


Algoritmos I – Regressão Quantílica

Conceitos, Aplicações e Prática

Seja bem-vindo a esta jornada educativa pelo mundo da Regressão Quantílica! Nesta apresentação, exploraremos conceitos fundamentais, aplicações práticas e técnicas analíticas que vão além da estatística tradicional.

A Regressão Quantílica é uma poderosa ferramenta estatística que nos permite enxergar além da média, revelando como diferentes variáveis se relacionam em diversos pontos da distribuição de dados.



Revolutione! Seja THRIVE!
www.ia-labs.com.br

Objetivos



Compreender os fundamentos

Explorar as bases teóricas da regressão quantílica e seu lugar na análise estatística moderna



Distinguir métodos estatísticos

Comparar a regressão quantílica com a regressão linear tradicional, destacando vantagens e limitações



Aplicar na prática


Desenvolver habilidades para implementar e interpretar modelos de regressão quantílica em problemas reais




Inspirar novas ideias

Estimular o pensamento criativo sobre como utilizar esta técnica em seus próprios estudos e projetos

Traditional
regression



Quantile regression



O que é Regressão Quantílica?

Uma nova perspectiva

A Regressão Quantílica é uma técnica estatística que vai além da média. Enquanto a regressão tradicional foca na média condicional da variável dependente, a regressão quantílica modela diferentes quantis condicionais.

Esta abordagem permite um retrato mais completo da relação entre variáveis, especialmente quando os dados não seguem uma distribuição simétrica ou quando os efeitos variam entre diferentes níveis da distribuição.

Visão ampliada dos dados

Em vez de obter uma única linha de regressão, a regressão quantílica nos dá múltiplas linhas, cada uma representando um quantil específico da distribuição condicional.

Isso significa que podemos examinar como a relação entre variáveis muda conforme nos movemos do topo para o fundo da distribuição, revelando padrões que ficariam ocultos na abordagem tradicional.

Motivação: Por Que Usar?

Captura efeitos heterogêneos

A regressão quantílica permite analisar como uma variável independente afeta diferentes partes da distribuição da variável dependente, revelando efeitos que podem variar significativamente entre os quantis.


Resistência a outliers

Por não focar exclusivamente na média, esta técnica é menos sensível a valores extremos, proporcionando estimativas mais robustas quando os dados contêm observações atípicas.

Ideal para distribuições assimétricas

Quando os dados não seguem uma distribuição normal, a regressão quantílica oferece uma visão mais completa e precisa da relação entre variáveis do que os métodos baseados na média.

Estas características tornam a regressão quantílica uma ferramenta valiosa para estudantes e pesquisadores que buscam compreender fenômenos complexos além da análise convencional.



Origens e Desenvolvimento Histórico



1978: Introdução formal

Roger Koenker e Gilbert Bassett Jr. publicam o artigo "Regression Quantiles" na revista Econometrica, estabelecendo as bases teóricas do método



Anos 1980–90: Expansão

Desenvolvimento de algoritmos eficientes e primeiras aplicações em economia, finanças e ciências sociais



Anos 2000: Aplicação em saúde

Crescimento do uso em biomedicina e epidemiologia para modelar fatores de risco em diferentes níveis de distribuição




Atualidade: Era computacional

Avanços em software e poder computacional democratizaram o acesso à técnica para pesquisadores de diversas áreas



Relembrando Regressão Linear Clássica



A regressão linear clássica é como tentar contar uma história completa olhando apenas para o personagem principal. Ela nos fornece uma visão geral útil, mas deixa de lado muitos detalhes importantes que acontecem nas "margens" da narrativa dos dados.

Limitações da Regressão Linear



Alta sensibilidade a outliers

Um único valor extremo pode influenciar significativamente a reta de regressão, distorcendo a análise para todos os dados



Visão limitada da distribuição

Ao focar apenas na média, perde-se informação sobre o comportamento dos dados em diferentes partes da distribuição




Problemas com assimetria

Em distribuições assimétricas, a média pode não ser representativa da tendência central real dos dados



Dificuldade com heterocedasticidade

Quando a variância dos erros não é constante, as estimativas podem ser ineficientes e os testes de hipótese imprecisos



Conceito de Quantil

Definição básica


Quantis são valores que dividem um conjunto de dados em partes iguais. Eles nos ajudam a entender como os dados estão distribuídos ao longo de todo o espectro de valores, não apenas no centro.

