

Aula 15 – Modelos para Volatilidade: ARCH e GARCH

Bem-vindo(a) à Aula 15 do nosso Curso de Série Temporal e Previsão! Sei que o dia pode ter sido longo, mas a jornada que vamos iniciar agora é fascinante e extremamente relevante para quem busca entender e prever os movimentos do mundo real, especialmente no mercado financeiro. Prepare-se para desvendar um dos conceitos mais dinâmicos e desafiadores da análise de séries temporais: a **volatilidade**.

Nesta aula, nosso objetivo principal é que você desenvolva uma compreensão sólida sobre os Modelos para Volatilidade, focando especificamente nos modelos ARCH e GARCH. Ao final, você será capaz de identificar situações onde a variância de uma série temporal não é constante, entender como os modelos ARCH e GARCH capturam essa dinâmica e reconhecer suas aplicações práticas, especialmente em cenários financeiros.

A relevância prática desses modelos é imensa. Imagine poder prever não apenas o valor médio de uma ação, mas também o quão "nervoso" ou "calmo" o mercado estará. Essa capacidade é crucial para a gestão de riscos, precificação de ativos e tomada de decisões de investimento. É um conhecimento que o diferencia, seja na academia, no mercado de trabalho ou em avaliações de concurso.

Vamos embarcar em uma jornada que começa com a compreensão da volatilidade, passa pelas limitações dos modelos tradicionais como o ARIMA, e nos leva à construção e aplicação dos poderosos modelos ARCH e GARCH. Veremos como eles evoluíram e como se conectam com as tendências mais recentes em Machine Learning e Deep Learning. Para começar, vamos relembrar brevemente o que já sabemos sobre séries temporais e como a "variância" se encaixa nesse cenário.

O Que é Volatilidade e Por Que Ela Importa?

No nosso dia a dia, estamos acostumados a pensar em previsões como a temperatura média de amanhã ou o preço médio de um produto. Em séries temporais, modelos como o ARIMA que estudamos focam principalmente em prever a **média** da série, ou seja, o seu comportamento central. No entanto, o mundo real é muito mais do que apenas médias; ele é repleto de incertezas e flutuações.

Pense na previsão do tempo. Não basta saber que a temperatura média será de 25°C. É igualmente importante saber se essa temperatura vai oscilar muito ao longo do dia, com picos de calor e quedas bruscas, ou se ela permanecerá estável. Essa medida da intensidade das flutuações é o que chamamos de **volatilidade**. Em termos estatísticos, a volatilidade é a medida da dispersão dos retornos de um ativo financeiro, ou, de forma mais ampla, a variabilidade de uma série temporal ao longo do tempo.

❏ Para o investidor, a volatilidade é sinônimo de **risco**. Um ativo com alta volatilidade significa que seus retornos podem variar muito, tanto para cima quanto para baixo, aumentando a incerteza.

Já um ativo com baixa volatilidade tende a ter retornos mais estáveis e previsíveis. Entender e modelar essa volatilidade é crucial para gerenciar riscos, precificar opções e tomar decisões de investimento mais informadas. É como ter um mapa que não só mostra o caminho, mas também indica as áreas de turbulência.

Onde os Modelos ARIMA Encontram Seus Limites?

Você se lembra dos modelos ARIMA? Eles são ferramentas poderosas para modelar a média de uma série temporal, capturando padrões de autocorrelação e tendências. Eles assumem que, após remover a média e os padrões de dependência, os **resíduos** (o "erro" da previsão) são independentes e têm uma **variância constante** ao longo do tempo. Essa é a premissa de **homocedasticidade**.

Mas a realidade, especialmente em séries financeiras, é bem diferente. Imagine que você está observando o preço de uma ação. Em alguns períodos, o preço pode variar muito pouco, mostrando um comportamento calmo. De repente, após um evento de notícia importante, o preço começa a oscilar violentamente, com grandes altas e baixas em curtos intervalos. Essa mudança na intensidade das flutuações é um sinal claro de que a variância dos resíduos não é constante, mas sim **variável no tempo**.

