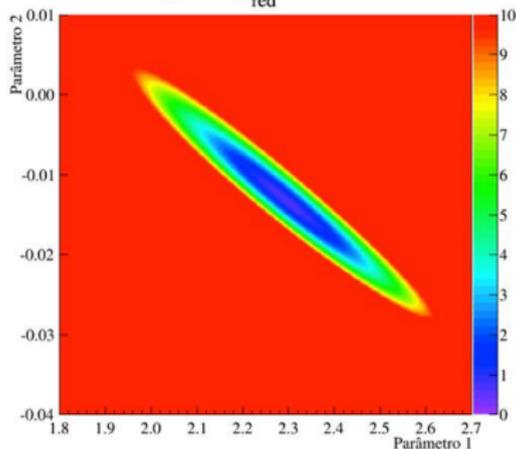
$$\begin{bmatrix} 0.131082 & -0.0190145 & 0.000579051 \\ -0.0190145 & 0.00395063 & -0.000138616 \\ 0.000579051 & -0.000138616 & 5.21416E-06 \end{bmatrix}$$

# Mapa de $\chi^2$

Estudo dos parâmetros do passa banda



Mapa de  $\chi^2_{red}$  da bolinha



$$\rho_{01} = \frac{\text{COV}_{01}}{\sigma_0\sigma_1} = 0.02$$

$$\rho_{12} = \frac{\text{COV}_{12}}{\sigma_1\sigma_2} = -0.96$$

- Como extrair a covariância ou correlação entre dois parâmetros do mapa de  $\chi^2$ ?

- Vamos começar com duas grandezas gaussianas, independentes entre si, cada uma com uma variância conhecida. A probabilidade de obtermos, simultaneamente, um determinado valor de  $a$  e  $b$  é:

$$P(a, b) = P(a)P(b) = \frac{1}{2\pi\sigma_a\sigma_b} \exp\left[-\frac{1}{2}\left(\frac{a - \mu_a}{\sigma_a}\right)^2\right] \exp\left[-\frac{1}{2}\left(\frac{b - \mu_b}{\sigma_b}\right)^2\right]$$

$$P(a, b) = P(a)P(b) = \frac{1}{2\pi\sigma_a\sigma_b} \exp\left\{-\frac{1}{2}\left[\left(\frac{a - \mu_a}{\sigma_a}\right)^2 + \left(\frac{b - \mu_b}{\sigma_b}\right)^2\right]\right\}$$

$$P(a, b) = P(a)P(b) = \frac{1}{2\pi\sigma_a\sigma_b} \exp \left\{ -\frac{1}{2} \left[ \left( \frac{a - \mu_a}{\sigma_a} \right)^2 + \left( \frac{b - \mu_b}{\sigma_b} \right)^2 \right] \right\}$$

$$P(a, b) = \frac{1}{2\pi\sigma_a\sigma_b} \exp \left( -\frac{1}{2} \chi^2 \right)$$

