



Universidade Federal da Paraíba
Centro de Informática
Programa de Pós-Graduação em Modelagem Matemática e Computacional

UMA COMPARAÇÃO DAS DISTRIBUIÇÕES INFLACIONADAS PARA MODELAR
DADOS DUPLAMENTE LIMITADOS

ISAAC FERREIRA DE LIMA

Dissertação de Mestrado

João Pessoa

Maio de 2024

Universidade Federal da Paraíba
Centro de Informática
Programa de Pós-Graduação em Modelagem Matemática e Computacional

ISAAC FERREIRA DE LIMA

UMA COMPARAÇÃO DAS DISTRIBUIÇÕES INFLACIONADAS PARA MODELAR
DADOS DUPLAMENTE LIMITADOS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Modelagem Matemática e Computacional, UFPB, da Universidade Federal da Paraíba, como parte dos requisitos necessários à obtenção do título de Mestre em Modelagem Matemática e Computacional.

Orientadoras: Tatiene Correia de Souza

Tarciana Liberal Pereira de Araújo

João Pessoa

Maio de 2024

Catálogo na publicação
Seção de Catalogação e Classificação

L732c Lima, Isaac Ferreira de.

Uma comparação das distribuições inflacionadas para modelar dados duplamente limitados / Isaac Ferreira de Lima. - João Pessoa, 2024.

336 f. : il.

Orientação: Tatine Correia de Souza.

Coorientação: Tarciana Liberal Pereira de Araújo.

Dissertação (Mestrado) - UFPB/CI.

1. Matemática computacional. 2. Distribuições inflacionadas. 3. Distribuição beta. 4. Distribuição kumaraswamy. 5. Distribuição gama unitária. I. Souza, Tatine Correia de. II. Araújo, Tarciana Liberal Pereira de. III. Título.

UFPB/BC

CDU 519.6(043)

Ata da Sessão Pública de Defesa de Dissertação de
Mestrado de **ISAAC FERREIRA DE LIMA**, candidato
ao título de Mestre em Modelagem Matemática e
Computacional, realizada no dia 31 de maio de 2024.

1 Aos trinta e um dias do mês de maio do ano de dois mil e vinte e quatro, às 09h30, via
2 videoconferência, reuniram-se os membros da Banca Examinadora constituída para julgar o
3 Trabalho Final do discente ISAAC FERREIRA DE LIMA, vinculado a Universidade Federal
4 da Paraíba sob a matrícula nº 20221002621, candidato ao grau de Mestre em “*Modelagem*
5 *Matemática e Computacional*”, na linha de pesquisa “*Modelagem Probabilística*”, do
6 Programa de Pós-Graduação em Modelagem Matemática e Computacional. A comissão
7 examinadora foi composta pelos professores Tatiene Correia de Souza, Orientadora e
8 Presidente da Banca; Tarciana Liberal Pereira de Araújo, Coorientadora;
9 Sérgio de Carvalho Bezerra, Examinador Interno ao Programa; e Ana Hermínia Andrade e
10 Silva, Examinadora Externa ao Programa. Dando início aos trabalhos, a Presidente da Banca
11 cumprimentou os presentes, comunicou a finalidade da reunião e passou a palavra ao
12 candidato para que fizesse, oralmente, a exposição do trabalho de dissertação intitulado “*UMA*
13 *COMPARAÇÃO DAS DISTRIBUIÇÕES INFLACIONADAS PARA MODELAR DADOS*
14 *DUPLAMENTE LIMITADOS*”. Concluída a exposição, o candidato foi arguido pela Banca
15 Examinadora, que emitiu o seguinte parecer: “**aprovado**”. Do ocorrido, eu, Gean Paulo P. M.
16 de Barros, secretário do Programa de Pós-Graduação em Modelagem Matemática e
17 Computacional (PPGMMC), lavrei a presente ata, que vai assinada por mim e pelos membros
18 da Banca Examinadora.

João Pessoa, 31 de maio de 2024.

Gean Paulo Pereira Maurício de Barros
Secretário do PPGMMC
SIAPE 2326476

Prof^ª. Dr^ª. Tatiene Correia de Souza
Orientadora (PPGMMC)

Prof^ª. Dr^ª. Tarciana Liberal Pereira de Araujo
Coorientadora (PPGMMC)

Prof. Dr. Sérgio de Carvalho Bezerra
Examinador Interno ao Programa (PPGMMC)

Prof^ª. Dr^ª. Ana Hermínia Andrade e Silva
Examinadora Externa ao Programa (UFPB)

*Dedico este trabalho a todos
aqueles que torcem pelo meu
crescimento profissional, que me
apoiam e ajudam.*

Agradecimentos

Agradeço a Deus por todas as bênçãos concedidas na minha vida.

À minha família, em especial, aos meus pais e meu irmão, por serem inspiração de força e dedicação. Por não medirem esforços para me apoiar e incentivar. Obrigado por tudo.

Às minhas orientadoras, professora Tatiane Correia e Tarciana Liberal, por toda orientação, competência e amizade ao longo desse tempo. Obrigado por todo conhecimento transmitido e direcionamento para a conclusão desta dissertação.

Aos amigos que fiz ao longo do curso, obrigado pelos momentos de descontração e partilha de conhecimento. Em especial, Valter, Franklin, Kleby, Valdemi, Anderson, Adriana e Eduarda, pela amizade e troca de experiências. Foi muito gratificante conviver com vocês.

Agradeço à banca examinadora, antecipadamente, pelas contribuições dadas para a melhoria deste trabalho desde a qualificação. A todos os professores do Programa de Pós-graduação em Modelagem Matemática e Computacional, por contribuírem para minha formação acadêmica.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pelo apoio financeiro.

Por fim, em geral agradeço a todos aqueles que por algum motivo ou situação, compartilharam conhecimento e ajudaram para que eu pudesse desfrutar deste momento.

Resumo da Dissertação apresentada ao PPGMMC/CI/UFPB como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

UMA COMPARAÇÃO DAS DISTRIBUIÇÕES INFLACIONADAS PARA MODELAR DADOS DUPLAMENTE LIMITADOS

ISAAC FERREIRA DE LIMA

Maio/2024

Orientadores: Tatiene Correia de Souza

Tarciana Liberal Pereira de Araújo

Programa: Modelagem Matemática e Computacional

No contexto de dados duplamente limitados, as distribuições inflacionadas são muito utilizadas para casos em que os dados contenham excesso de zeros e/ou uns. Existem na literatura algumas distribuições para lidar com dados nesse domínio como, por exemplo: beta inflacionada (Ospina e Ferrari, 2010), kumaraswamy inflacionada (Cribari-Neto e Santos, 2019) e gama unitária inflacionada (Silva, 2023). Neste trabalho, iremos apresentar as distribuições de probabilidade mais utilizadas no contexto de modelagem de dados distribuídos no intervalo unitário padrão, mas que podem conter zeros e/ou uns e, a partir de um estudo detalhado, via simulação de Monte Carlo, identificar os cenários, de acordo com as características que são mais adequados para cada distribuição.

