

# Aula 32 – Análise de Correlação e Regressão Linear Simples

Bem-vindo(a) à Aula 32 do nosso Curso de Pesquisa Clínica e Medicina Baseada em Evidências! Sabemos que a jornada de aprendizado pode ser desafiadora, especialmente após um dia cansativo. Mas imagine ter o poder de desvendar os segredos ocultos nos dados, de entender como diferentes fatores se conectam e, mais ainda, de prever resultados com base nessas relações. É exatamente isso que a análise de correlação e regressão linear simples nos permite fazer.

Nesta aula, nosso objetivo é claro: equipar você com as ferramentas para compreender e aplicar esses conceitos fundamentais. Ao final, você será capaz de medir a força e a direção da associação entre duas variáveis, visualizar essas relações de forma intuitiva, construir um modelo para prever uma variável a partir de outra e interpretar o quão bem esse modelo se ajusta aos dados. Essas habilidades são cruciais não apenas para cumprir horas complementares ou para sua aprovação em concursos, mas para se destacar em qualquer área que envolva análise de dados e tomada de decisão baseada em evidências, especialmente na pesquisa clínica.

A relevância prática desses tópicos é imensa. Desde a avaliação da eficácia de um novo medicamento até a compreensão de fatores de risco para doenças, a capacidade de analisar a relação entre variáveis é a espinha dorsal de estudos científicos robustos. E, em um cenário regulatório cada vez mais exigente, como o brasileiro com as diretrizes da ANVISA e do Sistema CEP/CONEP, a solidez da sua análise estatística é um diferencial que garante a validade e a aceitação dos seus resultados.

Nossa jornada começará explorando a ideia de associação, passaremos pela visualização de dados, quantificaremos as relações e, finalmente, aprenderemos a construir modelos preditivos. Prepare-se para conectar o que você já sabe sobre variáveis e estatística básica com um universo de possibilidades analíticas.

# A Busca por Conexões: Por Que as Variáveis se Relacionam?

No vasto universo da pesquisa clínica e da saúde, raramente um evento ocorre de forma isolada. Pelo contrário, a realidade é um emaranhado complexo onde diferentes fatores interagem e se influenciam mutuamente. Pense, por exemplo, na relação entre a dose de um medicamento e a resposta do paciente, ou entre a idade de uma pessoa e a incidência de uma doença específica. Intuitivamente, sabemos que existe uma ligação, mas como podemos quantificar e entender essa ligação de forma rigorosa?

Essa é a grande questão que nos impulsiona a explorar a análise de correlação e regressão. Não se trata apenas de observar que algo acontece, mas de medir a intensidade dessa ocorrência e, se possível, prever o que acontecerá a seguir. É como ser um detetive de dados, buscando pistas e padrões que revelem as histórias escondidas nos números.

A capacidade de identificar e quantificar essas relações é fundamental para a tomada de decisões baseadas em evidências. Seja para um médico ajustando a terapia de um paciente, um pesquisador desenvolvendo um novo fármaco ou um gestor de saúde pública planejando uma campanha de prevenção, entender como as variáveis se associam é o primeiro passo para intervenções eficazes e seguras. Além disso, em um contexto de pesquisa, a solidez dessas análises é um requisito inegociável para que os resultados sejam aceitos por agências reguladoras como a ANVISA, que exigem evidências robustas para a aprovação de produtos e práticas.

# Visualizando a Dança dos Dados: Os Diagramas de Dispersão

Antes de mergulharmos em números e fórmulas, há uma ferramenta incrivelmente poderosa e intuitiva para começar a entender a relação entre duas variáveis: o **diagrama de dispersão**. Imagine que você está tentando entender a relação entre a quantidade de horas que um estudante dedica ao estudo e sua nota final em uma disciplina. Você poderia simplesmente listar os números, mas seria difícil enxergar o padrão.


O diagrama de dispersão resolve isso transformando os dados em uma imagem. Ele é como um mapa onde cada ponto representa um par de valores para as duas variáveis que você está investigando. Uma variável é plotada no eixo horizontal (X) e a outra no eixo vertical (Y). Ao observar a nuvem de pontos, você pode rapidamente identificar se existe uma tendência, a direção dessa tendência e até mesmo a força aparente da relação.

