



Universidade Federal do Rio Grande do Sul
Instituto de Matemática e Estatística
Programa de Pós-Graduação em Estatística

Regressão Modal: estimação consistente via regressão quantílica suavizada

Eduardo Schirmer Finn

Porto Alegre, Maio de 2024.

CIP - Catalogação na Publicação

Finn, Eduardo Schirmer
Regressão Modal: estimação consistente via
regressão quantílica suavizada / Eduardo Schirmer
Finn. -- 2024.
48 f.
Orientador: Eduardo Horta.

Dissertação (Mestrado) -- Universidade Federal do
Rio Grande do Sul, Instituto de Matemática e
Estatística, Programa de Pós-Graduação em Estatística,
Porto Alegre, BR-RS, 2024.

1. Regressão Modal. 2. Suavização por Convolução.
3. Quantil Condicional. 4. Teoria Assintótica. 5.
Convergência Uniforme. I. Horta, Eduardo, orient. II.
Título.

Dissertação submetida por Eduardo Schirmer Finn como requisito parcial para a obtenção do título de Mestre em Estatística pelo Programa de Pós-Graduação em Estatística da Universidade Federal do Rio Grande do Sul.

Orientador(a):

Prof. Dr. Eduardo de Oliveira Horta

Comissão Examinadora:

Prof. Dr. Cleiton Guollo Taufemback (PPGEst - UFRGS)

Prof. Dr. Marcelo Fernandes (EESP - FGV)

Prof. Dr. Paolo Santucci de Magistris (DEF - LUISS)

Data de Apresentação: 21 de maio de 2024

*“Truth is much too complicated to allow anything but approximations”
(John von Neumann)*

AGRADECIMENTOS

Aos meus pais, pelo amor e apoio incondicional ao longo da minha trajetória e por terem me mostrado desde cedo a importância da educação.

À minha parceira de vida Natália, pelo amor, acolhimento e principalmente, paciência.

Ao meu orientador e xará, Eduardo Horta, pela orientação, ensinamentos, parceria, mentoria e incentivos.

Aos demais membros do PPGEst, pelos aprendizados e por sua dedicação ao programa.

Aos membros da banca, pelo tempo dedicado à leitura do meu trabalho.

Aos meus colegas de turma, principalmente, Robson e Bernardo, por toda ajuda concedida ao longo das matérias cursadas.

À Rita pelos cafés, lanches e, principalmente, por ter sido minha segunda mãe.

À Doli por me obrigar a interromper longos períodos no computador para dar uma curta caminhada.

A meu caro amigo Marcelo pelas primeiras aulas de derivadas que tive ao início da graduação.

Ao grande amigo e professor de matemática, Gustavo.

Aos demais, que de alguma maneira me ajudaram nesta trajetória de mestrado.

RESUMO

Em cenários de distribuições altamente assimétricas ou de caudas pesadas, métodos baseados na média, ou na mediana, podem não conseguir capturar as tendências centrais dos dados. Esta deficiência dos métodos tradicionais fomentou o surgimento de modelos de moda condicional como uma alternativa válida. Entretanto, a estimação da moda condicional de uma variável dado suas covariadas apresenta alguns desafios: abordagens não paramétricas estão passivas a baixas taxas de convergência e à “maldição da dimensionalidade”, enquanto estratégias semi-paramétricas (modelos lineares) podem levar a problemas de otimização não convexos. Propõe-se um novo tipo de estimador de regressão modal, construído pela inversão da densidade quantílica condicional. Contrapondo com outras abordagens na literatura, estima-se a função de densidade quantílica invertendo uma variante convolucional suavizada do modelo de regressão quantílica. O estimador resultando é consistente, além do benefício de possuir convergência uniforme com relação aos pontos das covariadas e à largura da banda.

Palavras-chave: *Regressão Modal; Suavização por Convolução; Quantil Condicional; Teoria Assintótica; Convergência Uniforme.*

ABSTRACT

For highly skewed or fat-tailed distributions, mean or median-based methods may be inadequate to capture centrality in the data. This deficiency of traditional methods has fostered the emergence of conditional mode models as a valuable approach. However, estimating the conditional mode of a variable given certain covariates presents challenges: nonparametric approaches suffer from the “curse of dimensionality”, while the semiparametric strategy can lead to non-convex optimization problems. We propose a novel estimator for mode regression, constructed by inverting the conditional quantile density. Unlike existing approaches in the literature, we estimate the quantile density function by inverting a convolution-type smoothed variant of the quantile regression model. Our resulting estimator is consistent, with the benefit of having uniform convergence with respect to both the design points of the covariates and to the bandwidth.

Keywords: *Mode Regression; Convolution-based Smoothing; Conditional Quantile; Asymptotic Theory; Uniform Convergence.*

ÍNDICE

1	Introdução	2
2	Revisão de Literatura	5
2.1	Moda Global e Estimação Semi-paramétrica	6
2.2	Moda Global e Estimação Não Paramétrica	6
2.3	Moda Local e Estimação Não Paramétrica	6
2.4	Abordagem por Regressão Quantílica	7
3	Regressão Modal via Convolução	8
3.1	Contexto	8
3.2	Estimação	10
4	Principais Resultados	11
5	Conclusões e trabalhos futuros	12
	Apêndices	14
A	Artigo Finn e Horta	15

CAPÍTULO 1

INTRODUÇÃO

Métodos econométricos convencionais costumam basear-se na média (ou na mediana); tais métodos podem falhar ao expressar as tendências centrais se a distribuição é assimétrica ou possui cauda longa (Kemp and Santos-Silva, 2012; Chen et al., 2016). Assim, a moda condicional surge como uma alternativa robusta, não obstante, possuindo a desejável interpretação como o valor mais provável de um conjunto de dados (Chacón, 2020). Essa interpretação torna-se especialmente valiosa ao lidar com variáveis contínuas, as quais, ao contrário de variáveis aleatórias discretas, não possuem uma versão da moda amostral direta. Nestes casos, a moda é formalmente definida como o valor que maximiza a função de densidade condicional. Desde o trabalho de Lee (1989), a estimativa da moda condicional, denominada de regressão modal, demonstrou sua utilidade em diversos domínios, especialmente em aplicações com dados assimétricos, como salários e preços (Kemp and Santos-Silva, 2012); consumo de energia elétrica (Ota, Kato and Hara, 2019); remunerações no mercado de trabalho (Zhang, Kato and Ruppert, 2023); variáveis dependentes truncadas (Lee, 1989); aprendizado de máquina (Feng et al., 2020); medicina (Wang et al., 2017), dados de trânsito (Einbeck and Tutz, 2006), tempo de erupções termais (Matzner-Løfber et al., 1998) e dados de incêndios florestais (Yao and Li, 2014).

Ao explorar o estado da literatura sobre moda condicional, a discussão direciona-se para dois pontos fundamentais: a suposição de se a moda é única (global) ou não (local), e a estratégia de estimação empregada — semi-paramétrica (linear) ou não paramétrica. Abordagens lineares requerem a condição de que a moda seja um maximizador único da densidade condicional; já técnicas não paramétricas, por sua vez, são geralmente usadas para modelos multimodais, (mas não exclusivamente); por fim, em alguns casos a moda global também é estimada não parametricamente (Sager and Thisted, 1982; Feng et al., 2020). O primeiro estimador semi-paramétrico considerando uma moda global foi desenvolvido por Lee (1989) e estabelece uma relação linear entre a moda da variável de interesse e as covariadas; no entanto, apesar da elegância, este modelo é impraticável.¹ Modelos subsequentes, como os de Kemp and Santos-Silva (2012) e Yao and Li (2014), resultam em problemas de otimização não convexos, gerando funções que podem ter múltiplos máximos; além disso, os algoritmos desenvolvidos são sensíveis aos pontos iniciais. Já a estimação não paramétrica tende a evitar problemas de especificação incorreta (Yao et al., 2012; Chen et al., 2016); no entanto, esses métodos sofrem da "maldição da dimensionalidade" com taxas de convergência excessivamente lentas (Zhang, Kato and Ruppert, 2023). Neste cenário, duas metodologias relacionadas foram desenvolvidas por Ota, Kato and Hara (2019) e Zhang, Kato and Ruppert (2023); ambos formularam modelos de moda condicional que dependem

¹Segundo Kemp and Santos-Silva (2012), este modelo possui suposições restritivas sobre a densidade condicional da resposta e, devido à função objetivo, o estimador carece de uma distribuição tratável.

da estimação da densidade quantílica condicional ao inverter um modelo de regressão quantílica. Tais modelos apresentam boas taxas de convergências assintótica, não dependem dimensionalidade e superam problemas de otimização.

Análogo ao que é feito em [Ota, Kato and Hara \(2019\)](#) e [Zhang, Kato and Ruppert \(2023\)](#), propõe-se uma abordagem nova que se baseia em trabalhar com outro estimador de regressão quantílica, a versão suavizada de [Fernandes, Guerre and Horta \(2021\)](#). O estimador suavizado oferece algumas vantagens: não possui pontos de descontinuidade, é assintoticamente não viesado e menos variável que o estimador tradicional de regressão quantílica. Simulações anteriores [Ongaratto and Horta \(2021\)](#) mostraram que o estimador supera o de [Ota, Kato and Hara \(2019\)](#) em muitos aspectos.

Objetivo

O principal objetivo da presente dissertação é desenvolver um estimador para a moda condicional, denominado *Regressão Modal via Convolução*, empregando uma regressão quantílica suavizada. Ademais, derivam-se as propriedades assintóticas do estimador, provando, por meio de taxas de convergências, que é consistente.

Novidades do trabalho

O presente trabalho difere do que é feito em [Zhang, Kato and Ruppert \(2023\)](#) pois os autores optam por uma abordagem de “estimar depois suavizar” enquanto a nossa estratégia pode ser descrita como “suavizar depois estimar”. A escolha de “estimar depois suavizar” se assemelha à ideia de [Parzen \(1979\)](#), de estimação dos quantis suavizando a função quantílica amostral. No entanto, o procedimento de “suavizar depois estimar” relaciona-se com o método de [Nadaraya \(1964\)](#), no qual o quantil não condicional é estimado pela inversão de um estimador suavizado da função de distribuição acumulada.

No que se refere às taxas de convergência, o estimador de [Zhang, Kato and Ruppert \(2023\)](#) possui $O_P(n^{-1/2}h^{-3/2}\sqrt{\log n} + h^2)$, enquanto o nosso, $O_P((\frac{\log n}{nh})^{1/4}) + o(h^{1/2})$. Ambas as taxas são independentes de dimensão, portanto, livres da “maldição da dimensionalidade”. Contudo, dada a escolha do parâmetro de largura de banda, o nosso estimador pode convergir mais rapidamente para a moda real, ademais, nossos pressupostos sobre h são mais relaxados, permitindo mais opções de escolha da banda de suavização. Entretanto, nossa convergência é uniforme tanto para x , quanto para h ; no caso de [Zhang, Kato and Ruppert \(2023\)](#), não há uniformidade para a largura da banda.

Organização do trabalho

Na seção seguinte é feita uma breve revisão de literatura, que engloba as hipóteses de moda única ou modas locais, assim como as opções de estimação (semi-paramétricas ou não paramétricas). Em sequência, expõe-se o modelo de regressão modal via regressão quantílica suavizada. No capítulo 4 são mencionados, brevemente, os principais achados do trabalho. Por fim, apresentamos nossas considerações finais junto aos encaminhamentos de trabalhos futuros. O restante dos resultados

encontra-se no artigo, disponível no Anexo [A](#).