Abstract of Dissertation presented to PPGMMC/CI/UFPB as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

A COMPARISON OF INFLATED DISTRIBUTIONS FOR MODELING
DOUBLY BOUNDED DATA

ISAAC FERREIRA DE LIMA

May/2024

Advisors: Tatiene Correia de Souza
Tarciana Liberal Pereira de Araújo

Program: Computational Mathematical Modelling

In the context of doubly bounded data, inflated distributions are widely used for cases where the data contain an excess of zeros and/or ones. There are several distributions in the literature to handle data in this domain, such as inflated beta (Ospina and Ferrari, 2010), inflated Kumaraswamy (Cribari-Neto and Santos, 2019), and inflated unitary gamma (Silva, 2023). In this work, we will present the most commonly used probability distributions in the context of modeling data distributed in the standard unit interval, but which may contain zeros and/or ones. Through a detailed study, via Monte Carlo simulation, we will identify scenarios according to the characteristics that are most suitable for each distribution.

Sumário

Lista de Figuras	x
Lista de Tabelas	xi
1 Introdução	1
1.1 Organização da dissertação	2
2 Distribuições Inflacionadas no Intervalo Unitário Padrão	3
2.1 Distribuição beta inflacionada	3
2.1.1 Distribuição beta	3
2.1.2 Distribuição beta inflacionada em zero ou um	4
2.1.3 Distribuição beta inflacionada em zero e um	5
2.2 Distribuição gama unitária Inflacionada	6
2.2.1 Distribuição gama unitária	6
2.2.2 Distribuição gama unitária inflacionada	6
2.3 Distribuição kumaraswamy inflacionada	8
2.3.1 Distribuição kumaraswamy	8
2.3.2 Distribuição kumaraswamy inflacionada em zero ou um	9
2.3.3 Distribuição kumaraswamy inflacionada em zero e/ou um	10
2.4 Critérios de Seleção	10
2.4.1 Critério de Informação de Akaike	11
2.4.2 Critério de Informação Bayesiano	11
2.4.3 HQ	11
2.5 Teste de aderência	12
2.5.1 Kolmogorov-Smirnov	12
2.5.2 Anderson-Darling	12
2.5.3 Cramér-von Mises	13
3 Estudo de simulação	14
3.1 Resultados numéricos	14
3.1.1 Inflacionamento em zero	15
3.1.2 Inflacionamento em zero e um	19

3.1.3	Inflacionamento em um	24
4	Aplicações das Distribuições Inflacionadas	28
4.1	Introdução	28
4.2	Proporção de pessoas que usa internet	28
4.3	Proporção de nascidos vivos com 4000 gramas ou mais	30
4.4	Proporção de pacientes com tuberculose e HIV	33
4.5	Proporção da população urbana que residente em domicílios com rede de esgoto sanitário nos municípios do estado do Espírito Santo	35
4.6	Proporção de população urbana residente em domicílios ligados a rede de esgoto sanitário nos municípios do estado do Rio Grande do Norte	37
4.7	Proporção de votos para o candidato Jair Bolsonaro por seções elei- torais da cidade de Chaves-PA	39
4.8	Proporção de pessoas que residem em domicílios com acesso a energia elétrica	41
5	Conclusão	44
	Referências Bibliográficas	48
A		52
B		74
C		271

Lista de Figuras

4.1	Histograma da proporção de pessoas dos países que utilizaram internet em 209 países.	30
4.2	QQ-Plot da proporção de pessoas que utilizaram internet em 209 países.	30
4.3	Histograma da proporção de nascidos com 4000 gramas ou mais em 223 municípios.	32
4.4	QQ-Plot da proporção de nascidos vivos com 4000 gramas ou mais em 223 municípios.	32
4.5	Histograma da proporção de pacientes com tuberculose e HIV em 178 países.	34
4.6	QQ-Plot da proporção de pacientes com tuberculose e HIV em 178 países.	34
4.7	Histograma da proporção de pessoas que residem em domicílio com rede esgoto sanitário em 52 municípios.	36
4.8	QQ-Plot da proporção de pessoas que residem em domicílio com rede de esgoto sanitário em 52 municípios.	36
4.9	Histograma da proporção da população que residem em domicílio com rede esgoto sanitário em 55 municípios.	38
4.10	QQ-Plot da porcentagem da população que residem em domicílios com rede de esgoto sanitário em 55 municípios.	39
4.11	Histograma da proporção de votos para Bolsonaro em 53 seções eleitorais.	41
4.12	QQ-Plot da proporção de votos para Bolsonaro em 53 seções eleitorais.	41
4.13	Histograma da proporção de pessoas que residem em domicílio com acesso a energia elétrica em 293 municípios.	43
4.14	QQ-Plot da proporção de pessoas que residem em domicílio com acesso a energia elétrica em 293 municípios.	43

Lista de Tabelas

3.1	Cenários considerados.	15
3.2	Resultados da proporção de escolha dos critérios para dados gerados com média 0,3.	17
3.3	Resultados da proporção de escolha dos critérios para dados gerados com média 0,5.	18
3.4	Resultados da proporção de escolha dos critérios para dados gerados com média 0,3.	21
3.5	Resultados da proporção de escolha dos critérios para dados gerados com média 0,5.	22
3.6	Resultados da proporção de escolha dos critérios para dados gerados com média 0,8.	23
3.7	Resultados da proporção de escolha dos critérios para dados gerados com média 0,5.	26
3.8	Resultados da proporção de escolha dos critérios para dados gerados com média 0,8.	27
4.1	Medidas descritivas da proporção de pessoas que utilizaram internet.	29
4.2	p-valores dos testes de hipóteses.	29
4.3	Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - dados da proporção de pessoas utilizaram a internet em 209 países.	29
4.4	Medidas descritivas da proporção de nascidos vivos com 4000 gramas ou mais.	31
4.5	P-valores dos testes de hipóteses.	31
4.6	Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - dados da proporção de nascidos com 4000 gramas ou mais nos 223 municípios.	32
4.7	Medidas descritivas da proporção de pacientes com tuberculose e HIV.	33
4.8	P-valores dos testes de hipóteses.	33

4.9	Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de pacientes com tuberculose e HIV em 178 países.	34
4.10	Medidas descritivas da proporção de pessoas que residem em domicílios com rede de esgoto sanitário.	35
4.11	P-valores dos testes de hipóteses.	35
4.12	Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de pessoas que reside em domicílio com rede de esgoto sanitário em 52 municípios.	37
4.13	Medidas descritivas da proporção de pessoas que residem em domicílios com rede de esgoto sanitário.	37
4.14	P-valores dos testes de hipóteses	38
4.15	Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de pessoas que residem em domicílio com rede de esgoto sanitário em 55 municípios.	39
4.16	Medidas descritivas da proporção de votos para o candidato Jair Bolsonaro.	39
4.17	P-valores dos testes de hipóteses.	40
4.18	Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de votos para o candidato Jair Bolsonaro em 53 seções eleitorais.	40
4.19	Medidas descritivas da proporção de pessoas que residem em domicílios com acesso a energia elétrica.	42
4.20	P-valores dos testes de hipóteses.	42
4.21	Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de pessoas que reside em domicílios com acesso a energia elétrica por municípios do estado de Santa Catarina.	43
5.1	Melhores cenários e distribuições mais escolhidas de acordo com os critérios.	45
5.2	Melhores cenários e distribuições mais escolhidas de acordo com os testes de hipótese.	46
5.3	Resumo das aplicações.	47
A.1	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,3.	53
A.2	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	54

A.3	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,3.	55
A.4	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	56
A.5	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,3.	57
A.6	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	58
A.7	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,3.	59
A.8	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	60
A.9	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,8.	61
A.10	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,3.	62
A.11	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	63
A.12	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,8.	64
A.13	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,3.	65
A.14	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	66
A.15	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,8.	67
A.16	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	68
A.17	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,8.	69
A.18	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	70
A.19	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,8.	71
A.20	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,5.	72
A.21	Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0,8.	73

Capítulo 1

Introdução

áreas.