Por exemplo, a mediana (50º percentil) divide os dados exatamente ao meio, com metade dos valores abaixo e metade acima dela.

Principais referências

- Quartis: dividem os dados em quatro partes iguais (25%, 50%, 75%)
- Decis: dividem em dez partes iguais (10%, 20%, ..., 90%)
- Percentis: dividem em cem partes iguais (1%, 2%, ..., 99%)

Os quantis nos permitem analisar desde comportamentos extremos até os mais típicos em um conjunto de dados.



Diferença Entre Média e Quantil



Média

- Representa o centro de massa da distribuição
- Altamente influenciável por valores extremos
- Oferece apenas uma medida de tendência central



Quantis

- Dividem a distribuição em partes iguais
- Menos sensíveis a outliers (especialmente a mediana)
- Fornecem uma visão mais completa da distribuição



Na prática

Em distribuições simétricas, média e mediana (quantil 0,5) coincidem. Em distribuições assimétricas, eles divergem, e os quantis oferecem uma descrição mais informativa.

Principais Quantis: Quartis, Decis, Percentis

Quartis

Dividem os dados em quatro partes iguais:

- Q1 (25%): primeiro quartil
- Q2 (50%): segundo quartil ou mediana
- Q3 (75%): terceiro quartil

A diferença entre Q3 e Q1 é conhecida como amplitude interquartil (IQR).

Decis

Dividem os dados em dez partes iguais (10%, 20%, ..., 90%).


Úteis para análises mais detalhadas que os quartis, como distribuição de renda ou desempenho escolar por categorias.

Percentis

Dividem os dados em cem partes iguais (1%, 2%, ..., 99%).

Comuns em análises de crescimento infantil, testes padronizados e outros contextos onde precisamos de comparações muito granulares.

QUARTILES



PERCENTILE

Definição Formal da Regressão Quantílica

$f(x)$

Definição matemática

$$Q_Y(\tau|X) = X'\beta_\tau$$



Interpretação

O quantil τ de Y dado X é uma função linear de X



Objetivo

Estimar β_τ para diferentes valores de τ entre 0 e 1

Na regressão quantílica, estimamos uma função que nos dá o valor do τ -ésimo quantil da variável dependente Y para cada valor da variável independente X . Diferentemente da regressão linear clássica, podemos estimar múltiplos quantis, obtendo uma compreensão mais rica das relações entre as variáveis.

Esta abordagem nos permite explorar como os fatores preditores afetam não apenas o comportamento médio, mas também os extremos e pontos intermediários da distribuição da variável resposta.

Interpretação dos Parâmetros

Coeficiente β_τ

Representa a mudança no τ -ésimo quantil de Y associada a uma mudança unitária em X

Insights específicos

Permite identificar variáveis que afetam mais os valores extremos ou medianos de Y



Variação entre quantis

Os coeficientes podem variar entre diferentes valores de τ , revelando efeitos heterogêneos

Análise comparativa

Comparar β_τ entre quantis revela onde o efeito de X é mais forte ou mais fraco

Função de Perda Assimétrica

Conceito fundamental

A regressão quantílica utiliza uma função de perda assimétrica chamada "check function" (ρ_τ), que penaliza os resíduos positivos e negativos de forma diferente, dependendo do quantil τ que estamos estimando.

Para o quantil τ , resíduos negativos são multiplicados por $(\tau-1)$, enquanto resíduos positivos são multiplicados por τ .

Consequências práticas

Para a mediana ($\tau=0,5$), a função penaliza igualmente resíduos positivos e negativos, resultando na minimização da soma dos desvios absolutos.

Para $\tau=0,25$, resíduos negativos recebem penalidade maior, resultando em uma linha que deixa aproximadamente 25% dos pontos abaixo dela e 75% acima.

Essa ponderação assimétrica é o segredo da regressão quantílica!

Programação Linear na Estimação

Reformulação do problema

O problema de minimização da função de perda assimétrica pode ser reformulado como um problema de programação linear, permitindo o uso de algoritmos eficientes.

Algoritmos de solução


Métodos como o simplex e pontos interiores são utilizados para encontrar os coeficientes ótimos para cada quantil de interesse, mesmo em grandes conjuntos de dados.

Implementação eficiente

A formulação como programação linear permite aplicar a regressão quantílica a grandes volumes de dados, tornando a técnica viável para aplicações modernas de análise de dados.