- A probabilidade é máxima quando o  $\chi^2$  é mínimo

- Limites no mapa de  $\chi^2$

$$1\sigma \rightarrow \chi^2 = \chi_{min}^2 + 1$$

$$2\sigma \rightarrow \chi^2 = \chi_{min}^2 + 4$$

- Podemos desenhar estas linhas

# Mapa para duas grandezas independentes


- Assumindo valor médio zero para ambas e

$$\sigma_a = 1$$



$$\sigma_b = 2$$

- Contornos em 1 e 2 sigmas

$$P(a, b) = \frac{1}{2\pi\sigma_a\sigma_b} \exp\left(-\frac{1}{2}\chi^2\right)$$

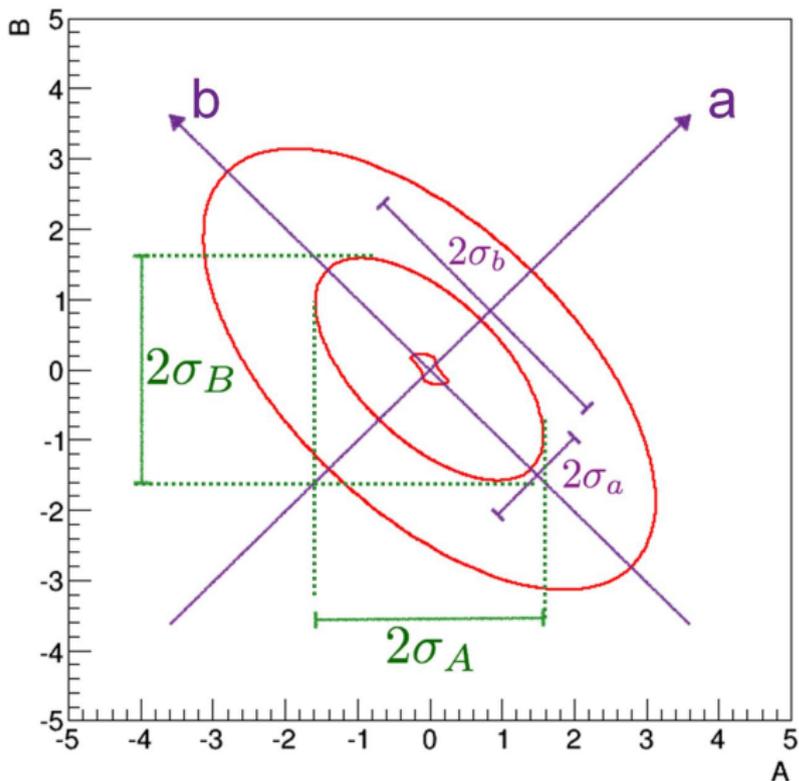


# Introduzir covariância significa girar estas elipses



$$a, b \rightarrow A, B$$

## Mapa de $\chi^2$ para $A$ e $B$



- Como eu matematizo esta rotação?
- Como eu extraio as relações entre as incertezas e as covariâncias?

- Rotação de um ângulo  $\theta$

$$\begin{pmatrix} A \\ B \end{pmatrix} = \begin{pmatrix} \cos\theta & \text{sen}\theta \\ -\text{sen}\theta & \cos\theta \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix}$$

- Simplificando a notação

$$\begin{pmatrix} A \\ B \end{pmatrix} = \begin{pmatrix} c & s \\ -s & c \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix}$$

$$A = ca + sb$$

$$B = -sa + cb$$

- Calculando a covariância

$$\text{COV}_{AB} = \langle (A - \mu_A)(B - \mu_B) \rangle = \langle AB \rangle$$

$$\text{COV}_{AB} = \langle (ca + sb)(-sa + cb) \rangle$$

$$\text{COV}_{AB} = \langle scb^2 - sca^2 + (c^2 - s^2)ab \rangle$$

- Como  $a$  e  $b$  são independentes

$$\text{COV}_{AB} = sc (\sigma_b^2 - \sigma_a^2)$$

- Escrevendo a covariância em termos do coeficiente de correlação

$$\rho_{AB}\sigma_A\sigma_B = SC(\sigma_b^2 - \sigma_a^2)$$

- Como eliminar a dependência com o ângulo?
  - ▶ Podemos calcular as variâncias de  $A$  e  $B$

- Da definição

$$\sigma_A^2 = \langle (A - \mu_A)^2 \rangle = \langle A^2 \rangle$$

$$\sigma_A^2 = \langle (ca + sb)^2 \rangle$$

$$\sigma_A^2 = \langle c^2 a^2 + s^2 b^2 + 2csab \rangle$$

- Como  $a$  e  $b$  não possuem covariância

$$\sigma_A^2 = c^2 \sigma_a^2 + s^2 \sigma_b^2$$

- Similarmente para  $B$

$$\sigma_B^2 = s^2 \sigma_a^2 + c^2 \sigma_b^2$$

- Calculando o produto das variâncias

$$\sigma_A^2 \sigma_B^2 = s^2 c^2 (\sigma_a^4 + \sigma_b^4) + (c^4 + s^4) \sigma_a^2 \sigma_b^2$$

- Comparando ao quadrado de

$$\rho_{AB} \sigma_A \sigma_B = sc (\sigma_b^2 - \sigma_a^2)$$

- Com pouca álgebra, chega-se a

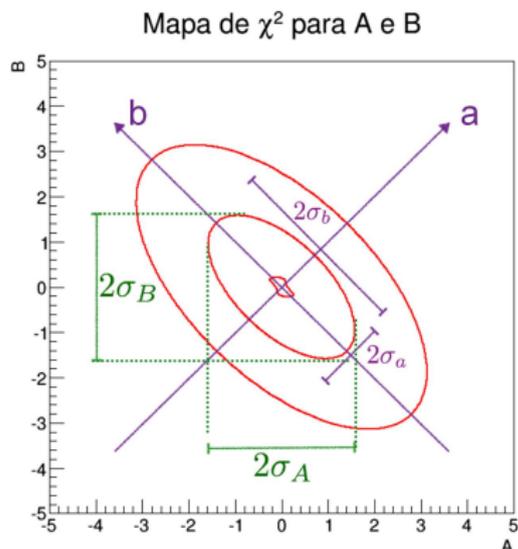
$$\rho_{AB}^2 = 1 - \left( \frac{\sigma_a \sigma_b}{\sigma_A \sigma_B} \right)^2$$

$$A = ca + sb \quad \text{e} \quad B = -sa + cb$$

$$\sigma_A^2 = c^2\sigma_a^2 + s^2\sigma_b^2$$


$$\sigma_B^2 = s^2\sigma_a^2 + c^2\sigma_b^2$$

$$\rho_{AB}^2 = 1 - \left( \frac{\sigma_a\sigma_b}{\sigma_A\sigma_B} \right)^2$$




# Como descrever as curvas de $\chi^2$ com covariância?

Mapa de  $\chi^2$  para a e b



Mapa de  $\chi^2$  para A e B



$$P(a, b) = \frac{1}{2\pi\sigma_a\sigma_b} \exp \left\{ -\frac{1}{2} \left[ \left( \frac{a}{\sigma_a} \right)^2 + \left( \frac{b}{\sigma_b} \right)^2 \right] \right\} \quad P(A, B) = ?$$