Em estudos recentes, novas classes de distribuições de probabilidade têm sido propostas buscando fornecer modelos mais adequados para dados no intervalo $(0,1)$. Grassia (1977) propôs a distribuição Gama unitária, Kumaraswamy (1980) propôs a distribuição kumaraswamy, Barndorff-Nielsen e Jørgensen (1991) introduziram a distribuição Simplex, Ferrari e Cribari-neto (2004) propuseram a distribuição beta, Mazucheli et al. (2018) propuseram a distribuição weibull unitária, etc.

Contudo, na presença de zeros e/ou uns, essas distribuições, que são absolutamente contínuas, não são mais adequadas. Para estes casos, faz-se necessário utilizar outra classe de distribuições chamada de distribuições inflacionadas, que são uma classe de modelos estatísticos usados para lidar com dados que possuem uma quantidade significativa de zeros e/ou uns. Essas distribuições são amplamente utilizadas em diversos campos, como epidemiologia, economia, ciências sociais, ecologia, entre outros.

Tong et al. (2013) utilizaram um modelo de distribuição gama com zeros ajustado para avaliar as perdas de empréstimos hipotecários em situações de inadimplência. Broek (1995) utilizou a distribuição Poisson inflacionada em zero para investigar o número de casos de infecção pelo HIV em homens. Nobre et al. (2017) utilizaram a distribuição gama com zeros ajustados para investigar o comportamento de indivíduos envolvidos em atividades físicas e determinar a quantidade de horas que dedicam ao treinamento diariamente.

Esses trabalhos apresentam vantagens em se usar cada distribuição abordada. Contudo, é de extrema importância identificar qual distribuição se adequa melhor a determinado conjunto de dados, seja pela sua natureza variabilidade ou proporção de zeros e/ou uns. Dessa forma, o objetivo dessa dissertação é, através de simulação de Monte Carlo, identificar padrões e características dos dados, distribuídos no intervalo unitário padrão mas que podem conter zeros e/ou uns para fornecer aos usuários cenários mais adequados para cada distribuição.

Dentre as distribuições inflacionadas que existem para modelar dados com excesso de zero e/ou uns serão abordadas, neste trabalho, as distribuições: beta inflacionada (Ospina e Ferrari, 2010), kumaraswamy inflacionada (Cribari-Neto e Santos, 2019) e gama unitária inflacionada (Silva, 2023). Essa comparação será realizada utilizando os critérios de informação (AIC, AICc, BIC, BICc, HQ e HQc) e testes de hipóteses: Kolmogorov–Smirnov, Anderson–Darling e Cramér–Von Mises.

1.1 Organização da dissertação

Em termos de estrutura, esta dissertação está dividida em quatro Capítulos, além da Introdução. No Capítulo 2, apresentamos as distribuições de probabilidade inflacionadas, abordadas nessa dissertação bem como os critérios de seleção e testes de hipóteses para comparar as distribuições. No Capítulo 3, apresentamos a avaliação numérica incluindo a descrição do método de Monte Carlo, o processo gerador dos dados e os resultados da avaliação computacional. No Capítulo 4, apresentamos aplicações das distribuições inflacionadas a dados reais. O Capítulo 5 apresenta as Conclusões deste trabalho.

Capítulo 2

Distribuições Inflacionadas no Intervalo Unitário Padrão

Neste Capítulo, apresentamos as distribuições de probabilidade contínuas no intervalo unitário padrão, abordadas nessa dissertação, bem como suas versões inflacionadas. Nas duas últimas seções deste Capítulo, são apresentados os critérios de informações e os testes de hipótese que serão úteis para comparação das distribuições inflacionadas, ou seja, verificar a adequabilidade das três distribuições aos dados.

2.1 Distribuição beta inflacionada

2.1.1 Distribuição beta

Seja Y uma variável aleatória que segue distribuição beta se sua densidade é dada por:

$$f(y; \mu, \phi) = \frac{\Gamma(\phi)}{\Gamma(\mu\phi)\Gamma((1-\mu)\phi)} y^{\mu\phi-1} (1-y)^{(1-\mu)\phi-1}, \quad y \in (0, 1), \quad (2.1)$$

em que $0 < \mu < 1$ e $\phi > 0$, em que a esperança e variância são dadas, respectivamente, por, $E(Y) = \mu$ e $\text{Var}(Y) = \mu(1-\mu)/(\phi+1)$. Essa parametrização da distribuição beta foi proposta por Ferrari e Cribari-Neto (2004). Dizemos que Y tem distribuição beta com média $\mu \in (0, 1)$, precisão ϕ e expressamos $Y \sim \mathcal{B}(\mu, \phi)$. Naturalmente, a partir da escolha de (μ, ϕ) , pode-se obter diferentes formas de densidades. Sendo assim, (2.1) pode formar uma classe de densidades beta.

A função de distribuição acumulada de Y , por sua vez, é:

$$F(Y) = \frac{\mathcal{B}_y(\mu, \phi)}{\mathcal{B}(\mu, \phi)},$$

para $0 < y < 1$, em que $\mathcal{B}_y(\mu, \phi)$ é a função beta incompleta e $\mathcal{B}(\mu, \phi)$ é a função beta, sendo expressas respectivamente por:

$$\mathcal{B}_y(\mu, \phi) = \int_0^y t^{\mu-1} (1-t)^{\phi-1} dt \quad \text{e} \quad \mathcal{B}(\mu, \phi) = \frac{\Gamma(\mu)\Gamma(\phi)}{\Gamma(\mu+\phi)}.$$

2.1.2 Distribuição beta inflacionada em zero ou um

Segundo Ospina e Ferreira (2010), em contextos reais, é possível encontrar dados representados por taxas, frações ou proporções que incluem zeros e/ou uns. Esses valores extremos podem estar relacionados a intervenções, truncamentos ou censura nos dados. Nesta situação, a distribuição beta não é mais adequada para representar tais dados.

Quando o conjunto de dados contém zeros e/ou uns (mas não ambos), uma abordagem natural seria incorporar à distribuição beta um ponto de massa em zero ou um. Sendo assim, pode-se obter modelos para frações observadas nos intervalos $[0, 1)$ ou $(0, 1]$.

A partir deste contexto, podemos supor que o componente contínuo dos dados pode ser modelado pela distribuição beta (2.1), pelo fato de que esta distribuição é bastante flexível e pode se ajustar aos dados no intervalo $(0, 1)$. Já o componente discreto, ou seja, o ponto de massa, será modelado por uma distribuição degenerada no valor conhecido c , em que c é igual a zero ou um, dependendo das características dos dados.