A transformação do problema de estimação em um problema de programação linear foi um avanço fundamental que tornou a regressão quantílica computacionalmente tratável, permitindo sua ampla aplicação em diversos campos científicos.

Simplex Method



O Modelo Matemático


$$\text{Min } \sum ((U_i))$$



O modelo matemático da regressão quantílica busca encontrar os parâmetros β que minimizam a soma ponderada dos resíduos. A expressão matemática central é:

$$\min_{\beta} \sum \rho_{\tau}(y_i - x_i^T \beta)$$

Onde ρ_{τ} é a função "check", definida como $\rho_{\tau}(u) = u(\tau - I(u < 0))$. Esta função atribui pesos assimétricos aos resíduos, dependendo do quantil τ que estamos estimando.

Exemplo numérico simples

25%

Quantil inferior

Regressão para o primeiro quartil

50%

Mediana

Regressão para o valor central

75%

Quantil superior


Regressão para o terceiro quartil

Considere um conjunto simples de dados: pares de valores (X,Y) onde X representa anos de estudo e Y representa salário mensal. Ao ajustar regressões para diferentes quantis, observamos que o retorno da educação (coeficiente angular) é maior nos quantis superiores da distribuição salarial.

Isso significa que um ano adicional de estudo tem impacto mais significativo para quem já está no topo da distribuição salarial do que para quem está na base, revelando uma dinâmica que ficaria oculta na regressão tradicional.



Comparação Visual: Linear vs Quantílica



O gráfico acima ilustra a principal diferença visual entre a regressão linear tradicional e a regressão quantílica. Enquanto a regressão OLS (mínimos quadrados ordinários) produz uma única linha representando a média condicional, a regressão quantílica gera múltiplas linhas para diferentes quantis.

Observe como as linhas para os quantis 0,25, 0,50 (mediana) e 0,75 capturam diferentes aspectos da relação entre X e Y, revelando uma história mais completa sobre como as variáveis interagem em diferentes partes da distribuição.

Quando Optar pela Regressão Quantílica?



Assimetria nos dados

Quando a distribuição condicional da variável dependente é assimétrica, a regressão quantílica oferece uma descrição mais precisa do que métodos baseados na média.



Presença de outliers

Se os dados contêm valores extremos ou atípicos que não devem ser removidos, a robustez da regressão quantílica é vantajosa.




Heterocedasticidade

Quando a variância dos erros não é constante, violando pressupostos da regressão tradicional, a regressão quantílica é uma alternativa sólida.




Interesse específico

Quando o foco está em partes específicas da distribuição (como valores extremos ou medianos) e não apenas na média.



Vantagens da Regressão Quantílica



Robustez a outliers

A regressão quantílica, especialmente a mediana ($\tau=0,5$), é muito menos afetada por valores extremos do que a regressão baseada na média.

Isso significa que você pode manter todas as suas observações na análise sem precisar remover pontos influentes.

Flexibilidade de modelagem

Ao estimar diferentes quantis, você captura uma visão mais completa da relação entre variáveis, identificando efeitos que podem variar ao longo da distribuição.

Esta flexibilidade permite descobrir padrões mais complexos nos dados.

Análise abrangente

Enquanto a regressão tradicional oferece apenas um "resumo" da relação entre variáveis, a regressão quantílica permite uma investigação detalhada de toda a distribuição condicional.

Você pode descobrir fatores que afetam mais fortemente determinados grupos específicos.

Limitações e Desvantagens



Interpretação mais complexa

A análise de múltiplos quantis exige maior cuidado na interpretação, pois os coeficientes podem variar significativamente entre quantis.



Demanda computacional

Os algoritmos de otimização para regressão quantílica são geralmente mais exigentes computacionalmente do que os mínimos quadrados ordinários.



Escassez de dados em quantis extremos

A estimação de quantis muito altos ou muito baixos pode ser imprecisa quando o tamanho da amostra é limitado.




Menor familiaridade

Por ser menos conhecida que a regressão linear tradicional, pode haver resistência à sua adoção ou dificuldade em comunicar resultados.



Estimação para Diversos Quantis



Na regressão quantílica, podemos estimar modelos para diversos quantis simultaneamente, construindo um panorama completo da relação entre as variáveis. Cada quantil é estimado separadamente, resultando em um conjunto de coeficientes próprios.