Homocedasticidade

Variância constante dos resíduos ao longo do tempo

Heterocedasticidade

Variância dos resíduos que muda ao longo do tempo

Heterocedasticidade Condicional

Variância que depende de informações passadas

Quando a variância dos resíduos de um modelo não é constante, dizemos que há **heterocedasticidade**. E, mais especificamente, quando essa heterocedasticidade depende de informações passadas (como grandes choques no período anterior), temos a **heterocedasticidade condicional**. Os modelos ARIMA, por si só, não conseguem capturar essa dinâmica da variância. Eles podem até prever a média corretamente, mas falham em modelar a "intensidade" dos erros, deixando uma parte importante da informação sem ser explorada. É como ter um termômetro que mede a temperatura média do dia, mas não consegue registrar as ondas de calor ou as quedas bruscas que aconteceram.

A Revolução do ARCH: Modelando a Variância

A incapacidade dos modelos tradicionais de lidar com a variância que muda ao longo do tempo era um grande problema, especialmente para economistas e analistas financeiros. Foi para resolver essa lacuna que, em 1982, Robert Engle introduziu o conceito de **Heterocedasticidade Condicional Autorregressiva**, ou **ARCH** (Autoregressive Conditional Heteroskedasticity). Essa foi uma verdadeira revolução, pois permitiu modelar a variância como uma função de informações passadas.

A ideia central por trás do ARCH é que a volatilidade de hoje não é aleatória; ela é influenciada pela volatilidade de ontem.

Mais especificamente, grandes erros (ou choques) no passado tendem a ser seguidos por grandes erros no presente, e pequenos erros tendem a ser seguidos por pequenos erros. É como se o mercado tivesse uma "memória" para a sua própria turbulência. Se o dia anterior foi muito agitado, há uma boa chance de que o dia de hoje também seja.

Pense nisso como um "medidor de estresse" do mercado. Se o medidor registrou um nível de estresse muito alto ontem (grandes variações), ele tende a continuar em um nível elevado hoje. O modelo ARCH captura essa persistência da volatilidade, permitindo que a variância condicional (a variância esperada para o próximo período, dadas as informações atuais) mude ao longo do tempo, em vez de permanecer constante. Isso nos dá uma ferramenta muito mais realista para entender e prever o risco.

Dissecando o Modelo ARCH (Parte 1)

Para entender o modelo ARCH de forma mais concreta, vamos pensar na sua estrutura. Um modelo ARCH(q) assume que a variância condicional do erro no tempo t (denotada por h_t ou σ_t^2) depende dos quadrados dos erros passados até um certo número de defasagens q .

Matematicamente, a variância condicional h_t é modelada da seguinte forma:

$$h_t = \alpha_0 + \alpha_1 \cdot \varepsilon_{t-1}^2 + \alpha_2 \cdot \varepsilon_{t-2}^2 + \dots + \alpha_q \cdot \varepsilon_{t-q}^2$$

h_t

Variância condicional no tempo t

α_0

Constante (nível base da variância)

α_i

Coeficientes que medem o impacto dos erros passados

$\varepsilon_{(t-i)}^2$

Erros quadrados (resíduos) de períodos anteriores

Para que a variância seja positiva e estável, os coeficientes α_i devem ser não negativos ($\alpha_i \geq 0$) e a soma deles deve ser menor que 1 (para garantir que a variância não exploda). Um modelo ARCH(1), por exemplo, considera apenas o erro quadrado do período imediatamente anterior: $h_t = \alpha_0 + \alpha_1 \cdot \varepsilon_{(t-1)}^2$. Isso significa que a volatilidade de hoje é influenciada diretamente pela intensidade do choque de ontem.

Dissecando o Modelo ARCH (Parte 2) e Limitações

A estimativa dos parâmetros de um modelo ARCH geralmente é feita por **Máxima Verossimilhança**, um método estatístico que busca os valores dos coeficientes que tornam a probabilidade de observar os dados atuais a maior possível. Uma vez estimados, podemos usar esses parâmetros para prever a volatilidade futura.

Por exemplo, se estamos modelando os retornos diários de uma ação e observamos um grande choque (um $\varepsilon_{(t-1)}^2$ alto), o modelo ARCH(1) nos dirá que a variância h_t esperada para o dia seguinte será maior. Isso é extremamente útil para entender como a informação de um evento inesperado se propaga na volatilidade do mercado.