A função densidade de probabilidade de y com respeito à medida gerada pela mistura é expressa da seguinte forma:

$$bi_c(y; \alpha, \mu, \phi) = \begin{cases} \alpha, & \text{se } y = c \\ (1 - \alpha)f(y; \mu, \phi), & \text{se } y \in (0, 1), \end{cases} \quad (2.2)$$

em que $0 < \alpha, \mu < 1$ e $\phi > 0$, sendo $f(y; \mu, \phi)$ a função densidade (2.1). Observe que $\alpha = P(y = c)$ representa a probabilidade de se ter zero ($c = 0$) ou um ($c = 1$), de acordo com o cenário. A densidade (2.2) pode ser escrita da seguinte forma:

$$bi_c(y; \alpha, \mu, \phi) = \{\alpha^{1_{c(y)}}(1 - \alpha)^{1-1_{c(y)}}\}\{f(y; \mu, \phi)^{1-1_{c(y)}}\}.$$

Podemos ver que esta densidade, fatora em dois termos, em que o primeiro depende somente de α e o segundo depende somente de (μ, ϕ) . Se $c = 0$, a distribuição (2.2) é chamada de distribuição beta inflacionada no ponto zero e escrevermos $Y \sim BIZ(\alpha, \mu, \phi)$ e $\alpha = P(y = 0)$. Se $c = 1$, a distribuição (2.2) é chamada de distribuição beta inflacionada no ponto um e escrevermos $Y \sim BIU(\alpha, \mu, \phi)$ e $\alpha = P(y = 1)$. A média e a variância de uma variável aleatória com distribuição

beta inflacionada em zero ou um, são dadas por:

$$\begin{aligned} E(Y^r) &= \alpha c + (1 - \alpha)\mu_r, \\ Var(Y) &= (1 - \alpha)\frac{V(\mu)}{\phi + 1} + \alpha(1 - \alpha)(c - \mu)^2, \end{aligned}$$

em que $c = 0$ ou $c = 1$, indicando o inflacionamento em zero ou um, respectivamente, $V(\mu) = \mu(1 - \mu)$, μ_r é o r -ésimo momento ao redor de zero da distribuição $\mathcal{B}(\mu, \phi)$, dada em (2.1) e ϕ é interpretado como um parâmetro de precisão uma vez que a variância diminui, a medida que o parâmetro ϕ aumenta.

A função de distribuição acumulada é dada por

$$BI_c(y; \alpha, \mu, \phi) = \alpha \mathbf{1}_c(y) + (1 - \alpha)F(y; \mu, \phi),$$

em que $\mathbf{1}_A(y)$ é uma função indicadora, que assume valor 1 se $y \in A$ e 0 se $y \notin A$. A função $F(\cdot; \mu, \phi)$ é a função de distribuição acumulada beta $\mathcal{B}(\mu, \phi)$ e $0 < \alpha < 1$ trata-se do parâmetro de mistura.

2.1.3 Distribuição beta inflacionada em zero e um

De acordo com Ospina e Ferreira (2010), nas situações em que a variável está distribuída no intervalo $[0, 1]$, admite-se que as probabilidades de observar os valores zero e um são positivas. Para esse tipo de dado, faz-se necessário utilizar uma mistura entre uma distribuição beta e uma distribuição Bernoulli, a qual atribui probabilidades não-negativas aos inteiros 0 e 1. A distribuição beta cumpre a função de modelar o componente contínuo e a distribuição de Bernoulli adequa o componente discreto, ou seja, os pontos de massa em zero e um.

Seja Y uma variável aleatória que tem distribuição beta inflacionada em zero e um (BIZU), a função densidade com respeito à medida gerada pela mistura é dada por:

$$bizu(y; \alpha, \gamma, \mu, \phi) = \begin{cases} \alpha\gamma & \text{se } y = 1 \\ \alpha(1 - \gamma) & \text{se } y = 0 \\ (1 - \alpha)f(y; \mu, \phi) & \text{se } y \in (0, 1), \end{cases}$$

com $0 < \alpha, \gamma, \mu < 1$ sendo $f(y; \mu, \phi)$ a função densidade beta (2.1) e escrevemos $Y \sim BIZU(\alpha, \gamma, \mu, \phi)$.

Note que $P(Y = 1) = \alpha\gamma$, $P(Y = 0) = \alpha(1 - \gamma)$. Podemos calcular $E(Y^r)$ e

$\text{Var}(Y)$ da seguinte maneira:

$$\begin{aligned} E(Y^r) &= \alpha\gamma + (1 - \alpha)\mu_r, \\ \text{Var}(Y) &= \alpha\gamma(1 - \gamma) + (1 - \alpha)\frac{\mu(1 - \mu)}{(\phi + 1)} + \alpha(1 - \alpha)(\gamma - \mu)^2. \end{aligned}$$

A função de distribuição acumulada é dada por

$$BIZU(y; \alpha, \gamma, \mu, \phi) = \alpha Ber(y, \gamma) + (1 - \alpha)F(y; \mu, \phi),$$

em que $Ber(\cdot; \gamma)$ é a função de distribuição acumulada de uma variável aleatória de Bernoulli de parâmetro γ e $F(\cdot; \mu, \phi)$ é a função de distribuição acumulada de uma variável aleatória com distribuição beta $\mathcal{B}(\mu, \phi)$. Os parâmetros são $0 < \mu, \gamma, \alpha < 1$ e $\phi > 0$, em que o parâmetro de mistura α permite combinar de forma convexa as duas distribuições.

2.2 Distribuição gama unitária Inflacionada

2.2.1 Distribuição gama unitária

A distribuição gama unitária, proposta por Grassia (1977), é uma distribuição probabilística bastante presente na literatura e útil para modelar variáveis no intervalo $(0, 1)$. Uma variável aleatória Y segue a distribuição gama unitária quando sua função de densidade é representada por:

$$f(y; \mu, \phi) = \frac{\left(\frac{\mu^{1/\phi}}{1 - \mu^{1/\phi}}\right)^\phi}{\Gamma(\phi)} y^{\left(\frac{\mu^{1/\phi}}{1 - \mu^{1/\phi}} - 1\right)} \left[\log\left(\frac{1}{y}\right)\right]^{\phi-1}, \quad 0 < y, \mu < 1, \text{ e } \phi > 0. \quad (2.3)$$

A distribuição gama unitária é bastante flexível e, dependendo dos valores de seus parâmetros, pode assumir diversas formas. Tal distribuição é adequada para modelar variáveis que estejam no intervalo unitário padrão. Existem situações nas quais temos interesse em investigar variáveis que são limitadas aos intervalos $(0, 1]$, $[0, 1)$ ou até mesmo $[0, 1]$. Para estes casos, faz-se necessário o uso de distribuições inflacionadas.