Observe no gráfico como as inclinações das retas variam entre os quantis 0,10, 0,50 e 0,90. Isso indica que o efeito da variável X sobre Y é mais forte nos quantis superiores da distribuição, um insight valioso que a regressão tradicional não captaria.

Interpretação do Coeficiente para o Quantil τ

Conceito fundamental

O coeficiente β_τ para uma variável X representa o impacto marginal de uma mudança unitária em X sobre o τ -ésimo quantil de Y , mantendo todas as outras variáveis constantes.

Em outras palavras, β_τ nos diz como o quantil específico de Y muda quando X aumenta em uma unidade.


Exemplo prático

Considere um modelo de salários onde X representa anos de educação:

- Se $\beta_{0.10} = 200$, então um ano adicional de educação está associado a um aumento de R\$200 no 10º percentil da distribuição salarial
- Se $\beta_{0.90} = 500$, então um ano adicional de educação está associado a um aumento de R\$500 no 90º percentil da distribuição salarial

A diferença entre esses coeficientes sugere que o retorno da educação é maior no topo da distribuição salarial.

Intervalos de Confiança e Inferência



Como a distribuição assintótica dos estimadores de regressão quantílica é complexa, o método bootstrap é frequentemente utilizado para obter erros padrão e intervalos de confiança. Esta abordagem não paramétrica é robusta e fornece resultados confiáveis mesmo quando as premissas tradicionais não são atendidas.

Testes de Hipóteses em Regressão Quantílica

Testes para coeficientes individuais

Podemos testar se um determinado coeficiente β_{τ} é estatisticamente diferente de zero, usando estatísticas t baseadas em erros padrão bootstrap.

$$H_0: \beta_{\tau} = 0 \text{ vs } H_1: \beta_{\tau} \neq 0$$

Testes de igualdade entre quantis

Podemos verificar se o efeito de uma variável é o mesmo em diferentes quantis, testando a hipótese:

$$H_0: \beta_{\tau 1} = \beta_{\tau 2} \text{ vs } H_1: \beta_{\tau 1} \neq \beta_{\tau 2}$$


Testes conjuntos

Podemos avaliar se um grupo de variáveis tem efeito significativo em um determinado quantil, usando estatísticas F ou testes de Wald:

$$H_0: \beta_{1_{\tau}} = \beta_{2_{\tau}} = \dots = \beta_{k_{\tau}} = 0$$

Estes testes nos permitem fazer inferências rigorosas sobre os resultados da regressão quantílica, validando nossas descobertas e construindo argumentos estatisticamente sólidos.

Residual Analysis



Diagnóstico e Verificação dos Ajustes

Gráficos de resíduos quantílicos

Verificam se os resíduos estão corretamente distribuídos para cada quantil estimado. Para um modelo bem ajustado, aproximadamente $\tau\%$ dos resíduos devem ser negativos para o quantil τ .

Análise de pontos de alavancagem

Identifica observações que exercem influência desproporcional sobre as estimativas. Embora a regressão quantílica seja mais robusta, pontos de alta alavancagem ainda merecem atenção.


Gráficos de quantis ajustados vs observados

Comparam os quantis condicionais estimados pelo modelo com os valores observados nos dados, permitindo visualizar a qualidade do ajuste em diferentes partes da distribuição.

Testes de especificação do modelo

Avaliam se a forma funcional do modelo é adequada para os dados, verificando linearidade, possíveis termos omitidos ou transformações necessárias.

Softwares e Ferramentas



A regressão quantílica está disponível em diversos pacotes estatísticos populares. O pacote **quantreg** em R, desenvolvido por Roger Koenker, é uma das implementações mais completas e populares. No Python, o módulo **statsmodels** oferece funções para regressão quantílica, enquanto no Stata o comando **qreg** é amplamente utilizado.

Estas ferramentas facilitam não apenas a estimação dos modelos, mas também a visualização de resultados, diagnósticos e testes de hipóteses, tornando a regressão quantílica acessível mesmo para usuários com conhecimento estatístico intermediário.