Pense nisso como observar a coreografia de dois dançarinos. Eles se movem juntos em sincronia (relação forte), um segue o outro de perto (relação positiva), um se afasta enquanto o outro se aproxima (relação negativa), ou eles se movem de forma completamente aleatória (sem relação). O diagrama de dispersão nos dá essa primeira impressão visual, que é crucial antes de qualquer análise numérica. Ele nos ajuda a detectar padrões lineares, não lineares e até mesmo a presença de pontos atípicos (outliers) que podem distorcer nossa análise.

# Quantificando a Ligação: O Coeficiente de Correlação de Pearson

Ver um padrão no diagrama de dispersão é um excelente começo, mas como podemos quantificar essa "dança" entre as variáveis? Precisamos de um número que nos diga não apenas a direção da relação, mas também a sua força. É aqui que entra o **Coeficiente de Correlação de Pearson (r)**. Ele é a medida estatística mais comum para avaliar a força e a direção de uma **relação linear** entre duas variáveis contínuas.

Pense no coeficiente de Pearson como um "termômetro" da relação. Ele varia de -1 a +1. Um valor de +1 indica uma correlação positiva perfeita, onde à medida que uma variável aumenta, a outra também aumenta de forma proporcional. Um valor de -1 indica uma correlação negativa perfeita, ou seja, quando uma variável aumenta, a outra diminui proporcionalmente. Um valor próximo de 0 sugere que não há uma relação linear entre as variáveis.



Por exemplo, se estamos investigando a relação entre a dose de um novo analgésico e a redução da dor em pacientes, um coeficiente de Pearson de +0.8 indicaria uma forte correlação positiva: quanto maior a dose, maior a redução da dor. Já um coeficiente de -0.7 entre o número de horas de sono e o nível de estresse indicaria que mais horas de sono estão associadas a menores níveis de estresse. É importante lembrar que Pearson mede apenas relações *lineares*. Uma relação pode ser forte, mas não linear (por exemplo, em forma de U), e Pearson pode subestimá-la.

A capacidade de quantificar essas relações é vital na pesquisa clínica. Um "r" alto e estatisticamente significativo pode ser uma forte indicação de que um tratamento está funcionando ou que um fator de risco é relevante, fornecendo dados cruciais para a **força da evidência** exigida por agências reguladoras como a ANVISA em processos de registro de medicamentos ou dispositivos.

# Correlação Não é Causalidade: Um Alerta Crucial

Aqui está uma das lições mais importantes e frequentemente mal interpretadas na estatística: **correlação não implica causalidade**. É um erro comum e perigoso assumir que, porque duas variáveis se movem juntas, uma causa a outra. Imagine a seguinte situação: estudos mostram uma forte correlação positiva entre o consumo de sorvete e o número de afogamentos. Será que comer sorvete causa afogamentos?

Claro que não! A explicação mais provável é uma terceira variável, o calor. Em dias quentes, as pessoas comem mais sorvete e nadam mais, aumentando a probabilidade de afogamentos. O calor é a **variável de confusão** que cria a ilusão de uma relação causal direta entre sorvete e afogamentos.

Essa distinção é vital na pesquisa clínica. Se um estudo mostra que pacientes que tomam um certo suplemento têm melhoras significativas, e há uma forte correlação entre o uso do suplemento e a melhora, não podemos automaticamente concluir que o suplemento *causou* a melhora. Pode haver outros fatores envolvidos, como mudanças na dieta, exercícios, ou até mesmo o efeito placebo.

A aplicação prática disso é a necessidade de cautela na interpretação de resultados. Para estabelecer causalidade, são necessários estudos com desenhos mais robustos, como ensaios clínicos randomizados e controlados, que minimizam a influência de variáveis de confusão. As **Boas Práticas Clínicas (BPC/GCP)**, padrões internacionais de ética e qualidade, enfatizam a importância de um desenho de estudo rigoroso precisamente para que as conclusões sobre causalidade sejam válidas e confiáveis, algo que as agências reguladoras como a ANVISA e o Sistema CEP/CONEP exigem para a aprovação de pesquisas e produtos.