Limitações do ARCH

- Necessidade de muitos parâmetros (q) para capturar persistência
- Resposta simétrica a choques positivos e negativos
- Menos parcimonioso para séries financeiras

No entanto, apesar de sua inovação, o modelo ARCH possui algumas limitações. Uma delas é a necessidade de um grande número de parâmetros (q) para capturar a persistência da volatilidade em séries financeiras. Muitas vezes, a volatilidade de hoje pode ser influenciada por choques que ocorreram há muitos dias, exigindo um q elevado. Isso torna o modelo menos parcimonioso e mais difícil de estimar.

Outra limitação é que o modelo ARCH responde simetricamente a choques positivos e negativos. Ou seja, uma queda brusca no mercado (erro negativo grande) tem o mesmo impacto na volatilidade futura que uma alta brusca de mesma magnitude (erro positivo grande). Na realidade, choques negativos (más notícias) tendem a aumentar a volatilidade mais do que choques positivos (boas notícias) de igual magnitude. Mas a história não termina aqui...

GARCH: Uma Evolução Natural e Mais Eficiente

As limitações do modelo ARCH, especialmente a necessidade de muitos parâmetros para capturar a persistência da volatilidade, levaram a uma evolução natural. Em 1986, Tim Bollerslev, aluno de Robert Engle, propôs o modelo **GARCH** (Generalized Autoregressive Conditional Heteroskedasticity). O GARCH é uma generalização do ARCH que permite uma representação mais flexível e parcimoniosa da variância condicional.

A grande sacada do GARCH é que ele não apenas considera os erros quadrados passados (como o ARCH), mas também as **variâncias condicionais passadas**.

É como se, para prever o nível de estresse do mercado hoje, você não olhasse apenas para os eventos estressantes de ontem, mas também para o nível geral de estresse que o mercado já estava sentindo ontem. Isso permite que a volatilidade seja mais persistente e que o modelo capture essa persistência com menos parâmetros.

Modelo ARCH

"Se choveu muito ontem (grande erro), o rio estará agitado hoje."

Modelo GARCH

"Se choveu muito ontem (grande erro) e o rio já estava agitado ontem (alta variância condicional passada), então ele estará ainda mais agitado hoje."

Essa adição da variância passada torna o GARCH muito mais eficiente para modelar a persistência da volatilidade observada em séries financeiras.

Entendendo o Modelo GARCH (Parte 1)

Um modelo GARCH(p,q) estende o ARCH(q) adicionando termos de variância condicional defasada. A variância condicional h_t no tempo t é modelada como:

$$h_t = \alpha_0 + \alpha_1 \cdot \varepsilon_{t-1}^2 + \dots + \alpha_q \cdot \varepsilon_{t-q}^2 + \beta_1 \cdot h_{t-1} + \dots + \beta_p \cdot h_{t-p}$$

h_t

Variância condicional no tempo t

α_0

Constante

α_i

Coeficientes dos termos ARCH (impacto dos erros quadrados passados)

β_j

Coeficientes dos termos GARCH (impacto das variâncias condicionais passadas)

$\varepsilon_{(t-i)}^2$

Erros quadrados (resíduos) de períodos anteriores

$h_{(t-j)}$

Variâncias condicionais de períodos anteriores

O modelo GARCH(1,1) é o mais comum e amplamente utilizado devido à sua parcimônia e capacidade de capturar a maioria dos padrões de volatilidade. Ele é definido por: $h_t = \alpha_0 + \alpha_1 \cdot \varepsilon_{(t-1)}^2 + \beta_1 \cdot h_{(t-1)}$. Aqui, α_1 mede a sensibilidade da volatilidade atual a choques passados, e β_1 mede a persistência da volatilidade.

Entendendo o Modelo GARCH (Parte 2) e Vantagens

Para que o modelo GARCH seja estacionário e a variância seja positiva, os coeficientes α_0 , α_i e β_j devem ser não negativos, e a soma dos coeficientes α_i e β_j deve ser menor que 1 ($\sum \alpha_i + \sum \beta_j < 1$). Se essa soma for próxima de 1, indica que a volatilidade é altamente persistente, ou seja, um choque na volatilidade levará muito tempo para se dissipar.