Exemplo em R: Ajustando e Interpretando

0.25

Primeiro quartil

Foco na parte inferior da distribuição

0.50

Mediana

Análise do comportamento central

0.75

Terceiro quartil

Foco na parte superior da distribuição

Um exemplo básico de código em R para ajustar regressão quantílica:

```
# Carregar o pacote  
library(quantreg)
```

```
# Ajustar regressão para os quantis 0.25, 0.50 e 0.75
```


```
modelo_q25 <- rq(salario ~ educacao + experiencia, tau = 0.25, data = dados)
```

```
modelo_q50 <- rq(salario ~ educacao + experiencia, tau = 0.50, data = dados)
```




```
modelo_q75 <- rq(salario ~ educacao + experiencia, tau = 0.75, data = dados)
```

```
# Resumo dos resultados para a mediana
```

```
summary(modelo_q50)
```



Visualizando Resultados em R



O pacote **quantreg** em R oferece funções poderosas para visualizar os resultados da regressão quantílica. O código a seguir cria um gráfico com múltiplas linhas de quantis sobrepostas aos dados observados:

```
# Ajustar regressão para múltiplos quantis
modelo_multi <- rq(y ~ x, tau = seq(0.1, 0.9, by = 0.1), data = dados)

# Plotar os resultados
plot(y ~ x, data = dados, pch = 19, col = "gray")
for (i in 1:9) {
  abline(coef(modelo_multi)[,i], col = i)
}

# Adicionar a linha OLS para comparação
abline(lm(y ~ x, data = dados), col = "red", lwd = 2)
legend("topleft", c("OLS", paste0("Q", seq(0.1, 0.9, by = 0.1))),
      lwd = c(2, rep(1, 9)), col = c("red", 1:9))
```

Exemplo Aplicado: Salários no Mercado de Trabalho



Educação básica

Impacto moderado em todos os quantis salariais



Graduação

Efeito maior nos quantis intermediários




Pós-graduação

Efeito amplificado nos quantis superiores

Em um estudo utilizando dados da PNAD/IBGE, pesquisadores aplicaram regressão quantílica para investigar como a escolaridade afeta diferentes níveis salariais no Brasil. Os resultados revelaram um padrão interessante: o retorno da educação (aumento percentual do salário por ano adicional de estudo) é significativamente maior nos quantis superiores da distribuição salarial.

Para trabalhadores no 10º percentil, um ano adicional de educação aumenta o salário em aproximadamente 5%, enquanto para aqueles no 90º percentil, o aumento chega a 12%. Isso indica que a educação tem um efeito mais forte para quem já está no topo da distribuição salarial, contribuindo para a desigualdade no mercado de trabalho.

Exemplo Aplicado: Mensuração Florestal



Na área florestal, pesquisadores da UFPR aplicaram regressão quantílica para modelar o volume de árvores em função do diâmetro à altura do peito (DAP) e altura total. A técnica permitiu estimar não apenas o volume médio esperado, mas também diferentes quantis do volume para cada combinação de características.


Esta abordagem é particularmente útil no manejo florestal, onde o interesse pode estar tanto na produção mínima garantida (quantis inferiores) quanto no potencial máximo de produção (quantis superiores). A regressão quantílica fornece estimativas mais precisas para decisões de manejo em diferentes cenários.

Exemplo Aplicado: Saúde Pública




Pressão arterial em idosos

A regressão quantílica permite identificar fatores de risco específicos para hipertensão severa (quantis superiores), que podem diferir dos fatores associados a níveis moderados.



Distribuição de IMC

Estudos usando regressão quantílica demonstram como fatores socioeconômicos afetam diferentemente a obesidade severa (quantis superiores) versus o sobrepeso moderado.



Crescimento infantil

As curvas de crescimento infantil são essencialmente quantis condicionais, permitindo avaliar se o desenvolvimento está dentro dos padrões esperados para cada idade.

Aplicação em Economia

Análise de consumo e renda

Economistas da FGV utilizaram regressão quantílica para analisar como a propensão marginal a consumir varia ao longo da distribuição de renda. Os resultados revelaram que famílias nos quantis inferiores de renda tendem a gastar uma proporção maior de cada real adicional em consumo básico.


Para o percentil 10 de renda, a propensão marginal a consumir é de aproximadamente 0,85 (85 centavos de cada real adicional são gastos), enquanto para o percentil 90, esse valor cai para 0,55.

Impacto de políticas fiscais

A regressão quantílica também é usada para avaliar o impacto de políticas fiscais em diferentes estratos econômicos. Um estudo da UFRJ sobre o impacto de transferências de renda mostrou que programas sociais têm efeito multiplicador maior nos quantis inferiores.

Esta abordagem permite desenhar políticas públicas mais efetivas e direcionadas, considerando seus efeitos heterogêneos em diferentes grupos socioeconômicos.