# Além da Associação: Prevendo o Futuro com a Regressão Linear Simples

Se a correlação nos diz *se* e *quão forte* duas variáveis se movem juntas, a **regressão linear simples** nos leva um passo adiante: ela nos permite *prever* o valor de uma variável com base no valor de outra. Imagine que você descobriu uma forte correlação positiva entre a quantidade de horas de estudo e a nota em uma prova. A regressão linear simples nos permitiria criar um modelo para estimar a nota de um aluno com base nas horas que ele estudou.



Nesse contexto, uma das variáveis é considerada a **variável dependente (Y)**, que é o resultado que queremos prever ou explicar. A outra é a **variável independente (X)**, que é a variável que usamos para fazer a previsão. No nosso exemplo, a nota da prova seria a variável dependente (Y) e as horas de estudo seriam a variável independente (X).

Pense na regressão linear como a tentativa de traçar a "melhor linha reta" através dos pontos em um diagrama de dispersão. Essa linha não apenas resume a relação entre as variáveis, mas também serve como uma ferramenta preditiva. Se você souber o valor de X, pode usar essa linha para estimar o valor correspondente de Y.

Na pesquisa clínica, essa capacidade preditiva é inestimável. Podemos, por exemplo, prever a resposta de um paciente a um tratamento com base em características iniciais, estimar o risco de uma doença com base em fatores demográficos ou até mesmo prever o tempo de recuperação após uma cirurgia. É uma ferramenta poderosa para a tomada de decisões clínicas e de saúde pública.

# A Equação da Linha: Entendendo o Modelo de Regressão

A "melhor linha reta" que mencionamos na regressão linear simples não é apenas um desenho; ela tem uma representação matemática precisa. Essa representação é a **equação da regressão linear simples**, que geralmente é expressa como:

$$Y = a + bX + e$$

Vamos desvendar cada parte dessa equação:

- **Y:** É a **variável dependente**, o valor que queremos prever ou explicar.
- **X:** É a **variável independente**, o valor que usamos para fazer a previsão.
- **a (coeficiente de intercepto):** É o ponto onde a linha de regressão cruza o eixo Y. Em termos práticos, é o valor esperado de Y quando X é igual a zero. Pense nele como o "ponto de partida" ou o valor base de Y.
- **b (coeficiente de inclinação ou coeficiente angular):** Ele nos diz o quanto Y muda, em média, para cada unidade de mudança em X. Se 'b' for positivo, a linha sobe (relação positiva); se for negativo, a linha desce (relação negativa).
- **e (erro ou resíduo):** Representa a diferença entre o valor real de Y e o valor de Y previsto pelo nosso modelo. É a parte da variação de Y que o modelo não consegue explicar.

A interpretação desses coeficientes é a chave para extrair significado do seu modelo. O coeficiente 'b' nos diz a magnitude e a direção do impacto de X sobre Y, o que é fundamental para quantificar o efeito de uma intervenção ou fator de risco na pesquisa clínica.

# O Coração da Previsão: O Coeficiente de Determinação ( $R^2$ )

Depois de construir nosso modelo de regressão, a próxima pergunta natural é: "Quão bom é esse modelo? Quanta da variação na variável dependente (Y) ele realmente consegue explicar?" É aqui que entra o **Coeficiente de Determinação, ou  $R^2$** .



Pense no  $R^2$  como uma "nota" para o seu modelo de regressão. Ele nos diz a proporção da variância total da variável dependente (Y) que é explicada pela variável independente (X) no modelo. O  $R^2$  varia de 0 a 1 (ou de 0% a 100%).

- Um  $R^2$  de 0.70 (ou 70%) significa que 70% da variação em Y pode ser explicada pelas mudanças em X.
- Um  $R^2$  próximo de 1 indica que o modelo explica uma grande proporção da variância de Y, sugerindo um bom ajuste.
- Um  $R^2$  próximo de 0 indica que o modelo explica muito pouco da variância de Y, sugerindo um ajuste pobre.