CAPÍTULO 2

REVISÃO DE LITERATURA

A estimação da moda global para uma variável contínua não é tão explícita quanto parece. [Sager \(1978\)](#) e [Chacón \(2020\)](#) dividem os estimadores de moda em duas categorias, direta e indireta. Estimadores indiretos é quando um passo intermediário é necessário, como, por exemplo, estimar a função de densidade, geralmente feito através da Estimativa de Densidade por Kernel (KDE), conforme introduzido por [Parzen \(1962\)](#). Os estimadores são do tipo direto quando especificamente construídos com o único propósito de estimar a moda, como é o caso do estimador “naive” da moda baseado em [Chernoff \(1964\)](#). Conforme afirmado por [Sager \(1978\)](#), essas classificações podem se misturar, já que a maioria dos estimadores diretos revela algum tipo de ligação com um tipo de estimação de densidade ([Chacón, 2020](#)). A partir da introdução de estimadores da moda, a atenção se voltou para estudar como a moda de uma variável de interesse responde às covariadas. No entanto, em vez de modelar essa relação por meio de um modelo baseado em média/mediana, [Sager and Thisted \(1982\)](#) estendem o estimador de [Chernoff \(1964\)](#) e desenvolvem o primeiro modelo de regressão modal global. Este primeiro modelo estabelece a moda como uma função monotônica das covariadas e utiliza-se um estimador não paramétrico de máxima verossimilhança; entretanto, este modelo é somente aplicável para dados ordinais. A combinação empregada por [Sager and Thisted \(1982\)](#), de estimativa não paramétrica e suposição de uma moda única, não é usual na literatura.

A regressão modal pode ser categorizada de acordo com dois principais fatores: (i) unimodal vs multimodal e (ii) estimativa (semi)paramétrica vs não paramétrica. Primeiramente, (i) a suposição da distribuição ter um único ponto de máximo, chamado de *moda global*, ou a hipótese de existirem diversos pontos de máximo, chamada *demoda local*. Em segundo lugar, (ii) o tipo de estimativa (semi)paramétrica, ao formular uma relação linear entre a variável de interesse e as covariadas; ou não paramétrica, como em [Chen et al. \(2016\)](#). Os modelos lineares pressupõem que a moda seja única, porém a suposição de moda única não implica que estimação deva ser (semi)paramétrica. Por outro lado, esta revisão não encontrou na literatura um modelo multimodal que não fosse estimado de forma não paramétrica. Diante disso, podemos dividir a literatura em 4 vertentes diferentes¹: (1) Moda Global e Estimação Semi-paramétrica; (2) Moda Global e Estimação Não Paramétrica e (3) Moda Local e Estimação Não Paramétrica; e (4) Abordagem por Regressão Quantílica. A primeira e última vertentes da literatura serão discutidas com maior detalhadamente neste trabalho, uma vez que têm relevância para o modelo proposto.²

¹Algumas metodologias que podem não se encaixar precisamente nesta categorização são [Liu et al. \(2013\)](#) e [Wang \(2024\)](#), que misturam características paramétricas e não paramétricas; e [Yu and Aristodemou \(2012\)](#), que desenvolvem uma abordagem bayesiana para a regressão modal.

²Para uma pesquisa geral sobre o papel da moda na estatística, recomendamos [Chacón \(2020\)](#); especificamente para

2.1 *Moda Global e Estimação Semi-paramétrica*

Dentre os primeiros trabalhos de regressão modal, [Lee \(1989\)](#) propôs uma abordagem linear onde uma função de perda suavizada é usada. A principal desvantagem desta linha de ação reside na suposição de homogeneidade e simetria dos termos de erro, o que leva à coincidência da moda condicional com a média condicional. Ainda, este trabalho inspirou pesquisas subsequentes sobre a estimação linear da moda condicional, como [Lee \(1993\)](#), onde em vez de usar um kernel retangular aplica-se um quadrático. Os artigos de Lee inspiraram trabalhos adicionais que buscaram eliminar hipótese de simetria dos erros, como [Kemp and Santos-Silva \(2012\)](#), onde a estimação é feita através da minimização de uma função de perda baseada em kernel e, focada em dados de alta dimensão, [Yao and Li \(2014\)](#). Ambos os métodos têm algoritmos problemáticos, já que não há garantia de convergência para o máximo global, e são altamente sensíveis aos valores iniciais. Algumas contribuições adicionais dessa vertente da literatura podem ser encontradas em seleção de variáveis ([Zhang et al., 2013](#)), análise de séries temporais ([Kemp et al., 2020](#)) e em dados em painel ([Ullah et al., 2021](#)).

2.2 *Moda Global e Estimação Não Paramétrica*

Uma abordagem linear pode ser muito restritiva, dependendo do conjunto de dados, assim, via regressão não paramétrica é possível modelar os componentes da moda condicional como funções suavizadas das covariadas ([Chen et al., 2016](#)). Além do trabalho pioneiro de [Sager and Thisted \(1982\)](#), a moda global é estimada de forma não paramétrica no trabalho de [Yao et al. \(2012\)](#) ao aplicar suavização polinomial. Na generalização dos autores, quando um polinômio tem grau zero e há uma única covariada, o método é chamado de regressão modal local linear; sem covariadas o modelo se resume a estimação de densidade via kernel. Contudo, o modelo apresenta algumas desvantagens: a aplicação limita-se a uma única moda ([Chen, 2018](#)), é passivo da “maldição da dimensionalidade” e impõe simetria nos erros. Uma regressão não paramétrica para moda global mais recente que mitiga a “maldição da dimensionalidade” é o trabalho de [Feng et al. \(2020\)](#), no qual uma análise de aprendizagem estatística é aplicada à regressão na moda. A estimação é obtida por meio de uma minimização empírica do risco. Dita modulação do problema torna-o não dependente da dimensão, deste modo, sendo aplicável a áreas como *big data* e *machine learning*.

2.3 *Moda Local e Estimação Não Paramétrica*

Visto que nem todas as estruturas de dados podem ser interpretadas como unimodais, [Scott \(1992\)](#) considera que podem existir mais de uma moda e as define como pontos de máximo locais da densidade condicional da variável resposta. [Matzner-Løfber et al. \(1998\)](#) utilizam desta ideia para realizar uma comparação do poder preditivo de modelos baseados na média, mediana e moda condicional, conclui-se que em casos de variáveis bimodais a regressão modal supera as alternativas em poder preditivo. Percebendo esta vantagem para dados aparentemente bimodais, [Einbeck and Tutz \(2006\)](#) desenvolvem um algoritmo que é aplicado a dados de fluxo de carros. Inspirados por M-estimadores locais, [Yao et al. \(2012\)](#) formulam uma regressão multimodal com suavização polinomial local. No entanto, eles regressão modal, indicamos a revisão de [Chen \(2018\)](#).

impõem um tipo de condição de simetria na distribuição do erro (Zhang, Kato and Ruppert, 2023). O trabalho de Chen et al. (2016) utiliza suposições menos restritivas, ademais, o estimador gerado tem propriedades assintóticas fortes; porém a taxa de convergência é lenta mesmo quando o número de covariáveis é relativamente baixo Zhang, Kato and Ruppert (2023).

2.4 Abordagem por Regressão Quantílica

Motivados pelo fato de que modelos lineares podem levar a problemas de especificações e otimizações não convexas, enquanto modelos não paramétricos tem convergência lenta e são passíveis à “maldição da dimensionalidade”, Ota, Kato and Hara (2019) desenvolveram uma abordagem semi-paramétrica inovadora baseada em quantis condicionais. A ideia baseia-se em utilizar uma regressão quantílica como um passo intermediário para estimar a moda. Parte-se do estimador tradicional de Koenker and Bassett (1978), a partir do qual tem-se uma estimativa da *densidade quantílica* condicional (obtida por diferenciação numérica). Esta abordagem supera os problemas adjacentes a modelos lineares e aos não paramétricos; no entanto, o estimador tradicional para a função quantílica possui pontos de descontinuidade; para contornar tal problema, Zhang, Kato and Ruppert (2023) propõem suavizar posteriormente o estimador por meio de um kernel, levando a taxas de convergência mais rápidas e uma distribuição assintótica Normal. Ambos os artigos partem de uma identidade chave que também exploramos neste trabalho, isto é, que a densidade quantílica é o recíproco da função de densidade, avaliada no quantil de interesse, que resume como a moda condicional pode ser obtida via a densidade quantílica.

CAPÍTULO 3

REGRESSÃO MODAL VIA CONVOLUÇÃO

3.1 Contexto

Seja $Y \in \mathbb{R}$ a representação de uma variável aleatória de respostas para a qual estamos interessados em estimar a moda condicional, dado o vetor de covariadas X^d , com $\mathcal{X} := \text{suporte}(X)$. Assuma que $Y|X = x$ seja contínua e unimodal, tendo função de distribuição acumulada condicional $F(\cdot|x)$ e função de densidade de probabilidade condicional $f(\cdot|x)$. Então, a **moda condicional** de Y dado $X = x$, denotada por $m(x)$, é definida como:

$$m(x) = \arg \max_{y \in \mathbb{R}} f(y|x), \quad x \in \mathcal{X}. \quad (3.1)$$

Assim, $m(x)$ corresponde ao ponto no espaço de covariadas onde a densidade (condicional) da resposta alcança seu valor máximo. Além disso, defina o τ -ésimo **quantil condicional de Y dado $X = x$** como o escalar $Q(\tau|x)$ dado por

$$Q(\tau|x) := \inf\{y \in \mathbb{R} : F(y|x) \geq \tau\}, \quad \tau \in (0, 1), x \in \mathcal{X}$$

e a **função quantílica condicional** como $\tau \mapsto Q(\tau|x)$

Vale ressaltar que a função quantílica é totalmente recuperável a partir da função de distribuição acumulada (fda), uma vez que é apenas a inversa generalizada da função $y \mapsto F(y|x)$, e no caso da distribuição ser uma função contínua, temos que $Q(\cdot|x) := F^{-1}(\cdot|x)$ para cada x ([van der Vaart, 1998](#); [Koenker, 2005](#)). Além disso, a **densidade quantílica condicional** é definida por meio de

$$q(\tau|x) = Q'(\tau|x) = \frac{\partial Q(\tau|x)}{\partial \tau}, \quad \tau \in (0, 1), x \in \mathcal{X}. \quad (3.2)$$

Uma identidade fundamental explorada por [Ota, Kato and Hara \(2019\)](#) e [Zhang, Kato and Ruppert \(2023\)](#) é que, como consequência do Teorema da Função Inversa, a identidade

$$q(\tau|x) = \frac{1}{f(Q(\tau|x)|x)} \quad (3.3)$$

vale para todo x e τ permitidos. Nesse sentido, podemos minimizar o inverso da densidade, como na equação (3.3), e recuperar o maximizador de $y \mapsto f(y|x)$ a partir da equação (3.1); conforme

$$m(x) = Q(\arg \min_{\tau} q(\tau|x)|x) \quad (3.4)$$

No que se refere à função quantílica, tanto [Ota, Kato and Hara \(2019\)](#) quanto [Zhang, Kato and Ruppert \(2023\)](#) consideram o modelo tradicional de regressão quantílica desenvolvido por [Koenker and Bassett \(1978\)](#), que estipula uma representação linear em covariadas da função quantílica condicional:

$$Q(\tau|x) = x^\top \beta(\tau), \quad \tau \in (0, 1), x \in \mathcal{X}, \quad (3.5)$$

onde $\beta : (0, 1) \mapsto \mathbb{R}^d$ é um parâmetro funcional. Para cada τ fixo no intervalo $(0, 1)$, o vetor $\beta(\tau)$ em (3.5) resolve um problema de minimização semelhante ao encontrado na regressão linear clássica. Para esse fim, a seguinte função objetivo populacional é proposta:

$$R(b; \tau) := \mathbb{E}[\rho_\tau(Y - X^\top b)] = \int \rho_\tau(t) dF(t; b) \quad (3.6)$$

com $\rho_\tau(u) := u[\tau - \mathbb{I}(u < 0)]$ conhecida como a *check function*. O parâmetro verdadeiro $\beta(\tau)$ minimiza $R(b; \tau)$ em relação a $b \in \mathbb{R}^d$. O equivalente amostral proposto por [Koenker and Bassett \(1978\)](#) é definido como:

$$\widehat{R}(b; \tau) := \frac{1}{n} \sum_{i=1}^n \rho_\tau(Y_i - X_i^\top b) = \int \rho_\tau(t) d\widehat{F}(t; b), \quad (3.7)$$

onde $\widehat{F}(\cdot; b)$ é a função de distribuição empírica dos erros $\varepsilon_i(b) = Y_i - X_i^\top b$, $i = 1, \dots, n$, com o estimador tradicional de regressão quantílica como o minimizador de $\widehat{R}(b; \tau)$, em relação a $b \in \mathbb{R}^d$, ou seja:

$$\widehat{\beta}(\tau) = \arg \min_{b \in \mathbb{R}^d} \widehat{R}(b; \tau), \quad \tau \in (0, 1) \quad (3.8)$$