Income Distribution Analysis



Aplicação em Finanças



Value-at-Risk (VaR)

Estimativa de perdas potenciais em diferentes níveis de confiança

2

Análise de volatilidade

Modelagem de como a volatilidade responde a diferentes fatores de mercado




Precificação de ativos

Captura de prêmios de risco variáveis em diferentes condições de mercado

No mercado financeiro, o Value-at-Risk (VaR) é uma medida crucial de risco que corresponde exatamente a um quantil da distribuição de retornos. A regressão quantílica permite modelar diretamente o VaR condicional, levando em conta fatores de mercado, volatilidade histórica e outras variáveis explicativas.

Esta abordagem tem se mostrado mais precisa do que métodos tradicionais, especialmente em períodos de turbulência econômica, quando as relações entre variáveis financeiras mudam drasticamente nos quantis extremos da distribuição.

Aplicação em Ciências Ambientais



Nas ciências ambientais, a regressão quantílica tem sido fundamental para modelar eventos extremos, como chuvas intensas, ondas de calor e enchentes. Pesquisadores da UFRJ utilizaram a técnica para analisar como fatores climáticos globais influenciam diferentes quantis da distribuição de precipitação no Brasil.

Ao modelar diretamente os quantis superiores (Q90, Q95, Q99), os cientistas conseguem fazer previsões mais precisas sobre eventos extremos, que são particularmente importantes para planejamento urbano, agricultura e prevenção de desastres. Esta abordagem é especialmente valiosa no contexto das mudanças climáticas, onde os eventos extremos podem se tornar mais frequentes e intensos.

Avanços Recentes na Regressão Quantílica

Modelos não-lineares

Desenvolvimentos recentes permitem a aplicação de regressão quantílica em estruturas não-lineares, usando splines, polinômios ou funções kernel para capturar relações complexas em diferentes quantis.

Estas técnicas expandem significativamente o poder de modelagem, especialmente para fenômenos que não seguem padrões lineares simples.

Séries temporais

A regressão quantílica para séries temporais permite modelar como diferentes quantis de uma variável evoluem ao longo do tempo, capturando mudanças em tendências, sazonalidade e volatilidade.

Esta abordagem é particularmente útil para previsão financeira, análise de demanda energética e estudos climatológicos.

Métodos bayesianos

Abordagens bayesianas para regressão quantílica incorporam conhecimento prévio através de distribuições a priori e fornecem distribuições posteriores completas para os parâmetros.

Isso permite uma quantificação mais rica da incerteza e facilita a incorporação de estruturas hierárquicas ou espaciais nos modelos.

Regressão Quantílica com Dados em Paineis



Heterogeneidade individual

A regressão quantílica em painéis permite controlar características não observáveis dos indivíduos, mantendo a capacidade de modelar diferentes quantis da distribuição condicional.

A combinação de regressão quantílica com metodologias de dados em painel representa um avanço significativo, permitindo analisar como as relações entre variáveis mudam não apenas ao longo da distribuição condicional, mas também entre indivíduos e ao longo do tempo.

Esta abordagem é particularmente valiosa em estudos longitudinais de educação, saúde e desenvolvimento econômico, onde tanto a heterogeneidade individual quanto os efeitos diferenciados nos extremos da distribuição são de interesse.



Dinâmica temporal


Modelos podem incorporar defasagens e tendências temporais, capturando como os efeitos evoluem ao longo do tempo em diferentes partes da distribuição.



Dados estruturados

Técnicas especiais lidam com estruturas hierárquicas ou agrupadas, como estudantes dentro de escolas ou pacientes dentro de hospitais.





Modelos Quantílicos Generalizados



Dados de contagem

Extensões da regressão quantílica para variáveis discretas, como número de ocorrências ou eventos, adaptando a abordagem para distribuições como Poisson ou Binomial Negativa.



Dados proporcionais

Modelos para dados limitados ao intervalo $[0,1]$, como taxas, proporções ou probabilidades, que requerem tratamento especial para respeitar estes limites.



Dados de sobrevivência

Abordagens quantílicas para análise de tempo até o evento, permitindo modelar diferentes percentis da distribuição de sobrevivência condicionada a covariáveis.



Estruturas complexas

Modelos para dados com estruturas de dependência complexas, como dados espaciais, redes ou séries temporais multivariadas.