Na pesquisa clínica, o  $R^2$  é uma métrica crucial para avaliar a utilidade de um modelo preditivo. Um alto  $R^2$  em um estudo bem conduzido fortalece a evidência de que um tratamento ou fator tem um impacto significativo, o que é fundamental para a **avaliação da eficácia** de novas terapias pela ANVISA e outras agências reguladoras. Ele ajuda a justificar a relevância clínica e a aplicabilidade prática dos achados.

# Construindo o Modelo: Mínimos Quadrados e a Linha de Melhor Ajuste

Agora que entendemos a equação e o  $R^2$ , surge a questão: como exatamente encontramos essa "melhor linha reta" que representa a relação entre X e Y? A resposta está em um método estatístico chamado **Mínimos Quadrados Ordinários (MQO)**, ou Ordinary Least Squares (OLS) em inglês.

Imagine que você tem um monte de pontos espalhados em um gráfico, e sua tarefa é desenhar uma linha que passe o mais perto possível de todos eles. Você poderia tentar várias linhas, mas qual delas seria a "melhor"? O método dos Mínimos Quadrados nos dá um critério objetivo. Ele busca a linha que minimiza a soma dos quadrados das distâncias verticais (os **resíduos**) de cada ponto até a linha.

O MQO é o método mais comum para estimar os coeficientes 'a' e 'b' da equação de regressão linear. Ele garante que a linha encontrada seja a que melhor representa a tendência linear dos dados, minimizando o erro de previsão. Embora os cálculos manuais possam ser complexos, softwares estatísticos como R, Python, SPSS ou Stata realizam essa otimização de forma automática, fornecendo os coeficientes 'a' e 'b' para a sua análise. Entender o princípio por trás do MQO é fundamental para confiar nos resultados gerados por esses softwares e para interpretar corretamente o "ajuste" do seu modelo.

# Pressupostos da Regressão Linear: A Base para a Confiança

Assim como uma casa precisa de uma fundação sólida para se manter de pé, um modelo de regressão linear precisa de certos **pressupostos** para que suas estimativas e conclusões sejam válidas e confiáveis. Ignorar esses pressupostos pode levar a resultados enganosos e interpretações incorretas, o que é particularmente perigoso na pesquisa clínica.



## Linearidade

A relação entre X e Y deve ser linear. Se o diagrama de dispersão mostrar uma curva, a regressão linear simples não será o modelo mais apropriado.



## Independência dos Resíduos

Os erros (resíduos) de cada observação devem ser independentes uns dos outros.



## Homocedasticidade

A variância dos resíduos deve ser constante para todos os níveis de X.



## Normalidade dos Resíduos

Os resíduos devem ser normalmente distribuídos.


A verificação desses pressupostos é uma etapa crítica em qualquer análise de regressão. Ferramentas visuais (como gráficos de resíduos) e testes estatísticos podem ser usados para avaliá-los. A violação de um ou mais pressupostos pode exigir transformações nos dados, o uso de outros tipos de regressão ou uma interpretação mais cautelosa dos resultados. Garantir a validade metodológica, incluindo a verificação de pressupostos, é uma exigência fundamental das **Boas Práticas Clínicas (BPC/GCP)** e um ponto de análise rigorosa por comitês de ética em pesquisa como o **Sistema CEP/CONEP** ao avaliar a submissão de projetos.

# Lidando com Desafios: Outliers e Variáveis Confounding

O mundo real dos dados raramente é perfeito, e na pesquisa clínica, isso é ainda mais evidente. Ao realizar análises de correlação e regressão, você inevitavelmente se deparará com desafios que podem distorcer seus resultados se não forem tratados adequadamente. Dois dos mais comuns são os **outliers** e as **variáveis de confusão (confounding variables)**.



**Outliers (Pontos Atípicos):** Imagine que você está medindo a pressão arterial de pacientes e, de repente, um valor é extremamente alto ou baixo em comparação com os demais. Esse é um outlier. No contexto da regressão, um outlier é um ponto de dado que se desvia significativamente da tendência geral dos outros pontos.