Conforme o Teorema 2.1 em [Bassett and Koenker \(1982\)](#), a função quantílica condicional empírica $\tau \mapsto x^\top \widehat{\beta}(\tau)$ apresenta saltos e não é diferenciável. Para superar esse problema, [Fernandes, Guerre and Horta \(2021\)](#) propuseram o uso de um estimador do tipo kernel para a função de distribuição acumulada (fda), semelhante à proposição de [Nadaraya \(1964\)](#), ao invés da função de distribuição empírica. A versão suavizada da função objetivo amostral em (3.7) resulta em:

$$\widehat{R}_h(b; \tau) = \frac{1}{n} \sum_{i=1}^n k_h * \rho_\tau(Y_i - X_i^\top b) = \int \rho_\tau(t) \widehat{f}_h(t; b) dt \quad (3.9)$$

onde o símbolo $*$ denota o operador de convolução, e onde $\widehat{f}_h(\cdot; b)$ é o estimador de kernel da densidade de $Y_i - X_i^\top b$. Aqui, $k_h(u) = k(u/h)/h$, é um kernel com parâmetro de suavização $h > 0$, que tende a 0 à medida que o tamanho da amostra, n , aumenta). O novo estimador é o minimizador da função objetivo (3.9), chamado de **estimador de regressão quantílica suavizado (SQRE)** e definido por:

$$\widehat{\beta}_h(\tau) := \arg \min_{b \in \mathbb{R}^d} \widehat{R}_h(b; \tau), \quad \tau \in (0, 1). \quad (3.10)$$

A relação $\tau \mapsto \widehat{\beta}_h(\tau)$ é continuamente diferenciável no intervalo $(0, 1)$, ao contrário de $\widehat{\beta}$. O fato de $\widehat{\beta}_h(\tau)$ ser diferenciável oferece algumas vantagens notáveis: (i) a suavidade da função objetivo garante a regularidade do estimador resultante; (ii) a matriz de covariância assintótica de $\widehat{\beta}_h(\tau)$ pode ser estimada de maneira padrão, como em [Newey and McFadden \(1994\)](#). Em relação à diferenciabilidade, escrevendo $\widehat{R}_h^{(1)}(b; \tau) := \partial \widehat{R}_h(b; \tau) / \partial b$, o SQRE satisfaz a condição de primeira ordem $\widehat{R}_h^{(1)}(\widehat{\beta}_h(\tau); \tau) = 0$. Segundo o Teorema da Função Implícita, obtemos:

$$\widehat{\beta}_h^{(1)}(\tau) = \frac{\partial \widehat{\beta}_h(\tau)}{\partial \tau} := \left[\widehat{R}_h^{(2)}(\widehat{\beta}_h(\tau); \tau) \right]^{-1} \bar{X} \quad (3.11)$$

3.2 Estimação

Considere a seguinte função objetivo (ou “sparsity”¹):

$$s_x(\tau) := -q(\tau|x), \quad \tau \in (0, 1), x \in \mathcal{X}. \quad (3.12)$$

Não é difícil mostrar que

$$s_x(\tau) = -x^\top \beta^{(1)}(\tau) = -x^\top [D(\tau)]^{-1} \mathbb{E}X \quad (3.13)$$

com

$$D(\tau) = R^{(2)}(\beta(\tau); \tau) = \mathbb{E}[X X^\top f(X^\top \beta(\tau)|X)]. \quad (3.14)$$

Sob alguns pressupostos, a função $\tau \mapsto s_x(\tau)$ tem um único maximizador, denotado por τ_x , que chamamos de **moda quantílica condicional** de Y dado $X = x$. Se inserirmos este otimizador na função quantílica $Q(\cdot|x)$, obtemos a expressão $m(x) = Q(\tau_x|x)$. Conseqüentemente, a estimação de $m(x)$ se resume a estimar a função quantílica condicional e τ_x . Em vista de (3.13), definimos, para certos τ , x e h , a **função “sparsity” condicional amostral** como:

$$\hat{s}_{x,h}(\tau) = -x^\top \hat{\beta}_h^{(1)}(\tau) = -x^\top [\hat{D}_h(\tau)]^{-1} \bar{X}, \quad (3.15)$$

conforme as definições de [Fernandes, Guerre and Horta \(2021\)](#):

$$\hat{D}_h(\tau) = \hat{R}_h^{(2)}(\hat{\beta}_h(\tau); \tau) = \frac{1}{n} \sum_{i=1}^n X_i X_i^\top k_h(X_i^\top \hat{\beta}_h(\tau) - Y_i). \quad (3.16)$$

Os otimizadores para as funções de “sparsity”, tanto populacional quanto amostral, conforme definidos em (3.13) e (3.15), são dados por:

$$\tau_x = \arg \max_{\tau \in (0,1)} s_x(\tau) \quad \text{e} \quad \hat{\tau}_{x,h} = \arg \max_{\alpha \leq \tau \leq 1-\alpha} \hat{s}_{x,h}(\tau) \quad (3.17)$$

onde $0 < \alpha < 1/2$ é uma constante.

Nosso **estimador da moda condicional suavizado** proposto é então dado por

$$\hat{m}_h(x) := \hat{Q}_{x,h}(\hat{\tau}_{x,h}) = x^\top \hat{\beta}_h(\hat{\tau}_{x,h}), \quad (3.18)$$

para todo $x \in \mathcal{X}$ e todo h admissível.

¹Esta é a nomenclatura usada por [Ota, Kato and Hara \(2019\)](#) e [Zhang, Kato and Ruppert \(2023\)](#).

CAPÍTULO 4

PRINCIPAIS RESULTADOS

Nesta seção expomos apenas um sumário dos principais resultados da dissertação. As condições, enunciados e provas dos principais resultados encontram-se no artigo, disponível no Anexo A.

Principais Resultados:

- Provamos que nossa função objetivo (“sparsity”) amostral converge para seu análogo populacional; conforme o Lema 2 do artigo isto ocorre a uma taxa $O_P(\sqrt{\log n/nh}) + o(h)$.
- O Teorema 1 do nosso artigo prova que o maximizador da função objetivo (“sparsity”), denominado $\hat{\tau}_{x,h}$ converge para o verdadeiro otimizador a uma taxa de $O_P((\frac{\log n}{nh})^{1/4}) + o(h^{1/2})$. A prova do Teorema 1 é em duas partes, demonstramos primeiro que $\hat{\tau}_{x,h}$ é consistente; e depois derivamos sua taxa de convergência assintótica.
- Partindo dos resultados anteriores, o Teorema 2 do artigo prova que o nosso estimador proposto para a moda condicional, denominado $\hat{m}_h(x)$, converge assintoticamente para a moda real. Sua convergência se dá na ordem de $O_P((\frac{\log n}{nh})^{1/4}) + o(h^{1/2})$.
- Após encontrar as taxas de convergência, realizamos uma breve análise comparativa com o estimador de [Zhang, Kato and Ruppert \(2023\)](#). Concluímos que nosso estimador tem taxa de convergência próxima, porém mais lenta que a dos autores. No entanto, a nossa abordagem diverge nos pressupostos sobre a banda de suavização, com o nosso estimador, diferente do deles, tendo convergência uniforme para h , podendo trazer vantagens em contextos que a seleção da largura de banda é orientada pelos dados.

CAPÍTULO 5

CONCLUSÕES E TRABALHOS FUTUROS

No presente trabalho, foi desenvolvido um novo estimador para a moda condicional $\hat{m}_h(x)$, chamado de *Regressão Modal via Convolução*, baseado na inversão da regressão quantílica suavizada de [Fernandes, Guerre and Horta \(2021\)](#). A ideia estimar a moda condicional por meio da regressão quantílica não é novidade, uma vez que já foi feita anteriormente ([Ota, Kato and Hara, 2019](#); [Zhang, Kato and Ruppert, 2023](#)). Este tipo de abordagem apresenta vantagens em relação aos dois principais problemas da regressão modal, convergência lenta juntamente com a “maldição da dimensionalidade” em modelos não paramétricos e otimização não convexa em modelos lineares. Nossa estratégia de estimação baseia-se em um passo intermediário no qual, para estimar $\hat{m}_h(x)$, precisamos primeiro estimar a função quantílica condicional $Q(\cdot|x)$ e, em seguida, a moda quantílica condicional de Y dado $X = x$, denotado por τ_x . Assim, a estimação da moda depende da estimação de $Q(\cdot|x)$ e τ_x primeiramente.

Ao contrário do trabalho existente de [Zhang, Kato and Ruppert \(2023\)](#), que inicialmente estima a regressão quantílica e depois a suavizam por meio de um kernel, nossa abordagem se baseia em “suavizar depois estimar”. Desenvolvemos consistência assintótica para nosso estimador, obtendo taxas de convergência semelhantes às do estimador de [Zhang, Kato and Ruppert \(2023\)](#). Além da suavização inicial, a principal diferenciação de nosso modelo em relação ao dos autores está na premissa de seleção de largura de banda. Nossa suposição para a escolha da largura de banda é menos restritiva, sem grandes sacrifícios no quesito taxas de convergência. A escolha pelo nosso estimador pode ser interessante em casos que a seleção da largura de banda é orientada pelos dados, já que a taxa de convergência de $\hat{m}_h(x)$ é uniforme tanto em x quanto em h .

Trabalhos futuros relacionados à pesquisa atual podem seguir diferentes rumos. O que consideramos mais importante é a continuação das propriedades assintóticas, especificamente, derivar a distribuição assintótica do estimador. Além disso, simulações similares às de [Ongaratto and Horta \(2021\)](#), que compararam este estimador com o de [Ota, Kato and Hara \(2019\)](#), podem ser atualizadas para avaliar o desempenho do estimador em comparação com o de Zhang, Kato e Ruppert. Ademais, é possível examinar nosso estimador com as aplicações econométricas de trabalhos anteriores de regressão modal, de outra forma, reestimar as regressões anteriores a fim de examinar o desempenho do nosso estimador contra os prévios. Numa linha similar, é possível realizar uma generalização do presente trabalho focado em séries temporais, com interesse em modelos de previsão para dados assimétricos.