Parcimônia

GARCH(1,1) captura a mesma persistência que ARCH(q) com q grande, usando apenas três parâmetros



Realismo

Reflete melhor a realidade de que a volatilidade é um processo que se autoalimenta



Gestão de Risco

Fundamental para calcular o Valor em Risco (VaR) de forma mais precisa

Conectando com a aplicação real, a capacidade do GARCH de modelar a persistência da volatilidade é fundamental para a gestão de risco. Por exemplo, ao calcular o **Valor em Risco (VaR)** de um portfólio, que estima a perda máxima esperada em um determinado horizonte de tempo com uma certa probabilidade, a inclusão de um modelo GARCH para a volatilidade torna a estimativa muito mais precisa e realista, pois considera a dinâmica do risco ao longo do tempo.

ARCH vs. GARCH: Qual Escolher?

Agora que você conhece os dois modelos, pode surgir a pergunta: qual deles devo usar? A escolha entre ARCH e GARCH, ou até mesmo entre diferentes ordens de GARCH (como GARCH(1,1) ou GARCH(1,2)), depende muito das características da sua série temporal e do objetivo da sua análise.

Em geral, o modelo **GARCH(1,1)** é o ponto de partida mais comum e robusto para a maioria das séries financeiras. Ele é surpreendentemente eficaz em capturar a dinâmica da volatilidade na maioria dos casos, sendo parcimonioso e flexível. Raramente é necessário um modelo GARCH de ordem superior (como GARCH(2,2)), a menos que haja evidências estatísticas muito fortes de que ordens maiores são necessárias para capturar padrões específicos de persistência.

O modelo **ARCH** puro é menos utilizado na prática para modelar a volatilidade de séries financeiras de alta frequência (diárias, horárias), pois ele geralmente exige muitas defasagens para capturar a persistência observada, tornando-o menos eficiente que o GARCH. No entanto, o ARCH foi o precursor e é fundamental para entender a lógica por trás da modelagem da variância condicional.

Conceito	Âmbito/Aplicação	Base/Origem	Exemplo
ARCH	Modelagem da variância condicional com base em choques passados.	Variância depende de erros quadrados passados.	ARCH(q): h_t depende de $\varepsilon_{(t-1)}^2, \dots, \varepsilon_{(t-q)}^2$.
GARCH	Generalização do ARCH, mais eficiente para persistência da volatilidade.	Variância depende de erros quadrados passados E variâncias condicionais passadas.	GARCH(1,1): h_t depende de $\varepsilon_{(t-1)}^2$ e $h_{(t-1)}$.

Para te ajudar a visualizar as principais diferenças e quando cada um pode ser mais relevante, veja o quadro comparativo acima. Lembre-se que a escolha final deve sempre ser guiada por testes estatísticos e pela análise da adequação do modelo aos dados.

Aplicações Práticas: Séries Financeiras

A beleza dos modelos ARCH e GARCH reside em sua capacidade de transformar a forma como entendemos e gerenciamos o risco. Sua aplicação mais proeminente e impactante é, sem dúvida, no campo das **finanças**.

Imagine que você é um gestor de portfólio. Não basta saber que o retorno médio de uma ação é de 0,5% ao dia. Você precisa saber o quão volátil essa ação pode ser, pois isso impacta diretamente o risco do seu investimento. Modelos GARCH são amplamente utilizados para:

01

Previsão de Volatilidade

Estimar a volatilidade futura de ativos financeiros (ações, moedas, commodities). Essa previsão é crucial para a tomada de decisões de investimento e para a precificação de derivativos.

03

Precificação de Opções

O famoso modelo de Black-Scholes para precificação de opções assume volatilidade constante, o que é uma simplificação irreal. Modelos GARCH permitem incorporar a volatilidade que muda ao longo do tempo, resultando em preços de opções mais precisos.

02

Gestão de Risco

Calcular métricas de risco como o **Valor em Risco (VaR)** e o **Expected Shortfall (ES)**. Ao incorporar a volatilidade dinâmica, essas medidas se tornam muito mais realistas, ajudando bancos e instituições financeiras a cumprir requisitos regulatórios e a proteger seus capitais.

04

Otimização de Portfólio

Ao entender a volatilidade e a correlação entre diferentes ativos, os investidores podem construir portfólios mais eficientes, maximizando o retorno para um dado nível de risco ou minimizando o risco para um dado retorno.

Em resumo, ARCH e GARCH são ferramentas indispensáveis para qualquer profissional que lida com dados financeiros e precisa quantificar e gerenciar o risco de forma sofisticada.