Quantile Regression Forests

Combinação com aprendizado de máquina

Quantile Regression Forests (QRF) combinam regressão quantílica com random forests, aproveitando o poder dos métodos de ensemble para modelagem não paramétrica de quantis condicionais.

A combinação de regressão quantílica com métodos de aprendizado de máquina representa uma fronteira promissora, especialmente para conjuntos de dados grandes e complexos. Estas técnicas exigem menos premissas sobre a forma funcional do modelo e frequentemente superam métodos paramétricos tradicionais em termos de precisão preditiva.


Funcionamento básico

Em vez de prever apenas a média nos nós terminais das árvores, o QRF armazena a distribuição empírica completa, permitindo estimar qualquer quantil da distribuição condicional.

Vantagens práticas


Esta abordagem captura automaticamente interações complexas e não linearidades nos dados, sem exigir especificação prévia da forma funcional ou transformações das variáveis.

Diagnóstico Avançado, Resíduos Quantílicos




Gráficos Q-Q de resíduos

Comparamos os quantis teóricos esperados com os quantis empíricos dos resíduos para verificar se o modelo está capturando corretamente a distribuição condicional em todos os níveis.



Worm plots




Uma variação dos gráficos Q-Q que ajuda a identificar regiões específicas onde o modelo não está se ajustando bem, especialmente útil para diagnóstico de modelos quantílicos.



Análise de densidade dos resíduos

Examinamos a distribuição dos resíduos para cada quantil estimado, verificando se aproximadamente $\tau\%$ dos resíduos são negativos para o quantil τ .

Visualização Avançada: Fan Plots



Os Fan Plots (gráficos em leque) são uma técnica avançada de visualização que representa múltiplos quantis condicionais simultaneamente, permitindo uma visualização completa da distribuição condicional da variável resposta.

Esta técnica utiliza gradientes de cor para representar a densidade de probabilidade entre quantis adjacentes, criando uma representação intuitiva de como a distribuição condicional muda em função das variáveis explicativas. É particularmente útil para identificar mudanças na forma da distribuição, como aumento da dispersão ou assimetria em determinadas regiões do espaço das covariáveis.

Interpretação Prática em Relatórios

Comunicação clara

Ao apresentar resultados de regressão quantílica para públicos não técnicos, comece explicando o conceito de quantis de forma intuitiva, relacionando-os a ideias familiares como "abaixo da média", "típico" e "acima da média".

Use analogias concretas, como a distribuição de alturas em uma sala de aula, onde algumas pessoas são mais baixas (quantis inferiores), outras têm altura mediana, e outras são mais altas (quantis superiores).

Visualizações efetivas

Crie gráficos claros que contraponham a abordagem da média (uma única linha) com a abordagem de quantis (múltiplas linhas), ilustrando visualmente a riqueza adicional de informação.

Use cores consistentes para cada quantil ao longo do relatório e adicione linhas de referência para facilitar a interpretação. Gráficos interativos, quando possível, permitem que os leitores explorem diferentes quantis conforme seu interesse.

Desafios de Aplicação: Tamanho de Amostra



A estimação de quantis extremos (muito baixos como 0,01 ou muito altos como 0,99) exige amostras substancialmente maiores do que a estimação de quantis centrais como a mediana. Isso ocorre porque há naturalmente menos observações nas caudas da distribuição, tornando as estimativas mais suscetíveis à variabilidade amostral.

Uma regra prática é que para estimar com precisão o quantil τ (ou $1-\tau$ para $\tau < 0,5$), você precisa de aproximadamente $1/(2\tau)$ observações por parâmetro no modelo. Por exemplo, para estimar o quantil 0,01 em um modelo com 5 parâmetros, seria recomendável ter pelo menos $5 \times 1/(2 \times 0,01) = 250$ observações.



Considerações Éticas no Uso de Modelos



Equidade e justiça

Na aplicação de regressão quantílica em políticas públicas, é fundamental considerar como os resultados podem afetar diferentes grupos populacionais, evitando perpetuar ou amplificar desigualdades existentes.



Transparência

Os pressupostos, limitações e incertezas dos modelos devem ser claramente comunicados, permitindo que os usuários finais compreendam o contexto e as ressalvas das análises.



Privacidade

A modelagem de quantis extremos pode revelar características de indivíduos específicos em amostras pequenas, exigindo cuidados adicionais com a confidencialidade dos dados.