REFERÊNCIAS BIBLIOGRÁFICAS

- Bassett, G., Koenker, R., 1982. An empirical quantile function for linear models with iid errors. *Journal of the American Statistical Association* 77, 407–415.
- Chacón, J.E., 2020. The modal age of statistics. *International Statistical Review* 88, 122–141.
- Chen, Y.C., 2018. Modal regression using kernel density estimation: A review. *Wiley Interdisciplinary Review: Computational Statistics* 10.
- Chen, Y.C., Genovese, C., Tibishirani, R., Wasserman, L., 2016. Nonparametric modal regression. *The Annals of Statistics* 44, 489–514.
- Chernoff, H., 1964. Estimation of the mode. *Annals of the Institute of Statistical Mathematics* 16, 31–41.
- Einbeck, J., Tutz, G., 2006. Modelling beyond regression functions: an application of multimodal regression to speed–flow data. *Applied Statistics* 55, 461–475.
- Feng, Y., Fan, J., Suykens, J., 2020. A statistical learning approach to modal regression. *Journal of Machine Learning Research* 21, 1–35.
- Fernandes, M., Guerre, E., Horta, E., 2021. Smoothing quantile regressions. *Journal of Business & Economic Statistics* 39, 338 – 357.
- Kemp, G., Santos-Silva, J., 2012. Regression towards the mode. *Journal of Econometrics* 170, 92–101.
- Kemp, G.C.R., Parente, P.M.D.C., Santos-Silva, J.M.C., 2020. Dynamic vector mode regression. *Journal of Business & Economic Statistics* 38, 647–661.
- Koenker, R., 2005. *Quantile Regression*. Cambridge University Press.
- Koenker, R., Bassett, G., 1978. Regression quantiles. *Econometrica* 46, 33–50.
- Lee, M.J., 1989. Mode regression. *Journal of Econometrics* 42, 337–349.
- Lee, M.J., 1993. Quadratic mode regression. *Journal of Econometrics* 57, 1–19.
- Liu, J., Zhanga, R., Zhaoa, W., Lv, Y., 2013. A robust and efficient estimation method for single index models. *Journal of Multivariate Analysis* 122, 226–238.
- Matzner-Løfber, E., Gannoun, A., Gooijer, J.G.D., 1998. Nonparametric forecasting: a comparison of three kernel-based methods. *Communications in Statistics - Theory and Methods* 27, 1593–1617.
- Nadaraya, E.A., 1964. Some new estimates for distribution functions. *Theory of Probability & Its Applications* 9, 497–500.

- Newey, W., McFadden, D., 1994. Large sample estimation and hypothesis testing, in: *Handbook of Econometrics* (Vol. 4). Elsevier.
- Ongaratto, A., Horta, E., 2021. *Conditional Mode: An Approach via Smoothed Quantile Regression*. Master's thesis. Federal University of Rio Grande do Sul (UFRGS). <https://lume.ufrgs.br/handle/10183/237727>.
- Ota, H., Kato, K., Hara, S., 2019. Quantile regression approach to conditional mode estimation. *Electronic Journal of Statistics* 13, 3120–3160.
- Parzen, E., 1962. On estimation of a probability density function and mode. *The Annals of Mathematical Statistics* 33, 1065–1076.
- Parzen, E., 1979. Nonparametric statistical data modeling. *Journal of the American Statistical Association* 74, 105–121.
- Sager, T., 1978. Estimation of a multivariate mode. *The Annals of Statistics* 6, 802–812.
- Sager, T.W., Thisted, R.A., 1982. Maximum likelihood estimation of isotonic modal regression. *The Annals of Statistics* 10, 690–707.
- Scott, D.W., 1992. *Multivariate Density Estimation: Theory, practice and Visualization*. John Wiley & Sons.
- Ullah, A., Wang, T., Yao, W., 2021. Modal regression for fixed effects panel data. *Empirical Economics* 60, 261–308.
- van der Vaart, A., 1998. *Asymptotic Statistics*. Cambridge University Press.
- Wang, T., 2024. Non-parametric estimator for conditional mode with parametric features. *Oxford Bulletin of Economics and Statistics* 86, 44–73.
- Wang, X., Chen, H., Cai, W., Shen, D., Huang, H., 2017. Regularized modal regression with applications in cognitive impairment prediction. *Advances in Neural Information Processing Systems* 30 (NIPS 2017) .
- Yao, W., Li, L., 2014. A new regression model: Modal linear regression. *Scandinavian Journal of Statistics* 41, 656–671.
- Yao, W., Lindsay, B.G., Li, R., 2012. Local mode regression. *Journal of Nonparametric Statistics* 24, 647–663.
- Yu, K., Aristodemou, K., 2012. Bayesian mode regression. *arXiv* .
- Zhang, R., Zhao, W., Liu, J., 2013. Robust estimation and variable selection for semiparametric partially linear varying coefficient model based on modal regression. *Journal of Nonparametric Statistics* 25, 523–544.
- Zhang, T., Kato, K., Ruppert, D., 2023. Bootstrap inference for quantile-based modal regression. *Journal of the American Statistical Association* 118, 122–134.

APÊNDICE A

ARTIGO FINN E HORTA

Autores: Eduardo Schirmer Finn e Eduardo de Oliveira Horta

Título: Convolutional Modal Regression

Revista: "a definir"

Ano: 2024

Convolution Mode Regression

Eduardo Schirmer Finn^{*§}, Eduardo Horta^{*†}

Abstract

For highly skewed or fat-tailed distributions, mean or median-based methods may be inadequate to capture centrality in the data. This deficiency of traditional methods has fostered the emergence of conditional mode models as a valuable approach. However, estimating the conditional mode of a variable given certain covariates presents challenges: nonparametric approaches suffer from the “curse of dimensionality”, while the semiparametric strategy can lead to non-convex optimization problems. We propose a novel estimator for mode regression, constructed by inverting the conditional quantile density. Unlike existing approaches in the literature, we estimate the quantile density function by inverting a convolution-type smoothed variant of the quantile regression model. Our resulting estimator is consistent, with the benefit of having uniform convergence with respect to both the design points of the covariates and to the bandwidth.

Keywords: *Mode Regression; Convolution-based Smoothing; Conditional Quantile; Asymptotic Theory; Uniform Convergence.*

1 Introduction

Conventional econometric methods are generally mean-based; such methods may fail to express the central tendency if distributions are highly skewed or long-tailed (Kemp and Santos-Silva, 2012; Chen et al., 2016). The conditional mode emerges as a robust alternative, conveying the desirable interpretation of being the most likely value of a dataset (Chacón, 2020). This interpretation becomes particularly valuable when dealing with continuous variables, which, unlike discrete random variables, do not have a straightforward sample mode version. In such cases, the mode is formally defined as a point of maximum (local or global) for the conditional probability density function. Since Lee (1989), the estimation of conditional mode, called mode regression, has demonstrated its utility across various domains, specially in applications with asymmetric data, such as wages (Zhang, Kato, and Ruppert, 2023); electrical energy consumption (Ota, Kato, and Hara, 2019); medical sciences (Wang et al., 2017), traffic data (Einbeck and Tutz, 2006) and a forest fire dataset (Yao and Li, 2014).

In reviewing the conditional mode literature, two fundamental considerations emerge in the discussion: firstly, the assumption of whether the mode is global or local; secondly,

^{*}Department of Statistics, Federal University of Rio Grande do Sul (UFRGS), Porto Alegre, Brazil.

[§]Corresponding Author, eduardosfinn@outlook.com

[†]eduardo.horta@ufrgs.br

if the estimation strategy employed is semiparametric (linear) or fully nonparametric. Linear approaches require the condition that the mode is a unique maximizer of the conditional density; nonparametric techniques in turn are usually used for multimodal models, but not exclusively—in a few cases the global mode is also estimated nonparametrically (Sager and Thisted, 1982; Feng et al., 2020). The first semiparametric estimator considering a unique mode was developed by Lee (1989) and establishes a linear relationship between the mode of the response and the covariates; however, despite being elegant, this model is impractical,¹ subsequent models, such as the ones of Kemp and Santos-Silva (2012) and Yao and Li (2014), yield out non-convex optimization problems, resulting in functions that may have multiple maxima; also, the algorithms developed are sensible to the starting points. On the other hand, nonparametric estimation tends to avoid misspecification (Yao et al., 2012; Chen et al., 2016); still, these methods suffer from the “curse of dimensionality” and, moreover, have slow convergence rates (Zhang, Kato, and Ruppert, 2023). Two related methods have been developed by Ota, Kato, and Hara (2019) and Zhang, Kato, and Ruppert (2023); both relying on estimating the conditional quantile density by inverting a quantile regression, overcoming slow convergence and optimization issues.

Similarly to what is done in Ota, Kato, and Hara (2019) and Zhang, Kato, and Ruppert (2023), we propose a novel approach which relies on working with a different quantile regression estimator, the smoothed version of Fernandes, Guerre, and Horta (2021). This alternative of the estimator provides some advantages: it is continuous, asymptotically unbiased and less variable than the traditional quantile regression estimator. Previous simulations (Ongaratto and Horta, 2021) have shown that our estimator outperforms the Ota, Kato, and Hara’s (2019) in many aspects.

The main goal of this work is to derive asymptotic properties for the estimator of the conditional mode via smoothed quantile regression, hereby denominated *Convolution Mode Regression*, proving its consistency, with convergence rates. Additionally, our approach differs from Zhang, Kato, and Ruppert (2023) as they opt for an “*estimate then smooth*” procedure (using the traditional quantile regression framework), while we “*smooth then estimate*” (a smoothed and continuous version of the estimator). The “*estimate then smooth*” approach is more akin to the proposition of Parzen (1979), of quantile estimation by smoothing the sample quantile function; whereas the “*smooth then estimate*” approach parallels Nadaraya (1964)’s method, in which the unconditional quantile is estimated via inverting a smoothed estimator of the cdf (cumulative distribution function). The convergence rate of the Zhang, Kato, and Ruppert (2023) estimator is $O_P(n^{-1/2}h^{-3/2}\sqrt{\log n+h^2})$, whilst ours is $O_P((\frac{\log n}{nh})^{1/4}) + o(h^{1/2})$; both rates free from the “curse of dimensionality”. Nonetheless, our estimator can be more adequate in cases where the choice of the bandwidth is data-driven, due to its uniform convergence also in h , something not present in

¹According to Kemp and Santos-Silva (2012) this model has restrictive assumptions on the conditional density of the response and, due to the objective function, the estimator lacks a tractable distribution.

Zhang, Kato, and Ruppert (2023).

1.1 Literature Review

Estimation of a global mode in a continuous variable environment is not as explicit as it seems. Sager (1978) and Chacón (2020) divide the mode estimators into two categories, direct and indirect. The latter classification is for when an intermediate step is required, such as estimating the density function (as it is not known) which is typically done via Kernel Density Estimation (KDE), as firstly presented by Parzen (1962). Estimators are of the direct kind when they are specifically constructed for the sole purpose of estimating the mode, this is the case for the “naive” estimator of the mode based on Chernoff (1964). As stated by Sager (1978), these classifications may blur, as the majority of direct estimators reveal some kind of linkage with a type of density estimation (Chacón, 2020).

Following the introduction of mode estimators, attention shifted towards studying how the mode of a variable of interest responds to covariates. Sager and Thisted (1982) generalized the framework of Chernoff (1964) and developed the first mode regression. The initial model established that the global mode of the dependent variable is a monotone function of the covariate, and was estimated via a maximum likelihood nonparametric estimator. Despite this model’s limitation in being applicable only to ordinal data, it laid the groundwork for mode regression. Additionally, it was shown that the conditional mode estimator could be formulated by applying a plug-in from a density estimator, such as KDE; nevertheless, consistency was not achieved. Remarkably, such combination of nonparametric estimation alongside the assumption of a unique (global) mode, is not very common in the literature.

Building on this initial work, mode regression has evolved and can be categorized according to two major factors: (i) unimodal vs. multimodal assumption, and (ii) semiparametric vs. nonparametric estimation. Firstly, (i) the assumption of the mode being unique, referred to as *global mode*; or assuming more than one point of maxima and that the data distribution is multimodal, namely *local mode* assumption. Secondly, (ii) the type of estimation that is employed, which can be done semiparametrically, mainly formulating a linear relationship between the dependent variable and the covariates; vis-à-vis estimating the conditional mode nonparametrically in order to allow for multiple local modes, as in Chen et al. (2016). It is important to note that while all linear/semiparametric mode regressions require the assumption of a global mode, the inverse statement does not hold, that is, there is no need for a model with a unique mode to be linear, since it can be estimated nonparametrically. On the other hand, our review did not uncover a multimodal model that was not estimated nonparametrically. In light of this, we can divide the conditional mode estimation literature into 4 different strands²: (1) unique mode with linear/ semiparametric estimation; (2) unique mode with nonparametric estimation,

²Some papers may not fit precisely in this categorization, since they mix parametric and nonparametric traits (Liu et al., 2013; Wang, 2024), or use a Bayesian approach (Yu and Aristodemou, 2012).

and (3) multimodal with nonparametric estimation; afterwards, special attention is given to (4) conditional quantile approaches towards the mode, since this is more related to our contribution. The first and last literature strands are the ones that will be further discussed in this article, since they bear relevance to the model we propose. For a general survey of the role of the mode in statistics, we recommend [Chacón \(2020\)](#); especially for mode regression, we indicate the review of [Chen \(2018\)](#).