2.2.2 Distribuição gama unitária inflacionada

A distribuição gama unitária inflacionada foi proposta por Silva (2023). Uma variável aleatória Y que segue a distribuição gama unitária inflacionada em zero e

um, $Y \sim GUI(\delta_0, \delta_1, \mu, \phi)$, pode ser expressa por:

$$f(y; \delta_0, \delta_1, \mu, \phi) = \begin{cases} \delta_0 & \text{se } y = 0 \\ (1 - \delta_0 - \delta_1)f(y; \mu, \phi) & \text{se } y \in (0, 1), \\ \delta_1 & \text{se } y = 1 \end{cases} \quad (2.4)$$

em que δ_0 denota probabilidade de y assumir o valor 0, δ_1 a probabilidade de y ser igual a 1, $f(y; \mu, \phi)$ é a função densidade da distribuição gama unitária apresentada em (2.3), $0 < \delta_0, \delta_1, \mu < 1$, $0 < \delta_0 + \delta_1 < 1$ e $\phi > 0$. A média e variância de uma variável aleatória $Y \sim GUI(\delta_0, \delta_1, \mu, \phi)$ são expressas por:

$$\begin{aligned} E(Y) &= \delta_1 + (1 - \delta_0 - \delta_1)\mu, \\ \text{Var}(Y) &= \delta_1(1 - \delta_1) + (1 - \delta_0 - \delta_1) [\text{Var}_{GU} - 2\mu\delta_1 + \mu^2(\delta_0 + \delta_1)], \end{aligned}$$

em que a Var_{GU} é a variância de uma variável aleatória, que segue a distribuição gama unitária,

$$\text{Var}_{GU} = \mu \left[\frac{1}{(2 - \mu^{1/\phi})^\phi} - \mu \right].$$

De forma semelhante ao trabalho de Bayes e Valdivieso (2016), Silva (2023) propôs reparametrizar a distribuição gama unitária inflacionada (2.4) com intuito de modelar a média da distribuição gama unitária inflacionada e não a média da distribuição gama unitária. Dessa forma o valor esperado de $Y \sim GUI(\delta_0, \delta_1, \mu, \phi)$, $\gamma = E(Y)$, depende de μ e é restrito para os valores δ_0 e δ_1 de acordo com

$$\delta_1 < \gamma < 1 - \delta_0.$$

Deste modo, para permitir que os parâmetros do modelo sejam estimados sem restrições, Silva (2023) sugeriu utilizar a seguinte parametrização:

$$\gamma = \delta_1 + (1 - \delta_0 - \delta_1)\mu, \quad \alpha_0 = \frac{\delta_0}{1 - \gamma} \quad \text{e} \quad \alpha_1 = \frac{\delta_1}{\gamma},$$

em que $0 < \alpha_0, \alpha_1, \gamma < 1$, $\phi > 0$ e $\delta_1 < \gamma < 1 - \delta_0$. Deste modo, considerando a nova parametrização tem-se que a densidade é dada por:

$$f(y; \alpha_0, \alpha_1, \gamma, \phi) = \begin{cases} \alpha_0(1 - \gamma) & \text{se } y = 0 \\ (1 - \alpha_0(1 - \gamma) - \alpha_1\gamma)f\left(y; \frac{\gamma(1 - \alpha_1)}{1 - \alpha_0(1 - \gamma) - \alpha_1\gamma}, \phi\right) & \text{se } y \in (0, 1) \\ \alpha_1\gamma & \text{se } y = 1. \end{cases} \quad (2.5)$$

Desta forma, a esperança e a variância da variável aleatória Y com distribuição

gama unitária inflacionada reparametrizada é dada por

$$E(Y) = \gamma,$$

$$\text{Var}(Y) = \alpha_1 \gamma (1 - \alpha_1 \gamma) + \gamma (1 - \alpha_1) \left[\left(2 - \left(\frac{\gamma (1 - \alpha_1)}{1 - \alpha_0 (1 - \gamma) - \alpha_1 \gamma} \right)^{1/\phi} \right)^{-\phi} - \gamma (1 - \alpha_1) \right].$$

Perceba que a expressão (2.5) é facilmente compreendida para casos em que a variável de interesse assume apenas um dos extremos, com $\delta_0 = 0$ e $\delta_1 > 0$ (distribuição inflacionada em 1), $\delta_0 > 0$ e $\delta_1 = 0$ (distribuição inflacionada em 0) ou $\delta_0 = \delta_1 = 0$ (distribuição Gama Unitária). Quando a distribuição é inflacionada em um, temos que $\gamma = \delta_1 + (1 - \delta_1)\mu$ e $\alpha_1 = \frac{\delta_1}{\gamma}$, já quando a distribuição é inflacionada em zero, temos que $\gamma = (1 - \delta_0)\mu$ e $\alpha_0 = \frac{\delta_0}{1 - \gamma}$. A função distribuição acumulada da variável aleatória $Y \sim GUI(\alpha_0, \alpha_1, \gamma, \phi)$ é dada por:

$$F(y; \alpha_0, \alpha_1, \gamma, \phi) = \begin{cases} 0, & \text{se } y < 0 \\ \alpha_0(1 - \gamma), & \text{se } y = 0 \\ \alpha_0(1 - \gamma) + \psi F\left(y \mid \frac{y(1 - \alpha_1)}{1 - \alpha_0(1 - \gamma) - \alpha_1 \gamma}, \phi\right), & \text{se } 0 < y < 1 \\ 1, & \text{se } y > 1, \end{cases}$$

em que $\psi = 1 - \alpha_0(1 - \gamma) - \alpha_1 \gamma$.

2.3 Distribuição kumaraswamy inflacionada

2.3.1 Distribuição kumaraswamy

A distribuição kumaraswamy foi proposta por Kumaraswamy (1976), e foi desenvolvida para ajustar dados delimitados por um limite superior e inferior. Mitnik e Baek (2013), propuseram uma parametrização baseada na mediana da distribuição kumaraswamy com suporte do intervalo unitário aberto (0,1). Seja Y uma variável aleatória segue a distribuição kumaraswamy, cuja notação é $Y \sim K(\omega, \phi)$, com função densidade de probabilidade (f.d.p) dada por:

$$f(y; \omega, \phi) = \frac{\phi \log(0.5)}{\log(1 - \omega^\phi)} y^{\phi-1} (1 - y^\phi)^{\frac{\phi \log(0.5)}{\log(1 - \omega^\phi)} - 1}, \quad (2.6)$$

em que $\omega \in (0, 1)$ é a mediana e $\phi > 0$ é o parâmetro de precisão. O valor esperado e a variância de $Y \sim K(\omega, \phi)$ são expressos por

$$E(Y) = \delta B\left(1 + \frac{1}{\phi}, \delta\right),$$

$$\text{Var}(Y) = \sigma^2 = \delta B\left(1 + \frac{2}{\phi}, \delta\right) - \left[\delta B\left(1 + \frac{1}{\phi}, \delta\right)\right]^2, \quad (2.7)$$

em que $\delta = \frac{\phi \log(0.5)}{\log(1-\omega^\phi)}$, $B(a, b) = \frac{\Gamma(a)\Gamma(b)}{\Gamma(a+b)}$ é a função beta e $\Gamma(x) = \int_0^\infty t^{x-1} e^{-t} dt$ é a função Gama. A função de distribuição acumulada (f.d.a) dada por:

$$F(y; \omega, \phi) = 1 - (1 - y^\phi)^{\frac{\phi \log(0.5)}{\log(1-\omega^\phi)}}.$$

2.3.2 Distribuição kumaraswamy inflacionada em zero ou um

A distribuição kumaraswamy inflacionada foi proposta por Cribari-Neto e Santos (2019). Quando os dados contêm observações em um dos extremos do intervalo unitário padrão (mas não em ambos simultaneamente) com probabilidade não nula, a distribuição kumaraswamy inflacionada em zero ou um é uma mistura de duas distribuições: uma distribuição $K(\omega, \phi)$ e uma distribuição degenerada no ponto c ($c = 0$ ou $c = 1$).

A função densidade de probabilidade de uma variável aleatória Y que segue distribuição kumaraswamy inflacionada em zero ou um, $Y \sim KI(y; \omega, \phi)$, pode ser expressa por:

$$ki_c(y; \gamma, \omega, \phi) = [\gamma^{\mathbb{I}_c(y)} (1 - \gamma)^{1 - \mathbb{I}_c(y)}] [f(y; \omega, \phi)^{1 - \mathbb{I}_c(y)}],$$

em que $0 < \gamma, \mu < 1$, $\gamma = P(Y = c)$, ω é a mediana e $\phi > 0$ é o parâmetros de precisão, $f(y; \omega, \phi)$, é a densidade expressa em (2.6).