## Descrevendo $P(A, B)$

- Começamos escrevendo  $a$  e  $b$  em função de  $A$  e  $B$

$$a = cA - sB \quad \text{e} \quad b = sA + cB$$

- Substituímos em

$$P(a, b) = \frac{1}{2\pi\sigma_a\sigma_b} \exp \left\{ -\frac{1}{2} \left[ \left( \frac{a}{\sigma_a} \right)^2 + \left( \frac{b}{\sigma_b} \right)^2 \right] \right\}$$

- É necessário que (MOSTRE ISTO)

$$P(a, b) da db = P(A, B) dA dB$$

## Descrevendo $P(A, B)$


- Com um pouco de álgebra e substituindo as relações necessárias entre as variâncias de  $a, b$  e  $A, B$

$$P(A, B) = \frac{1}{2\pi\sqrt{1-\rho^2}\sigma_A\sigma_B} \exp \left\{ -\frac{1}{2} \left( \frac{1}{1-\rho^2} \right) \left[ \left( \frac{A}{\sigma_A} \right)^2 + \left( \frac{B}{\sigma_B} \right)^2 - \frac{2\rho AB}{\sigma_A\sigma_B} \right] \right\}$$


- Note que, se a correlação for nula ( $\rho = 0$ ), voltamos à expressão para duas grandezas independentes

$$\sigma_A = 1 \text{ e } \sigma_B = 2$$


Mapa de  $\chi^2$  para A e B  $\rho = -0.95$




Mapa de  $\chi^2$  para A e B  $\rho = -0.75$



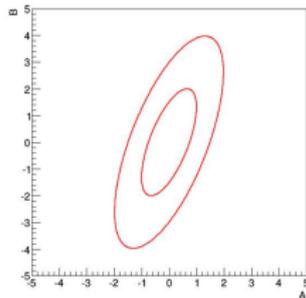
Mapa de  $\chi^2$  para A e B  $\rho = -0.50$



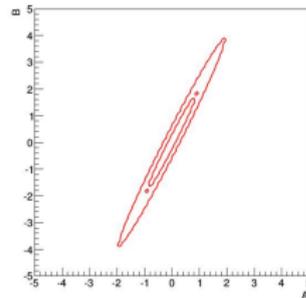
Mapa de  $\chi^2$  para A e B  $\rho = 0$



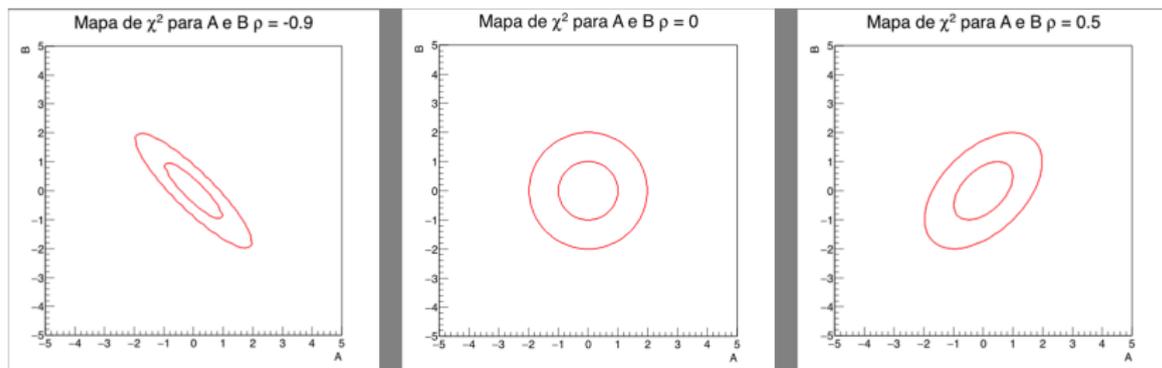
Mapa de  $\chi^2$  para A e B  $\rho = 0.66$



Mapa de  $\chi^2$  para A e B  $\rho = 0.99$



$$\sigma_A = \sigma_B = 1$$



- Incertezas iguais não significa falta de correlação  $\Rightarrow$  preste atenção nisto

- Introduzir correlações entre duas grandezas significa “girar” uma curva de  $\chi^2$ 
  - ▶ Sempre podemos redefinir variáveis de modo a eliminar correlações entre elas
- Do mapa de  $\chi^2$  é possível extrair a correlação entre duas grandezas “geometricamente”