**Variáveis de Confusão:** Já discutimos a ideia de que correlação não é causalidade devido a terceiras variáveis. Elas estão relacionadas tanto à variável independente (X) quanto à variável dependente (Y), criando uma associação espúria ou mascarando uma associação real.

Lidar com esses desafios é um sinal de rigor metodológico e é essencial para garantir a validade e a confiabilidade dos seus resultados na pesquisa clínica, atendendo aos padrões de **Boas Práticas Clínicas (BPC/GCP)** e às expectativas de órgãos como o **Sistema CEP/CONEP** e a **ANVISA**.

# Aplicações Práticas na Pesquisa Clínica e Saúde Pública

A análise de correlação e regressão linear simples não são apenas conceitos teóricos; são ferramentas poderosas com aplicações diretas e impactantes na pesquisa clínica e na saúde pública. A capacidade de quantificar e prever relações entre variáveis é a base para muitas descobertas e decisões que afetam a vida das pessoas.



## Farmacologia

Relação dose-resposta, farmacocinética e determinação da dose ideal de medicamentos.



## Epidemiologia

Identificação de fatores de risco, previsão de tendências e avaliação de intervenções em saúde pública.



## Gestão em Saúde

Previsão de demanda por leitos, análise de qualidade de vida e planejamento de recursos.

Em todos esses cenários, a aplicação rigorosa da correlação e regressão linear simples fornece a **evidência científica** necessária para embasar decisões clínicas, políticas de saúde e o desenvolvimento de novas terapias. Essa evidência é o que as agências reguladoras, como a **ANVISA**, e os comitês de ética, como o **Sistema CEP/CONEP**, buscam ao avaliar a validade e a relevância de uma pesquisa.

# A Ética e a Integridade dos Dados na Análise Estatística

No campo da pesquisa clínica, a análise estatística não é apenas uma questão de números e fórmulas; é, acima de tudo, uma questão de ética e integridade. A forma como os dados são coletados, analisados e interpretados tem implicações diretas na saúde e bem-estar dos pacientes, na confiança pública na ciência e na credibilidade das instituições de pesquisa.

## Manipulação de Dados

Alterar ou fabricar dados para obter um resultado desejado.

## Seleção de Dados

Escolher apenas os dados que apoiam uma hipótese, ignorando os demais.

## P-Hacking

Realizar múltiplas análises até encontrar um resultado significativo.