A função de densidade acumulada inflacionada em c é dada por

$$KI_c(y; \gamma, \omega, \phi) = \gamma + (1 - \gamma)F(y; \omega, \phi),$$

em $0 < \gamma < 1$, $0 < \omega < 1$ é a mediana, $\phi > 0$ é o parâmetro de precisão e $F(y; \omega, \phi)$ é a distribuição acumulada da densidade $K(y; \omega, \phi)$.

A média e a variância da distribuição $Y \sim KI(\gamma, \omega, \phi)$ são dadas, respectivamente, por:

$$E(Y) = \gamma c + (1 - \gamma)\omega_K,$$

$$\text{Var}(Y) = (1 - \gamma)\sigma^2 + \gamma(1 - \gamma)(c - \omega_K)^2,$$

em que ω_K é o primeiro momento da distribuição kumaraswamy e σ^2 é variância da distribuição $K(\omega, \phi)$ dada pela expressão (2.7).

2.3.3 Distribuição kumaraswamy inflacionada em zero e/ou um

A distribuição da seção anterior não é adequada para modelar dados fracionários quando ocorre inflacionamento dos dados em ambos os extremos do intervalo unitário padrão. Bayer et al. (2021) fez uma reparametrização da distribuição proposta por Cribari-Neto e Santos (2019), baseado na mediana de Mitnik e Baek (2013). Dizemos que a variável aleatória Y segue a distribuição Kumaraswamy inflacionada em zero e/ou um, se sua função densidade de probabilidade de Y é dada por:

$$zok(y; \lambda, p, \omega, \phi) = \begin{cases} \lambda(1-p) & \text{se } y = 0 \\ \lambda p & \text{se } y = 1 \\ (1-\lambda)f(y; \omega, \phi) & \text{se } y \in (0, 1), \end{cases}$$

em que $0 < \lambda < 1$ é o parâmetro de mistura, p é a probabilidade de que uma variável aleatória de distribuída Bernoulli seja igual a um e $f(y; \omega, \phi)$ é a função densidade kumaraswamy dada em (2.6), que é indexada por $0 < \omega < 1$ (mediana) e $\phi > 0$ (parâmetro de precisão). Vale ressaltar que, quando $p = 0$, tem-se a distribuição kumaraswamy inflacionada em zero, e quando $p = 1$, tem-se a distribuição kumaraswamy inflacionada em um, como casos particulares.

A média e a variância da distribuição $Y \sim zok(y; \lambda, p, \omega, \phi)$ são dadas, respectivamente, por:

$$E(Y) = \lambda p + \phi(1-\lambda)\mathbb{B}\left(1 + \frac{1}{\omega}, \phi\right),$$

$$\text{Var}(Y) = \lambda p(1-\lambda p) + (1-\lambda)\phi \left\{ \mathbb{B}\left(1 + \frac{2}{\omega}, \phi\right) - \mathbb{B}\left(1 + \frac{1}{\omega}, \phi\right)^2 \right\},$$

em que $\Phi_1 = 2\lambda p + \phi(1-\lambda)\mathbb{B}\left(1 + \frac{1}{\omega}, \phi\right)$ e $\mathbb{B}(\cdot, \cdot)$ é a função beta.

2.4 Critérios de Seleção

Não há dúvidas de que, sob a perspectiva estatística, a seleção da distribuição mais apropriada para representar um fenômeno que está sendo estudado é uma etapa de extrema importância. Na literatura muitos autores utilizam os critérios de informação para comparar a adequabilidades das distribuições de probabilidades a certos conjuntos de dados, (MAZUCHELI; MENEZES; GHITANY, 2018; MAZUCHELI; MENEZES; DEY, 2019; BAPAT; BHARDWAJ, 2021).

Nos critérios que serão apresentados a seguir, serão utilizados os seguintes elementos: $l(\hat{\theta})$, k e n . Neste contexto, $l(\hat{\theta})$ representa a função de log-verossimilhança

maximizada, $\hat{\theta}$ denota o estimador de máxima verossimilhança do vetor θ , k indica a quantidade de parâmetros e n representa o número de observações.

2.4.1 Critério de Informação de Akaike

O critério de informação de Akaike (AIC) é o critério de seleção mais utilizado para seleção de modelos estatísticos. Foi proposto por Akaike (1973) a partir da minimização da informação de Kullback-Leibler. O AIC é expresso por:

$$\text{AIC} = -2l(\hat{\theta}) + 2k.$$

Com o propósito de melhorar a performance do AIC em casos de tamanho finito, Sugiura (1978) apresentou um estimador não-viesado para a distância de Kullback-Leibler em regressão linear, o AICc. Já Hurvich e Tsai (1989) expandiu o uso do AICc para modelos de regressão não-lineares e modelos autorregressivos, justificando que o mesmo apresenta desempenho superior ao AIC em pequenas amostras. O AICc é definido como:

$$\text{AICc} = -2l(\hat{\theta}) + \frac{2nk}{n - k - 1}.$$

2.4.2 Critério de Informação Bayesiano

Considerando uma perspectiva bayesiana, há o critério de informação BIC proposto por Schwarz (1978). O BIC é definido como:

$$\text{BIC} = -2l(\hat{\theta}) + k\log(n).$$

De acordo com McQuarrie (1999), a relação entre os critérios de informação de Akaike (AIC) e sua versão corrigida (AICc), serviu como fundamento para desenvolver uma correção para BIC em pequenas amostras. O BIC é assintoticamente consistente, e essa mesma propriedade se estende ao BICc que é dado por:

$$\text{BICc} = -2l(\hat{\theta}) + \frac{nk \log(n)}{n - k - 1}.$$

2.4.3 HQ

O critério HQ foi proposto por Hannan e Quinn (1979). E é dado por:

$$\text{HQ} = -2l(\hat{\theta}) + 2k \log(\log(n)).$$

Assim como o critério AIC e BIC, o critério HQ também tem sua versão corrigida para amostras finitas dada por:

$$\text{HQc} = -2l(\hat{\theta}) + \frac{2nk \log(\log(n))}{n - k - 1}.$$

2.5 Teste de aderência

Há diversas avaliações e métricas disponíveis para determinar se o modelo estimado é apropriado para fins de inferência estatística. Na literatura alguns autores utilizaram os testes de hipótese para comprar distribuições inflacionadas a certos conjuntos de dados (CRIBARI-NETO; SANTOS, 2019; CHAKRABORTY; BHATTACHARJEE, 2021). Testes de hipótese são utilizados para validar uma afirmação, frequentemente é referida como hipótese nula, (H_0). Quando se trata de avaliar a adequação, as hipóteses são:

$$\begin{cases} H_0 : \text{A amostra segue o modelo estipulado} \\ H_1 : \text{A amostra não segue o modelo estipulado} \end{cases}$$

2.5.1 Kolmogorov-Smirnov

Kolmogoroff (1941) e Smirnov (1939) são notáveis por sua contribuição fundamental na concepção do teste de Kolmogorov-Smirnov (KS). Este método foi desenvolvido com o objetivo de avaliar a disparidade entre distribuições empíricas e uma distribuição teórica postulada. A estatística do teste KS, aplicada a uma distribuição cumulativa teórica $F(x)$ específica, quantifica essa disparidade através da seguinte expressão:

$$KS_n = \sqrt{n} \sup_x |F_n(x) - F(x)|$$

em que $F(x)$ representa o valor teórico da distribuição acumulada em x , enquanto $F_n(x)$ é o valor empírico da distribuição acumulada com base em uma amostra de tamanho n . Se a estatística KS_n ultrapassar o valor crítico KS_α em um determinado nível de significância α , a hipótese nula, que pressupõe que $F_n(x)$ se origina da distribuição teórica $F(x)$, é rejeitada. Isso implica que uma faixa com uma altura KS_α é delimitada em ambos os lados da distribuição teórica, e se a distribuição empírica estiver fora dessa faixa em qualquer ponto, a hipótese nula é rejeitada.