(1) Unique Mode & Semiparametric Estimation: following the initial work of [Sager and Thisted \(1982\)](#), [Lee \(1989\)](#) proposed a linear approach where a smoothed loss function is used. The main drawback of this line of action lies in the underlying assumptions, specially homogeneity and symmetry of the error terms, which led to the conditional mean coinciding with the conditional mode. Also, the estimator is impractical due to its distribution being intractable because of the objective function. This work inspired further investigation regarding linear conditional mode estimation, such as [Lee \(1993\)](#), where the rectangular kernel was replaced for a quadratic one. Still, restrictive assumptions were required on the conditional density of the response variable ([Chen, 2018](#)). Lee’s papers inspired further work that sought to eliminate the assumption of a symmetric error term, such as: [Kemp and Santos-Silva \(2012\)](#), where estimation is done via minimization of a kernel-based loss function; as well as [Yao and Li \(2014\)](#), who focused on high-dimensional data. Both methods have algorithmic issues, leading to a nonconvex optimization problems, with no guarantee of convergence to the global maximum, and high sensitivity to the selected starting point. Some further exploration of this literature strand can be found in variable selection ([Zhang et al., 2013](#)), time series analysis ([Kemp et al., 2020](#)) and in panel data ([Ullah et al., 2021](#)).

(2) Unique Mode & Nonparametric Estimation: a linear approach can be too restrictive depending on the type of data; thus, nonparametric regression can model the components of the conditional mode as smooth functions of the covariates ([Chen et al., 2016](#)). Apart from the pioneering work of [Sager and Thisted \(1982\)](#), the global mode is estimated nonparametrically in [Yao et al. \(2012\)](#) by applying local polynomial smoothing. In the generalization provided by the authors, when the degree of the polynomial is zero and there is a single covariate, the method is referred to as local linear modal regression; if there are no covariates, this method reduces to a kernel density estimate. Nonetheless, the model of [Yao et al. \(2012\)](#) carries out some issues: the application is limited to unique mode regression ([Chen, 2018](#)), it suffers from the “curse of dimensionality” and symmetry for the error’s distributions is imposed.³ A more recent nonparametric regression for single mode that mitigates the “curse of dimensionality” is found in [Feng et al. \(2020\)](#), where a statistical learning analysis is applied to mode regression. The estimation of the conditional mode is achieved via an empirical risk minimization approach. Such modulation turns the problem into non-dependable on dimension, thus being applicable

³According to [Zhang, Kato, and Ruppert \(2023\)](#), their sixth assumption (symmetry of the error term) leads to the problem corresponding to conditional mean estimation.

to areas such as big data and machine learning.

(3) Multimodal & Nonparametric Estimation: as it is not always the case that data structures can be interpreted as unimodal, multimode regressions come forth as alternatives that enable to uncover hidden relations otherwise undetected (Chen, 2018). The proposal to consider various modes arises from Scott (1992), who defined them as points of local maxima of the conditional density of the response. Such is the case for Matzner-Løfber et al. (1998), where a forecasting comparison is carried out for three kernel-based methods, namely, conditional mean regression, conditional median regression and conditional mode regression. The findings indicate that, when dealing with bimodal data, mode regression outperforms the competitors in terms of accuracy. Motivated by a similar prediction problem, where the data has two pronounced modes, Einbeck and Tutz (2006) develop the first systematic investigation regarding local modes (Chen, 2018; Chacón, 2020). Their estimator is computed from a modified *meanshift* algorithm; subsequently, it is applied to traffic data, and is used to determine the modal speed at different flows of cars. In contrast to Einbeck and Tutz (2006), where there is a lack of asymptotic theory, Chen et al. (2016) develop a conditional (multi)mode nonparametric model based on KDE. Less restrictive assumptions on the kernel density function are used, the method yields strong asymptotic properties and model misspecification is avoided. Despite this, according to Zhang, Kato, and Ruppert (2023) the convergence rate of the estimator is slow even when the number of covariates is not too large, namely, the approach suffers from the “curse of dimensionality”.

(4) Conditional Quantile Approach: motivated by the fact that linear mode regression models resulted in nonconvex optimization problems, and also in possible model misspecification, whereas the flexibility from nonparametric estimators comes at the cost of the “curse of dimensionality”, Ota, Kato, and Hara (2019) developed a novel semiparametric approach based on quantile regression. The main idea is to use this regression framework as an intermediate step for conditional mode estimation: namely, the quantile function of Koenker and Bassett (1978) is estimated, from which a conditional *quantile density* estimator is obtained via numerical differentiation. Importantly, the underlying model does not impose linearity of the mode function, not even when the quantile regression model used is linear-in-covariates. Furthermore, this approach avoids the “curse of dimensionality” and is appealing computationally, since the quantile regression estimator can be written as a linear programming problem. Still, using the traditional estimator for the quantile function can bring some concerns, since the empirical conditional quantile function has jumps—hence the mentioned numerical differentiation. In order to surpass this problem, Zhang, Kato, and Ruppert (2023) propose to post-smooth the quantile regression estimator by a kernel function. Not only does this strategy circumvents numerical differentiation, but also it yields faster convergence rates and an estimator that is asymptotically Normal, in contrast to a nonstandard Chernoff distribution as in Ota, Kato, and Hara (2019). Both models take off from a key identity that we also explore

in this paper, namely, that the quantile density is the reciprocal of the density function, evaluated at the quantile of interest, which summarizes how the conditional mode can be retrieved from the quantile density.

1.2 Organization

The rest of this paper is organized as follows. In Section 2 the model is presented, we introduce the estimator and explore its relationship with the smoothed quantile regression. In Section 3 we enunciate the main mathematical results of the paper, as well as the needed assumptions for them to hold; also, we compare our convergence rates to the most similar model in the literature for some different bandwidth scenarios. In Section 4 we state our concluding remarks along with possibilities for future work. The Appendix contains additional mathematical material, such as derivations and convergence rates calculations.

2 Convolution Mode Regression

2.1 Setup

Let $Y \in \mathbb{R}$ represent a target random variable for which we are interested in estimating the conditional mode, given a d -dimensional vector X of covariates, and write $\mathcal{X} := \text{support}(X)$. Assume that $Y|X = x$ is continuous and unimodal, having conditional cdf $F(\cdot|x)$ and conditional pdf $f(\cdot|x)$. Then, the **conditional mode** of Y given $X = x$, denoted by $m(x)$, is defined as:

$$m(x) = \arg \max_{y \in \mathbb{R}} f(y|x), \quad x \in \mathcal{X}. \quad (1)$$

Thus, $m(x)$ corresponds to the point in the covariate space at which the (conditional) density of the response attains its maximum value. Additionally, define the **τ -th conditional quantile of Y given $X = x$** as the scalar $Q(\tau|x)$ given by

$$Q(\tau|x) := \inf\{y \in \mathbb{R} : F(y|x) \geq \tau\}, \quad \tau \in (0, 1), x \in \mathcal{X}$$

and the **conditional quantile function** as the mapping $\tau \mapsto Q(\tau|x)$.

It is important to point out that the quantile function is entirely retrievable from the cdf, since it is just the generalized inverse of the function $y \mapsto F(y|x)$, and in the case of the distribution being a continuous function we have that $Q(\cdot|x) := F^{-1}(\cdot|x)$ for each x (van der Vaart, 1998; Koenker, 2005). Furthermore, the **conditional quantile density** is defined through

$$q(\tau|x) = Q'(\tau|x) = \frac{\partial Q(\tau|x)}{\partial \tau}, \quad \tau \in (0, 1), x \in \mathcal{X}. \quad (2)$$

A key identity explored by Ota, Kato, and Hara (2019) and Zhang, Kato, and Ruppert

(2023) is that, as a consequence of the Inverse Function Theorem, the identity

$$q(\tau|x) = \frac{1}{f(Q(\tau|x)|x)} \quad (3)$$

holds for every allowable x and τ . In this sense, given some regularity conditions which we introduce below, we can minimize the inverse of the density, as in equation (3), and retrieve the maximizer of $y \mapsto f(y|x)$ from equation (1); thus,

$$m(x) = Q(\arg \min_{\tau} q(\tau|x) | x) \quad (4)$$

Regarding the quantile function, both [Ota, Kato, and Hara \(2019\)](#) and [Zhang, Kato, and Ruppert \(2023\)](#) consider the quantile regression model developed by [Koenker and Bassett \(1978\)](#), which stipulates a linear-in-covariates representation of the conditional quantile function:

$$Q(\tau|x) = x^{\top} \beta(\tau), \quad \tau \in (0, 1), x \in \mathcal{X}, \quad (5)$$

where $\beta : (0, 1) \mapsto \mathbb{R}^d$ is a functional parameter. For each fixed τ in the interval $(0, 1)$, the vector $\beta(\tau)$ in (5) solves a similar minimization problem as the one found in classic linear regression. For this end, the following population objective function is proposed:

$$R(b; \tau) := \mathbb{E}[\rho_{\tau}(Y - X^{\top}b)] = \int \rho_{\tau}(t) dF(t; b) \quad (6)$$

with $\rho_{\tau}(u) := u[\tau - \mathbb{I}(u < 0)]$ known as the check function. The true parameter $\beta(\tau)$ minimizes $R(b; \tau)$ with respect to $b \in \mathbb{R}^d$. The sample equivalent proposed by [Koenker and Bassett \(1978\)](#) is defined as:

$$\widehat{R}(b; \tau) := \frac{1}{n} \sum_{i=1}^n \rho_{\tau}(Y_i - X_i^{\top}b) = \int \rho_{\tau}(t) d\widehat{F}(t; b), \quad (7)$$

where $\widehat{F}(\cdot; b)$ is the empirical distribution function of $\varepsilon_i(b) := Y_i - X_i^{\top}b$, for $i = 1, \dots, n$, with the traditional quantile regression estimator as the minimizer of $\widehat{R}(b; \tau)$, with respect to $b \in \mathbb{R}^d$, that is:

$$\widehat{\beta}(\tau) = \arg \min_{b \in \mathbb{R}^d} \widehat{R}(b; \tau), \quad \tau \in (0, 1) \quad (8)$$

According to Theorem 2.1 in [Bassett and Koenker \(1982\)](#), the empirical conditional quantile function $\tau \mapsto x^{\top} \widehat{\beta}(\tau)$ exhibits jumps, in particular it is not differentiable. To overcome this issue, [Fernandes, Guerre, and Horta \(2021\)](#) proposed using a kernel-type cdf estimator, similar to [Nadaraya \(1964\)](#), instead of the empirical distribution function. The resulting smoothed version of the sample objective function in (7) is:

$$\widehat{R}_h(b; \tau) = \frac{1}{n} \sum_{i=1}^n k_h * \rho_{\tau}(Y_i - X_i^{\top}b) = \int \rho_{\tau}(t) \widehat{f}_h(t; b) dt \quad (9)$$

where the symbol $*$ denotes the convolution operator, and where $\widehat{f}_h(\cdot; b)$ is the kernel estimator of the density of $Y_i - X_i^\top b$. Here, $k_h(u) = k(u/h)/h$, where $k: \mathbb{R} \rightarrow \mathbb{R}_+$ is a smooth kernel function and $h > 0$. The new estimator is the minimizer of the objective function (9), called the **smoothed quantile regression estimator (SQRE)** and defined by:

$$\widehat{\beta}_h(\tau) := \arg \min_{b \in \mathbb{R}^d} \widehat{R}_h(b; \tau), \quad \tau \in (0, 1). \quad (10)$$