Além do Básico: Hibridização e Machine Learning

O mundo da análise de séries temporais está em constante evolução. Embora os modelos ARCH e GARCH sejam poderosos, as tendências atuais buscam combiná-los com outras abordagens para obter resultados ainda melhores. Uma dessas tendências é a **Hibridização de Modelos**.

A ideia é simples: por que escolher entre um modelo estatístico clássico (como ARIMA-GARCH) e uma abordagem de Machine Learning (ML) se podemos usar o melhor de ambos?

Modelos híbridos combinam a capacidade dos modelos estatísticos de capturar padrões lineares e a dinâmica da volatilidade com a flexibilidade dos modelos de ML para aprender relações não lineares e complexas nos dados. Por exemplo, um modelo ARIMA-GARCH pode ser usado para modelar a média e a variância, e os resíduos resultantes podem ser alimentados em uma rede neural para capturar padrões remanescentes. É como um chef que combina uma receita tradicional (ARIMA-GARCH) com técnicas de culinária molecular (ML) para criar um prato inovador e delicioso.



Modelos Estatísticos

Capturam padrões lineares e dinâmica da volatilidade



Machine Learning

Aprendem relações não lineares e complexas



Modelos Híbridos

Combinam o melhor de ambas as abordagens

Outra área de crescimento explosivo é o uso de **Deep Learning para Séries Temporais**. Arquiteturas como as LSTMs (Long Short-Term Memory) e Transformers, originalmente desenvolvidas para processamento de linguagem natural, estão se mostrando extremamente eficazes para aprender dependências de longo prazo e padrões complexos em séries temporais, incluindo a volatilidade. Com grandes volumes de dados, esses modelos podem superar abordagens tradicionais, especialmente em tarefas de previsão de alta frequência.

O Futuro da Modelagem de Volatilidade: Automação e Big Data

Avançando para 2025 e além, a modelagem de volatilidade está sendo impulsionada por duas forças poderosas: a automação e o volume crescente de dados.

Feature Engineering Automatizado

O **Feature Engineering Automatizado** é uma tendência que simplifica o processo de criação de variáveis preditoras a partir de dados brutos de séries temporais. Ferramentas e bibliotecas como tsfresh (Time Series Feature Extraction based on Scalable Hypothesis tests) podem extrair milhares de características estatísticas de uma série temporal de forma automática, que podem então ser usadas como entradas para modelos de Machine Learning ou Deep Learning. Isso acelera a fase de pré-processamento e permite que os cientistas de dados se concentrem mais na modelagem e interpretação.

Big Data e Tempo Real

Com o advento do **Big Data**, a capacidade de processar e analisar volumes massivos de informações em tempo real se torna um diferencial. Isso permite a construção de modelos de volatilidade mais granulares e adaptativos, que podem reagir quase instantaneamente a novas informações do mercado. A combinação de modelos GARCH com técnicas de Big Data e Machine Learning abre portas para sistemas de negociação algorítmica mais sofisticados e sistemas de alerta de risco em tempo real.

❏ **Desafios Emergentes:** Essa sofisticação também traz desafios, como a interpretabilidade dos modelos complexos e as implicações éticas do uso de algoritmos autônomos em mercados financeiros. A necessidade de profissionais que compreendam tanto a teoria estatística quanto as novas tecnologias é cada vez maior.

Dicas para o Sucesso na Modelagem de Volatilidade

Chegamos a um ponto crucial da nossa jornada. Você agora compreende a importância da volatilidade, as limitações dos modelos tradicionais e a capacidade dos modelos ARCH e GARCH de capturar essa dinâmica. Mas como aplicar esse conhecimento de forma eficaz?

Aqui estão algumas dicas práticas para o sucesso na modelagem de volatilidade:

1 Qualidade dos Dados é Fundamental

Certifique-se de que seus dados de séries temporais estejam limpos, sem valores ausentes e com a frequência correta. Erros nos dados podem levar a modelos enganosos.

2 Comece Simples

O GARCH(1,1) é um excelente ponto de partida. Ele é robusto e, na maioria das vezes, suficiente para capturar a persistência da volatilidade. Apenas considere modelos mais complexos se houver evidências claras de que eles são necessários.