2.5.2 Anderson-Darling

Anderson e Darling (1952) foram os pioneiros no desenvolvimento do teste de Anderson-Darling, apresentando-o como uma alternativa eficaz às outras análises

estatísticas convencionais para detecção de desvios nas distribuições de amostras em relação à normalidade. Similar ao teste de Komogorov-Smirnov, inicialmente sua aplicação estava centrada em contextos de engenharia. A estatística do teste de Anderson-Darling para uma única amostra é calculada conforme a seguinte fórmula:

$$AD = A(1 + \frac{0,75}{n} + \frac{2,25}{n^2}),$$

em que A é calculado a seguir:

$$A = -n - \frac{1}{n} \sum_{i=1}^n (2i-1)(\ln(p_{(i)}) + \ln(1 - (p_{(n+1-i)}))),$$

as quantidades $p(i)$ são percentis ordenados da distribuição e n é o tamanho amostral.

2.5.3 Cramér–von Mises

Este teste é baseado na distribuição acumulada e foi proposto por Darling (1957). A estatística do teste de Cramér-von Mises é calculada a partir da seguinte expressão:

$$CVM = W(1, 0 + \frac{0,5}{n}),$$

em que W é expressa por:

$$W = \frac{1}{12n} + \sum_{i=1}^n \left(p(i) - \frac{2i-1}{2n} \right)^2,$$

as quantidades $p(i)$ são os percentis ordenados da distribuição e n é o número de observações.

Capítulo 3

Estudo de simulação

Nesta seção são apresentados os resultados de uma simulação de Monte Carlo para comparar as distribuições de probabilidade inflacionadas. Para essas comparações, foram utilizados os critérios de seleção (AIC, AICc, BIC, BICc, HQ e HQc), mencionados na seção 2.4, bem como os testes de hipóteses: Kolmogorov–Smirnov, Anderson–Darling e Cramér–Von Mises.

As simulações foram realizadas utilizando o *software* R (R Core Team, 2024), versão R 4.3.3, disponível em <https://posit.co/download/rstudio-desktop/>. Os resultados foram baseados em 10.000 réplicas de Monte Carlo. Foram utilizado diversos pacotes do software R: `goeftest` (CSÖRGŐ; FARAWAY, 1996), `goeftest` (MARSAGLIA; MARSAGLIA, 2004), `gamlss` (RIGBY; STASINOPOULOS, 2005), `VGAM` (YEE, 2008), `MASS` (RIPLEY; ET. AL, 2013), `gamlss.dist` (RIGBY; et. al, 2019), `extraDistr` e (WOLODZKO; WOLODZKO, 2020). Os cenários foram estabelecidos levando em consideração as seguintes distribuições: beta inflacionada, kumaraswamy inflacionada e gama unitária inflacionada, com inflacionamento em um, zero ou zero e um.

Foram considerados os seguintes tamanhos amostrais: $n = 30, 60, 100$ e 200 . As amostras utilizadas nas simulações foram geradas a partir das distribuições beta inflacionada ($BI(0, 1]$, $BI[0, 1)$ e $BI[0, 1]$), kumaraswamy inflacionada ($KI(0, 1]$, $KI[0, 1)$ e $KI[0, 1]$) e gama unitária inflacionada ($GUI(0, 1]$, $GUI[0, 1)$ e $GUI[0, 1]$). Foram calculadas a média, proporção de inflacionamento, variância, proporção de vezes que uma das distribuições foi escolhida em relação aos critérios (AIC, AICc, BIC, BICc, HQ e HQc) e a proporção de não rejeição da hipótese nula H_0 : a amostra segue a distribuição testada, ao nível de significância de 5%.

3.1 Resultados numéricos

As simulação foram realizadas considerando nove cenários para cada distribuição, representados na Tabela 3.1.

Tabela 3.1: Cenários considerados.			
	Cenários	μ	inflacionamento
$\phi = 10; 30$	1	0,3	5%
	2		7%
	3		10%
$\phi = 10; 50$	4	0,5	5%
	5		7%
	6		10%
$\phi = 10; 50$	7	0,8	5%
	8		7%
	9		10%

Os resultados das simulações em relação aos critérios de escolha encontram-se nas Tabelas 3.2 a 3.8, em que 3.2 e 3.3 são para inflacionamento em zero, 3.4, 3.5 e 3.6 são para inflacionamento em zero e um, e 3.7 e 3.8 são para inflacionamento em um. Vale ressaltar que o modelo selecionado foi o mesmo considerando todos os critérios. Os resultados da proporção de vezes que os testes não rejeitaram a hipótese nula encontra-se no Apêndice A.

3.1.1 Inflacionamento em zero

Para os Cenários 1, 2, 3, 4, 5 e 6, quando os dados são gerados considerando a distribuição beta inflacionada(BI), de acordo com os critérios, foi escolhida a distribuição gama unitária inflacionada(GUI) com maior frequência. Percebeu-se que no cenário 6 (Tabela 3.3), com uma precisão maior ($\phi = 50$), os critérios indicaram a distribuição GUI 70% das vezes quando o tamanho da amostra foi de 200.

No que se refere aos testes de hipóteses, considerando a hipótese nula H_0 : os dados seguem distribuição BI, 5% de significância, é possível observar (Tabelas A.1 e A.2) que a proporção de não rejeição de H_0 esteve, em geral, entre 91% e 95%, com exceção de alguns cenários, como por exemplo quando $\mu = 0,5$, $\phi = 50$, $n = 200$, porcentagem de inflacionamento de 10% e considerando o teste de AD (Tabela A.2), observamos um percentual de 83,55%.

É importante citar que mesmo os dados sendo gerados de uma distribuição beta inflacionada a hipótese nula de que os dados seguem distribuição gama unitária inflacionada não foi rejeitada na maioria dos cenários, com um percentual de não rejeição de até 90%.

Considerando que os dados foram gerados de uma distribuição KI, de acordo com os critérios, foi escolhida a distribuição KI com maior frequência. Percebeu-se que no cenário 1 (Tabela 3.2), com uma precisão maior ($\phi = 30$), os critérios indicaram a distribuição KI 99,43% das vezes quando o tamanho da amostra foi de 200.

Já sobre os testes de hipóteses (Tabela A.3 e A.4), é possível verificar proporções

de não rejeição altas quando a hipótese nula é de que os dados segue distribuição KI, com valores um pouco menor nos cenários com maior proporção de inflacionamento. Por exemplo, ao observar a proporção de não rejeição da distribuição KI nos cenários 1, 2 e 3 (Tabela A.3), a proporção de não rejeição não são tão altos em 3, como é no cenário 1, os resultados são mais altos ainda quando a precisão é mais baixa ($\phi = 10$) neste cenário, a mesma observação pode ser percebida na Tabela A.4.