The mapping $\tau \mapsto \widehat{\beta}_h(\tau)$ is continuously differentiable over the interval $(0, 1)$, unlike $\widehat{\beta}$. Differentiability offers notable advantages, and the reasons are twofold: (i) the smoothness of the objective function ensures the regularity of the resulting estimator; (ii) the asymptotic covariance matrix of $\widehat{\beta}_h(\tau)$ can be estimated in a standard fashion, as in [Newey and McFadden \(1994\)](#). Regarding differentiability, writing $\widehat{R}_h^{(1)}(b; \tau) := \partial \widehat{R}_h(b; \tau) / \partial b$, the SQRE satisfies the first-order condition $\widehat{R}_h^{(1)}(\widehat{\beta}_h(\tau); \tau) = 0$. Accordingly, following the Implicit Function Theorem, we obtain:

$$\widehat{\beta}_h^{(1)}(\tau) = \frac{\partial \widehat{\beta}_h(\tau)}{\partial \tau} := \left[\widehat{R}_h^{(2)}(\widehat{\beta}_h(\tau); \tau) \right]^{-1} \bar{X} \quad (11)$$

Explicit formulas for the first and second order derivatives of $\widehat{R}_h(b; \tau)$ with respect to b (respectively, $\widehat{R}_h^{(1)}(b; \tau)$ and $\widehat{R}_h^{(2)}(b; \tau)$) are provided in equation (33) in [A.1](#).

2.2 Estimation

Consider the following objective (or “sparsity”⁴) function:

$$s_x(\tau) := -q(\tau|x), \quad \tau \in (0, 1), \quad x \in \mathcal{X}. \quad (12)$$

It is not difficult to show that

$$s_x(\tau) = -x^\top \beta^{(1)}(\tau) = -x^\top [D(\tau)]^{-1} \mathbb{E}X \quad (13)$$

where

$$D(\tau) = R^{(2)}(\beta(\tau); \tau) = \mathbb{E}[XX^\top f(X^\top \beta(\tau)|X)]. \quad (14)$$

Under some regularity assumptions that will be introduced below, the function $\tau \mapsto s_x(\tau)$ has a unique maximizer, denoted τ_x , which we call the **conditional quantile mode** of Y given $X = x$. If we plug in this optimizer in the quantile function $Q(\cdot|x)$ we get the expression $m(x) = Q(\tau_x|x)$. Consequently, the estimation of $m(x)$ boils down to estimating the conditional quantile function, and τ_x . In view of (13), we define, for conformable τ , x and h , the **sample conditional sparsity function** as:

$$\widehat{s}_{x,h}(\tau) = -x^\top \widehat{\beta}_h^{(1)}(\tau) = -x^\top [\widehat{D}_h(\tau)]^{-1} \bar{X}, \quad (15)$$

⁴This is the nomenclature used by [Ota, Kato, and Hara \(2019\)](#) and [Zhang, Kato, and Ruppert \(2023\)](#).

where

$$\widehat{D}_h(\tau) = \widehat{R}_h^{(2)}(\widehat{\beta}_h(\tau); \tau) = \frac{1}{n} \sum_{i=1}^n X_i X_i^\top k_h(X_i^\top \widehat{\beta}_h(\tau) - Y_i), \quad (16)$$

see [Fernandes, Guerre, and Horta \(2021\)](#).

The optimizers for the sparsity functions, both population and sample, as defined in (13) and (15), are given by:

$$\tau_x = \arg \max_{\tau \in (0,1)} s_x(\tau) \quad \text{and} \quad \widehat{\tau}_{x,h} = \arg \max_{\alpha \leq \tau \leq 1-\alpha} \widehat{s}_{x,h}(\tau) \quad (17)$$

where $0 < \alpha < 1/2$ is a constant.

Our proposed **smoothed conditional mode estimator** is then given by

$$\widehat{m}_h(x) := \widehat{Q}_{x,h}(\widehat{\tau}_{x,h}) = x^\top \widehat{\beta}_h(\widehat{\tau}_{x,h}), \quad (18)$$

for all $x \in \mathcal{X}$ and every allowable h .

3 Main Results

Before providing consistency results of the proposed estimator, we state the conditions for which our results are derived.

3.1 Assumptions:

- **A1:** The support of X , denoted \mathcal{X} , is compact and a subset of $\bar{\mathbb{R}}_{+*}^d$, i.e., the components of X are positive, bounded RVs. The matrix $\mathbb{E}[X X^\top]$ is full rank.
- **A2:** The mapping $\tau \mapsto \beta(\tau)$ is three times continuously differentiable.
- **A3:** The conditional density $f(y|x)$ is continuous and strictly positive over $\mathbb{R} \times \mathcal{X}$. Also, the derivative $f^{(1)}(\cdot|\cdot)$ exists and is uniformly continuous in the sense that

$$\lim_{\epsilon \rightarrow 0} \sup_{(x,y) \in \mathbb{R}^{d+1}} \sup_{t:|t| \leq \epsilon} |f^{(1)}(y+t|x) - f^{(1)}(y|x)| = 0,$$

and that $\sup_{(x,y) \in \mathbb{R}^{d+1}} |f^{(j)}(y|x)| < \infty$ and $\lim_{y \rightarrow \pm\infty} f^{(j)}(y|x) = 0$ for all $j \in \{0, 1\}$.

Remark. The degree of differentiability of $f(\cdot|\cdot)$ is used in [Fernandes, Guerre, and Horta \(2021\)](#) to control the order of the smoothing kernel. Here, we set the maximum value of j equal to 1, for simplicity.

- **A4:** The kernel $k: \mathbb{R} \mapsto \mathbb{R}$ is even, integrable and has bounded first and second derivatives. Additionally, $\int k(z) dz = 1$; $0 < \int_0^\infty K(z)[1 - K(z)] dz < \infty$ and, lastly, $0 < \int z^2 k(z) dz < \infty$.
- **A5:** $h \in [\underline{h}_n, \bar{h}_n]$ with $n \underline{h}_n^3 / \log n \rightarrow \infty$ and $\bar{h}_n = o(1)$.

- **A6:** For all $x \in \mathcal{X}$, there exists $\tau_x \in (0, 1)$ such that, for every $\epsilon > 0$, it holds that

$$\sup_{\tau: |\tau - \tau_x| \geq \epsilon} s_x(\tau) < s_x(\tau_x)$$

- **A7:** For some $0 < \alpha < 1/2$, it holds that

$$\alpha < \inf_{x \in \mathcal{X}} \tau_x \leq \sup_{x \in \mathcal{X}} \tau_x < 1 - \alpha.$$

Assumptions A1-A5 are taken directly from [Fernandes, Guerre, and Horta \(2021\)](#), with minor modifications. Due to A1-A3, the Hessian $D(\tau)$ as defined in (14), is positive definite for all possible values of $\tau \in (0, 1)$, therefore, $D(\tau)$ is invertible. Additionally, A2 ensures the function $\tau \mapsto Q(\tau|x)$ is increasing over the interval $(0, 1)$, and, together with A3, that its derivative with respect to τ is strictly positive. Also, A3 expresses some ordinary regularity conditions which guarantee smoothness of $f(\cdot|\cdot)$ ([Koenker, 2005](#)). Similar conditions can be found in [Chen et al. \(2016\)](#); [Ota, Kato, and Hara \(2019\)](#); [Zhang, Kato, and Ruppert \(2023\)](#); however, each of these estimates requires four-times continuous differentiability of the density. Assumptions A4 and A5 concern the kernel function k and the bandwidth parameter h . A6 ensures uniqueness of the conditional mode and is also commonly used in deriving consistency of M-estimators, see Theorem 5.7 in [van der Vaart \(1998\)](#). Finally, Assumption A7 limits the possible values for the optimizer τ_x , ensuring that the conditional modes are bounded away from the tails of the conditional distributions, uniformly on the covariate space.

3.2 Consistency of the Convolution Mode Regression Estimator:

The following lemma is a reinstatement of an inequality in [Fernandes, Guerre, and Horta \(2021\)](#).

Lemma 1. Under Assumption A1 to A5, it holds that

$$\left\| \widehat{D}_h(\tau) - D(\tau) \right\| = o(h^j) + O_P \left(\sqrt{\log n / (nh)} \right), \quad (19)$$

uniformly for $\tau \in [\alpha, 1 - \alpha]$ and $h \in [\underline{h}_n, \bar{h}_n]$.

Proof. See the proof of Proposition 1 in [Fernandes, Guerre, and Horta \(2021\)](#). ■

Our next result is regarding the sample sparsity function and the fact that it converges to the population counterpart.

Lemma 2. Under Assumptions A1 to A5, it holds that

$$|\widehat{s}_{x,h}(\tau) - s_x(\tau)| = o(h) + O_P \left(\sqrt{\log n / (nh)} \right)$$

uniformly over $\tau \in [\alpha, 1 - \alpha]$, $x \in \mathcal{X}$ and $h \in [\underline{h}_n, \bar{h}_n]$.

Proof. Write

$$-(\widehat{s}_{x,h}(\tau) - s_x(\tau)) = x^\top [\widehat{D}_h(\tau)]^{-1} \bar{X} - x^\top [D(\tau)]^{-1} \mathbb{E}X.$$

Using $\bar{X} = \bar{X} - \mathbb{E}X + \mathbb{E}X$ and rearranging, we have

$$\begin{aligned} -(\widehat{s}_{x,h}(\tau) - s_x(\tau)) &= x^\top [\widehat{D}_h(\tau)]^{-1} (\bar{X} - \mathbb{E}X) \\ &\quad + x^\top \left\{ [\widehat{D}_h(\tau)]^{-1} - [D(\tau)]^{-1} \right\} (\mathbb{E}X) \end{aligned} \quad (20)$$

Lemma 1 implies, by the local Lipschitz property of matrix inversion, that

$$\left\| [\widehat{D}_h(\tau)]^{-1} - [D(\tau)]^{-1} \right\| = o(h) + O_P \left(\sqrt{\log n / (nh)} \right)$$

uniformly in τ and h as above. This together with

$$\sup_{\tau, h} |\widehat{D}_h(\tau)| = O_P(1), \quad \bar{X} - \mathbb{E}X = O_P(1/\sqrt{n}), \quad \mathbb{E}X = O(1), \quad \sup_{x \in \mathcal{X}} \|x\| = O(1)$$

tells us that

$$\begin{aligned} -(\widehat{s}_{x,h}(\tau) - s_x(\tau)) &= x^\top O_P(1) O_P(1/\sqrt{n}) \\ &\quad + x^\top \left(o(h) + O_P \left(\sqrt{\log n / (nh)} \right) \right) O(1) \\ &= o(h) + O_P \left(\sqrt{\log n / (nh)} \right) \end{aligned} \quad (21)$$

as stated. ■

After showing that our sparsity functions are consistent, we prove that its maximizer $\widehat{\tau}_{x,h}$, in equation (17), is also consistent for τ_x .

Theorem 1. Under Assumptions A1 to A7, it holds that

$$\widehat{\tau}_{x,h} = \tau_x + o(h^{1/2}) + O_P \left(\frac{\log n}{nh} \right)^{1/4} \quad (22)$$

uniformly for $x \in \mathcal{X}$ and $h \in [\underline{h}_n, \bar{h}_n]$.

Proof. The proof of Theorem (1) consists of two parts: initially, it is proved that $\widehat{\tau}_{x,h}$ is consistent; then, in the second part of the proof, we calculate its rate of convergence.