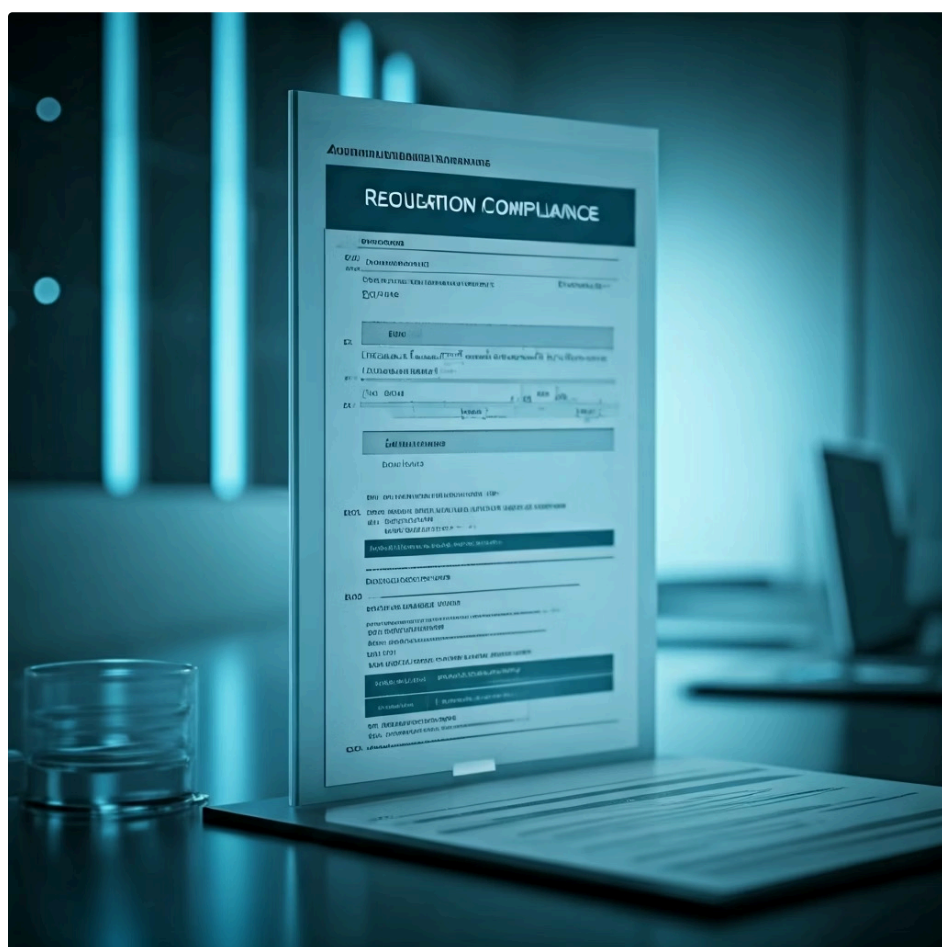
## Relato Seletivo

Publicar apenas resultados positivos e omitir os negativos.


Para combater essas práticas, a pesquisa clínica é regida por princípios éticos rigorosos e diretrizes regulatórias. A **Resolução CNS nº 466/12** no Brasil estabelece as diretrizes gerais para pesquisas envolvendo seres humanos, enfatizando a necessidade de metodologia adequada e análise de dados transparente. As **Boas Práticas Clínicas (BPC/GCP)** exigem que os planos de análise estatística sejam predefinidos e que os dados sejam gerenciados com rigor, garantindo a rastreabilidade e a integridade. O **Sistema CEP/CONEP** atua como guardião desses princípios, revisando e aprovando os projetos de pesquisa para garantir que a metodologia, incluindo a análise estatística, seja ética e cientificamente sólida.

# O Papel da Análise de Correlação e Regressão no Marco Regulatório Brasileiro

A pesquisa clínica no Brasil opera sob um rigoroso arcabouço regulatório, e a análise estatística, incluindo a correlação e a regressão, desempenha um papel central nesse cenário. Não se trata apenas de realizar cálculos, mas de garantir que esses cálculos e suas interpretações estejam alinhados com as expectativas e exigências das autoridades sanitárias e éticas.



A **ANVISA**, com seu novo marco regulatório de 2024, tem um foco crescente na qualidade e robustez dos dados apresentados para o registro de medicamentos, produtos para a saúde e na condução de ensaios clínicos.



O **Sistema CEP/CONEP** é o guardião da ética na pesquisa envolvendo seres humanos no Brasil, avaliando o plano de análise estatística e a adequação metodológica dos projetos.

Em resumo, a análise de correlação e regressão linear simples não são apenas ferramentas acadêmicas; são componentes essenciais para a conformidade regulatória. Elas fornecem a linguagem quantitativa que permite aos pesquisadores comunicar seus achados de forma clara e convincente às autoridades, assegurando que a pesquisa seja não apenas cientificamente válida, mas também eticamente responsável e legalmente aceitável no contexto brasileiro.

# Consolidação e Próximos Passos

Chegamos ao final da nossa jornada pela análise de correlação e regressão linear simples. Vimos que, no vasto mar de dados da pesquisa clínica, a capacidade de identificar, quantificar e prever relações entre variáveis é uma bússola essencial. Começamos com a visualização intuitiva através dos diagramas de dispersão, que nos dão a primeira pista sobre a "dança" dos dados. Em seguida, aprendemos a quantificar essa dança com o Coeficiente de Correlação de Pearson, que nos informa a força e a direção de uma relação linear.

Avançamos para a Regressão Linear Simples, uma ferramenta poderosa que nos permite ir além da associação e construir modelos para prever uma variável a partir de outra, entendendo a equação da linha e a importância do Coeficiente de Determinação ( $R^2$ ) para avaliar o ajuste do nosso modelo. Discutimos a crucial distinção entre correlação e causalidade, os pressupostos necessários para uma análise válida e como lidar com desafios como outliers e variáveis de confusão. Finalmente, conectamos esses conceitos à realidade da pesquisa clínica e ao rigor do marco regulatório brasileiro, destacando a importância da ética e integridade dos dados.