3 Teste e Valide

Não confie apenas nos resultados da estimação. Realize testes de diagnóstico nos resíduos do seu modelo GARCH para verificar se a heterocedasticidade foi removida. Use técnicas de backtesting para avaliar a performance do seu modelo em dados não vistos.

4 Conhecimento do Domínio

A estatística é uma ferramenta, mas o contexto é o guia. Entender o mercado financeiro, os eventos econômicos e os fatores que impulsionam a volatilidade é tão importante quanto dominar as equações.

Lembre-se, a modelagem de séries temporais é uma arte e uma ciência. A prática leva à perfeição, e a combinação de teoria sólida com aplicação prática é o caminho para se tornar um especialista.

Na próxima aula, expandiremos nossa visão para múltiplas séries temporais com os Vetores Autoregressivos (VAR).

Consolidação e Próximos Passos

Parabéns! Você concluiu a Aula 15, mergulhando fundo nos modelos ARCH e GARCH. Vimos que a volatilidade é uma medida crucial do risco e que os modelos tradicionais falham em capturar sua dinâmica variável no tempo. Os modelos ARCH e GARCH surgiram como soluções elegantes, permitindo-nos modelar a variância condicional com base em choques passados (ARCH) e na própria volatilidade passada (GARCH), tornando-os ferramentas indispensáveis para a análise de séries financeiras. Exploramos suas aplicações práticas e vislumbramos as tendências futuras, como a hibridização com Machine Learning e o uso de Deep Learning.



Sempre verifique

A heterocedasticidade nos resíduos de seus modelos de média



Considere o GARCH(1,1)

Como seu ponto de partida para modelar a volatilidade



Use a previsão de volatilidade

Para aprimorar suas análises de risco e precificação



Mantenha-se atualizado

Com as tendências de ML e Deep Learning para séries temporais

Autoavaliação

- 1. Qual é a principal limitação dos modelos ARIMA que os modelos ARCH e GARCH buscam resolver?**
 - a) Incapacidade de modelar tendências.
 - b) Dificuldade em lidar com sazonalidade.
 - c) Assunção de variância constante dos resíduos (homocedasticidade).
 - d) Exigência de dados estacionários.
- 2. Um modelo ARCH(q) modela a variância condicional (h_t) como uma função de:**
 - a) Apenas a média dos erros passados.
 - b) Os erros quadrados passados.
 - c) A variância condicional passada.
 - d) Apenas a constante α_0 .
- 3. A principal vantagem do modelo GARCH(p,q) sobre o ARCH(q) é:**
 - a) Sua capacidade de modelar a média da série de forma mais precisa.
 - b) A inclusão de termos de variância condicional passada, tornando-o mais parcimonioso para capturar a persistência da volatilidade.
 - c) Sua simplicidade matemática, que facilita a estimação.
 - d) A eliminação completa da necessidade de dados estacionários.
- 4. Em séries financeiras, a volatilidade é frequentemente associada a qual conceito?**
 - a) Retorno médio.
 - b) Liquidez.
 - c) Risco.
 - d) Volume de negociação.
- 5. Explique brevemente como a hibridização de modelos (por exemplo, ARIMA-GARCH com Machine Learning) pode ser benéfica na previsão de séries temporais.**

Gabarito e Recursos Adicionais

1. c)

Assunção de variância constante dos resíduos

2. b)

Os erros quadrados passados

3. b)

Inclusão de termos de variância condicional passada

4. c)

Risco

Resposta da Questão 5:

A hibridização de modelos pode ser benéfica porque combina as forças de diferentes abordagens. Modelos estatísticos como ARIMA-GARCH são bons para capturar padrões lineares e a dinâmica da volatilidade. Ao combinar com Machine Learning (como LSTMs), que são excelentes em aprender relações não lineares e complexas, é possível capturar uma gama mais ampla de padrões nos dados, resultando em previsões mais precisas e robustas.

Próxima Aula

Aula 16 – Vetores Autoregressivos (VAR) para Múltiplas Séries. Prepare-se para expandir sua análise para o mundo multivariado!

Recursos Adicionais

- **Livros:** "Time Series Analysis" de Hamilton (referência clássica para aprofundamento teórico).
- **Artigos:** Artigos originais de Engle (1982) e Bollerslev (1986) para entender a base.
- **Bibliotecas Python/R:** arch (Python) ou rugarch (R) para implementação prática.

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