Part 1 (T1): First, by the definition of $\widehat{\tau}_{x,h}$ and through Lemma 2, we have

$$\widehat{s}_{x,h}(\widehat{\tau}_{x,h}) \geq \widehat{s}_{x,h}(\tau_x) = s_x(\tau_x) + r_n,$$

where $r_n = o(h) + O_P\left(\sqrt{\log n/(nh)}\right)$ uniformly over τ , x and h . Hence,

$$\begin{aligned}
s_x(\tau_x) - s_x(\widehat{\tau}_{x,h}) &\leq \widehat{s}_{x,h}(\widehat{\tau}_{x,h}) - s_x(\widehat{\tau}_{x,h}) - r_n \\
&\leq |\widehat{s}_{x,h}(\widehat{\tau}_{x,h}) - s_x(\widehat{\tau}_{x,h})| + |r_n| \\
&\leq \sup_{\tau,x,h} |\widehat{s}_{x,h}(\tau) - s_x(\tau)| + \sup_{\tau,x,h} |r_n| \\
&= o(h) + O_P\left(\sqrt{\log n/(nh)}\right)
\end{aligned} \tag{23}$$

where the last equality follows again by Lemma 2.

Now, notice that compactness of \mathcal{X} , together with Assumptions A2, A6 and A7, ensure there exists an $x \in \mathcal{X}$ such that

$$\sup_{x \in \mathcal{X}} \sup_{\tau: |\tau - \tau_x| \geq \epsilon} s_x(\tau) - s_x(\tau_x) = \sup_{\tau: |\tau - \tau_x| \geq \epsilon} s_x(\tau) - s_x(\tau_x) < 0$$

In view of this and using A6 once more, the following holds: for each $\epsilon > 0$ there exists an $\eta > 0$ such that the bound

$$s_x(\tau) \leq s_x(\tau_x) - \eta$$

holds for all x in the support of X and all τ with $|\tau - \tau_x| \geq \epsilon$.

Using compactness of $\mathcal{X} \times [\underline{h}_n, \bar{h}_n]$ and letting (x, h) attain the supremum $\sup_{x,h} |\widehat{\tau}_{x,h} - \tau_x|$ over $\mathcal{X} \times [\underline{h}_n, \bar{h}_n]$, we have

$$\{|\widehat{\tau}_{x,h} - \tau_x| \geq \epsilon\} \subseteq \{s_x(\tau_x) - s_x(\widehat{\tau}_{x,h}) \geq \eta\} \subseteq \{\sup_{x,h} s_x(\tau_x) - s_x(\widehat{\tau}_{x,h}) \geq \eta\}.$$

Thus, for any $\epsilon > 0$,

$$\mathbb{P}\{\sup_{x,h} |\widehat{\tau}_{x,h} - \tau_x| \geq \epsilon\} \leq \mathbb{P}\{\sup_{x,h} s_x(\tau_x) - s_x(\widehat{\tau}_{x,h}) \geq \eta\} \rightarrow 0$$

in view of (23).

Part 2 (T1) Recall the equations (13) and (15) with $D(\tau)$ and $\widehat{D}_h(\tau)$ defined as in (14) and (16). The first derivative of $s_x(\tau)$ is as:

$$s_x^{(1)}(\tau) := \frac{\partial s_x(\tau)}{\partial \tau} = x^\top \left[[D(\tau)]^{-1} D^{(1)}(\tau) [D(\tau)]^{-1} \mathbb{E}X \right]$$

with $D^{(1)}(\tau)$ defined as $\partial D(\tau)/\partial \tau = \mathbb{E}[X X^\top f^{(1)}(X^\top \beta(\tau)|X) \cdot X^\top [D(\tau)]^{-1} \mathbb{E}X]$; the derivation of $D^{(1)}(\tau)$ is found in Appendix A.2, equation (34).

The first order condition $s_x^{(1)}(\tau_x) = 0$ and its sample analog, $\widehat{s}^{(1)}(\widehat{\tau}_{x,h}) = 0$ yield:

$$\begin{aligned}
x^\top [D(\tau_x)]^{-1} D^{(1)}(\tau_x) [D(\tau_x)]^{-1} \mathbb{E}X &= 0 \\
x^\top [\widehat{D}_h(\widehat{\tau}_{x,h})]^{-1} \widehat{D}^{(1)}(\widehat{\tau}_{x,h}) [D(\widehat{\tau}_{x,h})]^{-1} \bar{X} &= 0
\end{aligned}$$

Now, by a Taylor expansion with Lagrange remainder, we have

$$s_x(\widehat{\tau}_{x,h}) = s_x(\tau_x) + s_x^{(1)}(\tau_x)[\widehat{\tau}_{x,h} - \tau_x] + \frac{1}{2}s_x^{(2)}(\tau_x^*)[\widehat{\tau}_{x,h} - \tau_x]^2$$

with τ_x^* as a point between $\widehat{\tau}_{x,h}$ and τ_x . Assumptions A2, A6, and A7 ensure that $\tau \mapsto s_x(\tau)$ is strictly convex in a vicinity of τ_x , so $\inf_{\tau} s^{(2)}(\tau) > 0$ in such a vicinity.

Applying the first-order condition $s_x(\tau_x) = 0$, we can rewrite the expansion as:

$$s_x(\widehat{\tau}_{x,h}) = s_x(\tau_x) + \frac{1}{2}s_x^{(2)}(\tau_x^*)[\widehat{\tau}_{x,h} - \tau_x]^2, \quad (24)$$

which leads to

$$|\widehat{\tau}_{x,h} - \tau_x| = \sqrt{2} \sqrt{\frac{|s_x(\widehat{\tau}_{x,h}) - s_x(\tau_x)|}{|s_x^{(2)}(\tau_x^*)|}} = \sqrt{\frac{o(h) + O_P(\sqrt{\log n/(nh)})}{O_P(1)}}$$

Using $\sqrt{a+b} \leq \sqrt{a} + \sqrt{b}$, it yields our rate of convergence for $\widehat{\tau}_{x,h}$:

$$|\widehat{\tau}_{x,h} - \tau_x| = o(h^{1/2}) + O_P\left(\frac{\log n}{nh}\right)^{1/4} \quad (25)$$

as stated. ■

Now that the consistency for the quantile modes is proved and the rates of convergence are defined, we proceed to state the consistency for the estimator of the mode, $\widehat{m}_h(x)$. Our second theorem is constructed using previous results from this paper and from [Fernandes, Guerre, and Horta \(2021\)](#).

Theorem 2. If Assumptions A1 to A7 hold, then

$$\widehat{m}_h(x) = m(x) + o(h^{1/2}) + O_P\left(\frac{\log n}{nh}\right)^{1/4} \quad (26)$$

uniformly for $x \in \mathcal{X}$ and $h \in [\underline{h}_n, \bar{h}_n]$.

Proof. From Theorem 1 we know that $\widehat{\tau}_{x,h} \xrightarrow{p} \tau_x$ at a rate of $o(h^{1/2}) + O_P(\log n/nh)^{1/4}$. Also, from Theorems 1 and 2 in [Fernandes, Guerre, and Horta \(2021\)](#) we have:

$$\|\widehat{\beta}_h(\tau) - \beta(\tau)\| = O_P\left(\frac{1}{\sqrt{n}} + h^2\right) \quad (27)$$

Recalling that

$$m(x) = x^\top \beta(\tau_x) \quad \text{and} \quad \widehat{m}_h(x) = x^\top \widehat{\beta}_h(\widehat{\tau}_{x,h})$$

we obtain

$$\begin{aligned} |\widehat{m}_h(x) - m(x)| &= \left| x^\top \widehat{\beta}_h(\widehat{\tau}_{x,h}) - x^\top \beta(\tau_x) \right| \\ &= \left| x^\top (\widehat{\beta}_h(\widehat{\tau}_{x,h}) - \beta(\tau_x)) \right| \leq \|x\| \cdot \|\widehat{\beta}_h(\widehat{\tau}_{x,h}) - \beta(\tau_x)\|. \end{aligned} \quad (28)$$

Given the differentiability condition (A2), we have that $\beta(\tau)$ is Lipschitz-continuous, thus, for some constant $C > 0$, we have

$$\begin{aligned} \|\widehat{\beta}_h(\widehat{\tau}_{x,h}) - \beta(\tau_x)\| &\leq \|\widehat{\beta}_h(\widehat{\tau}_{x,h}) - \beta(\widehat{\tau}_{x,h})\| + \|\beta(\widehat{\tau}_{x,h}) - \beta(\tau_x)\| \\ &\leq (\sup_\tau \|\widehat{\beta}_h(\tau) - \beta(\tau)\|) + C\|\widehat{\tau}_{x,h} - \tau_x\| \\ &\leq O_p\left(\frac{1}{\sqrt{n}} + h^2\right) + C\left[o(h^{1/2}) + O_p\left(\frac{\log n}{nh}\right)^{1/4}\right], \end{aligned} \quad (29)$$

which yields (26). ■

Remark 1. Denote our rate of convergence from Theorem 2 as R_{CMR} and the rate from the estimator proposed by Zhang, Kato, and Ruppert (2023) as R_{ZKR} ,

$$\begin{aligned} R_{CMR} &= O_p\left(n^{-1/4}h^{-1/4}(\log n)^{1/4}\right) + o(h^{1/2}) \\ R_{ZKR} &= O_p\left(n^{-1/2}h^{-3/2}(\log n)^{1/2} + h^2\right) \end{aligned} \quad (30)$$

Neither rate is dimension dependable, thus free from the ‘‘curse of dimensionality’’; under certain conditions on h , our rate, R_{CMR} , is marginally slower than R_{ZKR} . Apart from the presence of the deterministic term, both rates are similar, and the difference lies on the selection of the bandwidth parameter, h . Given a certain bandwidth, R_{ZKR} can achieve, at best, a rate of $(n \log n)^{-2/7}$, similar to the rate of Kemp and Santos-Silva (2012) and faster than the rate in Ota, Kato, and Hara (2019). Despite the differences in convergence rates, we attain uniformity with respect to design points of the covariates and the bandwidth.

Remark 2. Rewrite R_{ZKR} in (30) as

$$O_p\left(\left[\frac{\log n}{nh^3}\right]^{1/2} + h^2\right). \quad (31)$$

The ratio

$$\frac{(\log n/(nh))^{1/4}}{(\log n/(nh^3))^{1/2}} = \frac{nh^5}{\log n} \quad (32)$$

diverges to infinity under Assumption (viii) in Zhang, Kato, and Ruppert (2023), so under this assumption our estimator cannot achieve O_p rates faster than theirs. Nevertheless, under our weaker Assumption A5, we can make (32) go to zero, for example by taking $h = (n/\log n)^{-1/5}b$ with $b \rightarrow 0$ and $b^3(n/\log n)^{-2/5} \rightarrow \infty$. However, this particular choice for the bandwidth is not contemplated due to Zhang, Kato, and Ruppert’s (2023)

assumptions, but is enabled by condition A5.

Remark 3. Importantly, our estimator $\widehat{m}_h(x)$ attains the rate in Theorem 2 uniformly both in x and h ; on the other hand, the representation in Proposition 1 of Zhang, Kato, and Ruppert (2023) is not uniform for the bandwidth. Obtaining uniformity in h can be useful for 3 types of bandwidth choices: (i) data-driven bandwidth choices, as in Fernandes, Guerre, and Horta (2021); (ii) adaptive bandwidth choices, such as the ones of Terrell and Scott (1992); Lepski et al. (1997); and (iii) choices robust to bandwidth-snooping, as in Armstrong and Kolesár (2018).