## → **Comece com o diagrama de dispersão**

Visualize a relação entre as variáveis.

## → **Use o coeficiente de Pearson**

Quantifique a força e direção da relação linear.

## → **Construa o modelo de regressão**

Interprete os coeficientes e avalie o  $R^2$ .

## → **Verifique pressupostos e outliers**

Garanta a validade e confiabilidade dos resultados.

# Autoavaliação

1. Qual das seguintes afirmações sobre o Coeficiente de Correlação de Pearson ( $r$ ) está CORRETA?
  - a) Um valor de  $r = 0$  indica uma forte relação não linear entre as variáveis.
  - b) Ele mede a força e a direção de qualquer tipo de relação entre duas variáveis.
  - c) Um valor de  $r = -0.9$  indica uma forte correlação negativa.
  - d) Ele pode ser usado para estabelecer causalidade entre as variáveis.
2. Em um modelo de regressão linear simples ( $Y = a + bX + e$ ), o coeficiente 'b' representa:
  - a) O valor esperado de Y quando X é zero.
  - b) A proporção da variância de Y explicada por X.
  - c) A mudança média em Y para cada unidade de mudança em X.
  - d) O erro ou resíduo do modelo.
3. Um pesquisador obteve um  $R^2$  de 0.85 em seu modelo de regressão linear. Isso significa que:
  - a) 85% dos dados são outliers.
  - b) 85% da variação na variável dependente é explicada pela variável independente.
  - c) A correlação entre as variáveis é de 0.85.
  - d) O modelo não é adequado para previsão.
4. Qual dos seguintes pressupostos é fundamental para a validade das estimativas em uma regressão linear simples?
  - a) A variável independente deve ser categórica.
  - b) Os resíduos devem ser independentes e ter variância constante (homocedasticidade).
  - c) A relação entre X e Y deve ser exponencial.
  - d) A amostra deve ser pequena.
5. Explique, em suas palavras, por que a distinção entre correlação e causalidade é tão crítica na pesquisa clínica e como as Boas Práticas Clínicas (BPC/GCP) abordam essa questão.

# Gabarito

## 1. c)

Um valor de  $r = -0.9$  indica uma forte correlação negativa.

## 2. c)

A mudança média em Y para cada unidade de mudança em X.

## 3. b)

85% da variação na variável dependente é explicada pela variável independente.

## 4. b)

Os resíduos devem ser independentes e ter variância constante (homocedasticidade).



**5. Resposta esperada:** A distinção é crítica porque confundir correlação com causalidade pode levar a conclusões errôneas sobre a eficácia de tratamentos ou a identificação de fatores de risco, com sérias implicações para a saúde pública e individual. As BPC/GCP abordam isso exigindo desenhos de estudo rigorosos, como ensaios clínicos randomizados e controlados, que são projetados especificamente para minimizar variáveis de confusão e permitir inferências causais mais robustas, em contraste com estudos observacionais que podem apenas indicar correlação.

# Conexão com a Próxima Aula

Nesta aula, desvendamos o poder da regressão linear simples, que nos permite prever uma variável a partir de outra. Mas o que acontece quando a realidade é mais complexa e múltiplas variáveis influenciam o resultado que queremos prever? Na **Aula 33 – Introdução à Análise de Regressão Múltipla e Logística**, expandiremos nossos horizontes para modelos que incorporam diversos preditores e exploraremos como prever resultados categóricos, abrindo portas para análises ainda mais sofisticadas e alinhadas com a complexidade dos dados clínicos.

## Recursos Adicionais

- Livros de Estatística Aplicada à Saúde
- Softwares Estatísticos (R, Python, SPSS)
- Diretrizes da ANVISA e Resoluções CNS





# NOTA IMPORTANTE

⚠ As informações regulatórias/legais/técnicas desta aula estão atualizadas até 2025. Consulte sempre fontes oficiais para verificar alterações.