Regressão Quantílica vs Outras Técnicas Robustas


Regressão Quantílica

- Modela múltiplos quantis da distribuição condicional
- Não assume forma particular para a distribuição dos erros
- Permite efeitos heterogêneos das covariáveis
- Adequada quando o interesse está em partes específicas da distribuição


Regressão Robusta por M-estimadores

- Foca em estimar a tendência central de forma robusta
- Utiliza funções de perda que reduzem a influência de outliers
- Mantém o foco na média (modificada) condicional
- Ideal quando o interesse é na relação "típica" entre variáveis

Embora ambas as abordagens ofereçam robustez contra valores atípicos, elas têm objetivos diferentes. A regressão robusta tradicional busca estimar a tendência central de forma menos sensível a outliers, enquanto a regressão quantílica modela diferentes partes da distribuição condicional, oferecendo uma visão mais completa da relação entre variáveis.



Quantile Regression vs Robust Regression



Boas Práticas de Modelagem

1 Escolha estratégica dos quantis

Selecione quantis relevantes para seus objetivos específicos. Para uma visão geral, considere quartis (0,25, 0,50, 0,75) ou decis importantes (0,10, 0,50, 0,90).



Análise exploratória prévia

Examine graficamente os dados para identificar padrões que sugiram onde a regressão quantílica pode ser mais informativa que a regressão tradicional.




Verificação de robustez

Teste diferentes especificações do modelo e compare os resultados entre quantis para garantir que os padrões observados são estáveis.




Visualização informativa

Apresente os resultados de forma visual, mostrando como os coeficientes variam entre quantis ou como as linhas de regressão se diferenciam ao longo da distribuição.



Linhas Finais: O Que Levar da Regressão Quantílica?



A regressão quantílica representa uma expansão fundamental em nossa caixa de ferramentas estatísticas, permitindo que analisemos os dados com maior profundidade e precisão. Ela nos lembra que o mundo real raramente pode ser capturado por uma única medida central e que diferentes partes da distribuição muitas vezes contam histórias distintas e valiosas.



Referências Bibliográficas (1/2)

Artigo Fundacional

KOENKER, R.; BASSETT, G. (1978). Regression Quantiles. *Econometrica*, vol. 46, n. 1, p. 33-50.



Publicação Profissional

RAMOS, José. Desvendando a Regressão Quantílica: Aplicações práticas e interpretação de resultados. LinkedIn, 2024.

Estudo Aplicado

MENSURAÇÃO FLORESTAL. Regressão Quantílica na Estimativa de Volume de Árvores. UFPR, 2020.



Material Didático

UNICAMP. Regressão Quantílica: Teoria e Aplicações. Material Didático da Disciplina Ce731, Instituto de Matemática, Estatística e Computação Científica, 2023.

Referências Bibliográficas (2/2)



Tese Acadêmica

USP. Modelos de regressão quantílica para análise de dados longitudinais. Tese de Doutorado em Estatística, Instituto de Matemática e Estatística, Universidade de São Paulo, 2012.



Conteúdo Digital

ESTATÍSTICA FÁCIL. O que é: Regressão Quantílica - Uma abordagem intuitiva para iniciantes. Canal do YouTube, 2023.



Recurso Internacional

KOENKER, R. Quantile Regression. Cambridge University Press, 2005.



Pacote Estatístico

KOENKER, R. quantreg: Quantile Regression. R package version 5.94, 2022. Disponível em: <https://CRAN.R-project.org/package=quantreg>



Referências complementares

Além das referências listadas acima, recomenda-se consultar os repositórios digitais das principais universidades brasileiras que mantêm acervos atualizados de teses, dissertações e artigos sobre IA:

- Biblioteca Digital de Teses e Dissertações da USP (www.teses.usp.br)
- Repositório Institucional da UFMG (repositorio.ufmg.br)
- Repositório Digital da Unicamp (repositorio.unicamp.br)
- Repositório Digital da UNIFESP (repositorio.unifesp.br)
- Biblioteca Digital da UFPE (repositorio.ufpe.br)
- Lume - Repositório Digital da UFRGS (lume.ufrgs.br)
- Repositório Institucional da FGV (bibliotecadigital.fgv.br)
- Biblioteca Digital de Monografias da UFABC (biblioteca.ufabc.edu.br)

Para acompanhar os avanços mais recentes na pesquisa brasileira, recomenda-se também os anais das conferências BRACIS, SBIA, ENIAC e workshops especializados organizados pela Sociedade Brasileira de Computação (SBC).