4 Concluding Remarks

In the present paper we developed a novel estimator for the conditional mode $\widehat{m}_h(x)$, called *Convolution Mode Regression*, based on inverting the smoothed quantile regression of Fernandes, Guerre, and Horta (2021). The idea of achieving the conditional mode via quantile regression is not groundbreaking, since it has been done previously (Ota, Kato, and Hara, 2019; Zhang, Kato, and Ruppert, 2023). Despite that, it presents advantages regarding the two main problems with mode regression, slow convergence in nonparametric settings and nonconvex optimization in linear environments. Our estimation strategy relies on an intermediate step in which, in order to estimate $\widehat{m}_h(x)$, we need to firstly estimate the conditional quantile function $Q(\cdot|x)$, and then the conditional quantile mode of Y given $X = x$, denoted τ_x . Thus, the mode estimation relies on estimating $Q(\cdot|x)$ and τ_x first.

Differently from the existing work of Zhang, Kato, and Ruppert (2023), who initially estimate the quantile regression then smooth it through a kernel, our approach relies on “smooth then estimate”. We develop asymptotic consistency for our estimator, obtaining convergence rates similar to the ones of the estimator of Zhang, Kato, and Ruppert (2023), which, in the majority of cases, had a marginally faster rate. Apart from the initial smoothing, the main differentiation of our model from the authors’ is in the bandwidth selection premise, since our assumption for the choice of h is less restrictive, without sacrificing significantly in terms of convergence rates. Furthermore, the uniformity $\widehat{m}_h(x)$ with respect to h makes our model an interesting choice when the bandwidth selection is data-driven or adaptive.

Further work related to present research can take many directions. In what we assess as more important, the continuation of the asymptotic properties, namely, the limiting distributions of the estimator. Furthermore, simulations similar to those Ongaratto and Horta (2021) did, comparing to the Ota, Kato, and Hara (2019) estimator, may be updated in order to evaluate the performance of the estimator against Zhang, Kato, and Ruppert’s (2023). Comparisons with previous mode regression papers’ econometric applications can be carried out, centered on assessing estimator performance. In accordance to that, a generalization of the present framework focused on time series can be done,

with the interest in forecasting models for asymmetric data.

A Appendix

A.1 First and Second Derivatives of $\widehat{R}_h(b; \tau)$

From [Fernandes, Guerre, and Horta \(2021\)](#), the first and second derivatives of the smoothed sample objective function, $\widehat{R}_h(b; \tau)$, with respect to b , are, respectively:

$$\begin{aligned}\widehat{R}_h^{(1)}(b; \tau) &= \frac{1}{n} \sum_{i=1}^n X_i \left[K \left(\frac{X_i^\top b - Y_i}{h} \right) - \tau \right] \\ \widehat{R}_h^{(2)}(b; \tau) &= \frac{1}{n} \sum_{i=1}^n X_i X_i^\top k_h(X_i^\top b - Y_i)\end{aligned}\tag{33}$$

with $K(t) := \int_{-\infty}^t k(v)dv$.

A.2 Derivation of $D^{(1)}(\tau)$

Recalling the definition of $D(\tau)$:

$$D(\tau) := R^{(2)}(\beta(\tau); \tau) = \mathbb{E}[XX^\top f(X^\top \beta(\tau)|X)]$$

The first order differentiation is expressed as:

$$\begin{aligned}D^{(1)}(\tau) &:= \frac{\partial}{\partial \tau} \mathbb{E}[XX^\top f(X^\top \beta(\tau)|X)] \\ &= \mathbb{E}[XX^\top f^{(1)}(X^\top \beta(\tau)|X) \cdot X^\top \beta^{(1)}(\tau)] \\ &= \mathbb{E}[XX^\top f^{(1)}(X^\top \beta(\tau)|X) \cdot X^\top [D(\tau)]^{-1} \mathbb{E}X] \\ D^{(1)}(\tau) &= \mathbb{E} \left[XX^\top f^{(1)}(X^\top \beta(\tau)|X) \cdot X^\top \left\{ \mathbb{E}[XX^\top f(X^\top \beta(\tau)|X)] \right\}^{-1} \mathbb{E}X \right]\end{aligned}\tag{34}$$

A.3 Derivation of $s_x(\tau)$

Recalling the definition of the population sparsity function:

$$s_x(\tau) = -\frac{\partial}{\partial \tau} x^\top \beta(\tau) = -x^\top \underbrace{[D(\tau)]^{-1} \mathbb{E}X}_{\beta^{(1)}(\tau)}$$

To calculate the first derivative of $s_x(\tau)$, we use the definition of $\beta(\tau)$ as in the previous equation:

$$s_x^{(1)}(\tau) := \frac{\partial s_x(\tau)}{\partial \tau} = \frac{\partial}{\partial \tau} -x^\top \beta^{(1)}(\tau) = -x^\top \beta^{(2)}(\tau)\tag{35}$$

Now, computing $\beta^{(2)}(\tau)$:

$$\begin{aligned}
\beta^{(2)}(\tau) &:= \frac{\partial \beta^{(1)}(\tau)}{\partial \tau} = \frac{\partial}{\partial \tau} [D(\tau)]^{-1} \mathbb{E}X \\
&= -D^{(1)}(\tau) [D(\tau)]^{-2} \mathbb{E}X \\
&= -D^{(1)}(\tau) [D(\tau)]^{-1} \beta^{(1)}(\tau) \\
&= -[D(\tau)]^{-1} D^{(1)}(\tau) [D(\tau)]^{-1} \mathbb{E}X
\end{aligned} \tag{36}$$

Applying the result in (36) to equation (35) we get $s_x^{(1)}(\tau)$:

$$s_x^{(1)}(\tau) = x^\top \left[[D(\tau)]^{-1} D^{(1)}(\tau) [D(\tau)]^{-1} \mathbb{E}X \right] \tag{37}$$

with $D^{(1)}(\tau)$ defined as in equation (34).

The second derivative of $s_x(\tau)$ is required in the Taylor Expansion (24), so we compute $s^{(2)}(\tau)$ as follows:

$$\begin{aligned}
s^{(2)}(\tau) &:= \frac{\partial s^{(1)}(\tau)}{\partial \tau} = \frac{\partial}{\partial \tau} x^\top [D(\tau)]^{-1} D^{(1)}(\tau) [D(\tau)]^{-1} \mathbb{E}X \\
s^{(2)}(\tau) &= x^\top \left[\left([D(\tau)]^{-1} D^{(2)} - 2[D^{(1)}(\tau)]^2 \right) [D(\tau)]^{-3} \right] \mathbb{E}X
\end{aligned} \tag{38}$$

References

- Armstrong, T. and M. Kolesár (2018). A simple adjustment for bandwidth snooping. *Review of Economic Studies* 85, 732–765.
- Bassett, G. and R. Koenker (1982). An empirical quantile function for linear models with iid errors. *Journal of the American Statistical Association* 77(378), 407–415.
- Chacón, J. E. (2020). The modal age of statistics. *International Statistical Review* 88(1), 122–141.
- Chen, Y.-C. (2018). Modal regression using kernel density estimation: A review. *Wiley Interdisciplinary Review: Computational Statistics* 10(4).
- Chen, Y.-C., C. Genovese, R. Tibishirani, and L. Wasserman (2016). Nonparametric modal regression. *The Annals of Statistics* 44(2), 489–514.
- Chernoff, H. (1964). Estimation of the mode. *Annals of the Institute of Statistical Mathematics* 16, 31–41.
- Einbeck, J. and G. Tutz (2006). Modelling beyond regression functions: an application of multimodal regression to speed–flow data. *Applied Statistics* 55(4), 461–475.
- Feng, Y., J. Fan, and J. Suykens (2020). A statistical learning approach to modal regression. *Journal of Machine Learning Research* 21(2), 1–35.

- Fernandes, M., E. Guerre, and E. Horta (2021). Smoothing quantile regressions. *Journal of Business & Economic Statistics* 39(1), 338 – 357.
- Kemp, G. and J. Santos-Silva (2012). Regression towards the mode. *Journal of Econometrics* 170(1), 92–101.
- Kemp, G. C. R., P. M. D. C. Parente, and J. M. C. Santos-Silva (2020). Dynamic vector mode regression. *Journal of Business & Economic Statistics* 38(3), 647–661.
- Koenker, R. (2005). *Quantile Regression*. Cambridge University Press.
- Koenker, R. and G. Bassett (1978). Regression quantiles. *Econometrica* 46(1), 33–50.
- Lee, M.-J. (1989). Mode regression. *Journal of Econometrics* 42(3), 337–349.
- Lee, M.-J. (1993). Quadratic mode regression. *Journal of Econometrics* 57, 1–19.
- Lepski, O. V., E. Mammen, and V. G. Spokoiny (1997). Optimal spatial adaptation to inhomogeneous smoothness: an approach based on kernel estimates with variable bandwidth selectors. *The Annals of Statistics* 25(3), 929–947.
- Liu, J., R. Zhanga, W. Zhaoa, and Y. Lv (2013). A robust and efficient estimation method for single index models. *Journal of Multivariate Analysis* 122, 226–238.
- Matzner-Løfber, E., A. Gannoun, and J. G. D. Gooijer (1998). Nonparametric forecasting: a comparison of three kernel-based methods. *Communications in Statistics - Theory and Methods* 27(7), 1593–1617.
- Nadaraya, E. A. (1964). Some new estimates for distribution functions. *Theory of Probability & Its Applications* 9(3), 497–500.
- Newey, W. and D. McFadden (1994). Large sample estimation and hypothesis testing. In *Handbook of Econometrics (Vol. 4)*. Elsevier.
- Ongaratto, A. and E. Horta (2021). Conditional mode: An approach via smoothed quantile regression. Master’s thesis, Federal University of Rio Grande do Sul (UFRGS), <https://lume.ufrgs.br/handle/10183/237727>.
- Ota, H., K. Kato, and S. Hara (2019). Quantile regression approach to conditional mode estimation. *Electronic Journal of Statistics* 13(2), 3120–3160.
- Parzen, E. (1962). On estimation of a probability density function and mode. *The Annals of Mathematical Statistics* 33(3), 1065–1076.
- Parzen, E. (1979). Nonparametric statistical data modeling. *Journal of the American Statistical Association* 74(365), 105–121.
- Sager, T. (1978). Estimation of a multivariate mode. *The Annals of Statistics* 6(4), 802–812.

- Sager, T. W. and R. A. Thisted (1982). Maximum likelihood estimation of isotonic modal regression. *The Annals of Statistics* 10(3), 690–707.
- Scott, D. W. (1992). *Multivariate Density Estimation: Theory, practice and Visualization*. John Wiley & Sons.
- Terrell, G. and D. Scott (1992). Variable kernel density estimation. *The Annals of Statistics* 20(3), 1236–1265.
- Ullah, A., T. Wang, and W. Yao (2021). Modal regression for fixed effects panel data. *Empirical Economics* 60, 261–308.
- van der Vaart, A. (1998). *Asymptotic Statistics*. Cambridge University Press.
- Wang, T. (2024). Non-parametric estimator for conditional mode with parametric features. *Oxford Bulletin of Economics and Statistics* 86(1), 44–73.
- Wang, X., H. Chen, W. Cai, D. Shen, and H. Huang (2017). Regularized modal regression with applications in cognitive impairment prediction. *Advances in Neural Information Processing Systems 30 (NIPS 2017)*.
- Yao, W. and L. Li (2014). A new regression model: Modal linear regression. *Scandinavian Journal of Statistics* 41, 656–671.
- Yao, W., B. G. Lindsay, and R. Li (2012). Local mode regression. *Journal of Nonparametric Statistics* 24(3), 647–663.
- Yu, K. and K. Aristodemou (2012). Bayesian mode regression. *arXiv*.
- Zhang, R., W. Zhao, and J. Liu (2013). Robust estimation and variable selection for semiparametric partially linear varying coefficient model based on modal regression. *Journal of Nonparametric Statistics* 25(2), 523–544.
- Zhang, T., K. Kato, and D. Ruppert (2023). Bootstrap inference for quantile-based modal regression. *Journal of the American Statistical Association* 118(541), 122–134.