É importante citar que a porcentagem de vezes que a hipótese nula foi não rejeitada considerando a distribuição BI e GUI foi zero na maioria dos cenários, com poucas exceções quando $n = 30$ e H_0 de a distribuição GUI e BI é adequada.

Considerando que os dados foram gerados de uma distribuição GUI, de acordo com os critérios, foi escolhida com maior frequência a própria distribuição inflacionada. Percebeu-se que no cenário 6 (Tabela 3.3) com uma precisão maior ($\phi = 50$), os critérios indicam a distribuição GUI 73,35% das vezes quando o tamanho da amostra foi de 200.

No que se refere aos testes de hipóteses, considerando a hipótese nula H_0 : os dados seguem distribuição GUI, com 5% de significância, é possível observar (Tabelas A.5 e A.6) que a proporção de vezes que H_0 não foi rejeitado esteve, em geral, entre 91% e 95%, com exceção de alguns casos, como por exemplo os cenários 3 e 6 (Tabelas A.5 e A.6), quando $n = 200$, porcentagem de inflacionamento de 10% e considerando os testes de AD e KS.

É importante citar que a proporção de vezes que H_0 foi não rejeitada, considerando a distribuição KI, foi zero na maioria dos casos, com poucas exceções quando $n = 30$. Já a proporção de vezes que H_0 não foi rejeitada, considerando distribuição BI, foram resultados altos, mas não superior à da distribuição GUI.

Tabela 3.2: Resultados da proporção de escolha dos critérios para dados gerados com média 0, 3.

Cenários	ϕ	n	$y \sim \text{BI}[0, 1)$				$y \sim \text{KI}[0, 1)$				$y \sim \text{GUI}[0, 1)$			
			% de escolha				% de escolha				% de escolha			
			BI[0, 1)	KI[0, 1)	GUI[0, 1)	BI[0, 1)	KI[0, 1)	GUI[0, 1)	BI[0, 1)	KI[0, 1)	GUI[0, 1)	BI[0, 1)	KI[0, 1)	GUI[0, 1)
1	10	30	6,75	40,03	53,22	12,30	77,63	10,07	9,21	30,98	59,81	9,21	30,98	59,81
		60	11,51	35,79	52,70	9,01	87,60	3,39	16,13	23,66	60,21	16,13	23,66	60,21
		100	17,87	32,36	49,77	6,24	92,79	0,97	22,99	17,12	59,89	22,99	17,12	59,89
		200	28,60	25,94	45,46	1,52	98,43	0,05	29,49	8,71	61,79	29,49	8,71	61,79
	30	30	13,05	31,21	55,74	23,99	76,01	0,00	14,73	25,65	59,62	14,73	25,65	59,62
		60	22,88	23,32	53,76	10,94	89,06	0,00	22,44	16,59	60,97	22,44	16,59	60,97
		100	29,14	17,10	53,76	5,52	94,48	0,00	29,43	9,99	60,58	29,43	9,99	60,58
		200	41,06	8,37	50,57	0,64	99,36	0,00	36,99	2,99	60,02	36,99	2,99	60,02
	10	30	5,92	39,51	54,57	11,30	77,56	11,14	7,49	31,51	61,00	7,49	31,51	61,00
		60	10,03	36,73	54,57	8,65	87,17	4,18	15,04	24,00	60,96	15,04	24,00	60,96
		100	16,13	32,62	51,25	5,81	92,79	1,40	21,27	17,55	61,18	21,27	17,55	61,18
		200	24,89	26,43	48,68	1,76	98,13	0,11	28,36	8,80	62,84	28,36	8,80	62,84
2	30	30	10,38	31,48	58,14	24,01	75,99	0,00	11,80	26,27	61,93	11,80	26,27	61,93
		60	21,37	23,74	54,89	11,63	88,37	0,00	21,35	16,64	62,01	21,35	16,64	62,01
		100	27,58	17,16	55,26	5,45	94,55	0,00	27,06	10,38	62,56	27,06	10,38	62,56
		200	37,66	8,45	53,89	1,10	98,90	0,00	34,75	3,28	61,97	34,75	3,28	61,97
	10	30	5,48	39,94	54,58	9,90	76,95	13,15	6,95	32,21	60,84	6,95	32,21	60,84
		60	9,25	36,66	54,09	7,70	86,52	5,78	13,53	24,62	61,85	13,53	24,62	61,85
		100	12,88	33,42	53,70	5,09	92,77	2,14	19,47	18,32	62,21	19,47	18,32	62,21
		200	21,67	26,68	51,65	1,67	98,16	0,17	27,30	9,61	63,09	27,30	9,61	63,09
	30	30	8,99	31,93	59,08	24,27	75,73	0,00	9,80	24,47	63,73	9,80	24,47	63,73
		60	19,51	23,90	56,59	11,79	88,21	0,00	11,81	25,34	62,85	11,81	25,34	62,85
		100	26,17	17,62	56,21	5,63	94,37	0,00	18,54	19,32	62,14	18,54	19,32	62,14
		200	33,48	9,11	57,41	1,04	98,96	0,00	27,30	3,63	63,57	27,30	3,63	63,57

Tabela 3.3: Resultados da proporção de escolha dos critérios para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{BI}[0, 1)$				$y \sim \text{KI}[0, 1)$				$y \sim \text{GUI}[0, 1)$			
			% de escolha				% de escolha				% de escolha			
			BI[0, 1)	KI[0, 1)	GUI[0, 1)	BI[0, 1)	KI[0, 1)	GUI[0, 1)	BI[0, 1)	KI[0, 1)	GUI[0, 1)	BI[0, 1)	KI[0, 1)	GUI[0, 1)
4	10	30	3,70	38,89	57,41	6,50	73,30	20,20	6,44	32,14	61,42	6,44	32,14	61,42
		60	6,25	35,21	58,54	8,23	83,30	8,47	11,81	25,34	62,85	11,81	25,34	62,85
		100	9,59	32,28	58,13	6,14	89,52	4,34	18,54	19,32	62,14	18,54	19,32	62,14
		200	14,73	26,24	59,03	2,83	96,94	0,23	27,99	10,60	61,41	27,99	10,60	61,41
	50	30	8,28	28,41	63,31	23,61	76,39	0,00	8,42	24,39	67,19	8,42	24,39	67,19
		60	16,32	20,00	63,68	10,71	89,29	0,00	14,33	14,99	70,68	14,33	14,99	70,68
		100	23,60	13,51	62,89	4,94	95,06	0,00	21,86	8,41	69,73	21,86	8,41	69,73
		200	32,86	5,52	61,62	2,11	97,89	0,00	33,28	2,16	64,56	33,28	2,16	64,56
5	10	30	2,46	38,73	58,81	4,99	73,37	21,64	4,56	32,31	63,13	4,56	32,31	63,13
		60	4,96	35,89	59,15	7,25	83,09	9,66	9,56	25,63	64,81	9,56	25,63	64,81
		100	7,97	32,35	59,68	5,65	89,15	5,20	16,18	19,46	64,36	16,18	19,46	64,36
		200	10,59	26,76	62,65	3,36	96,05	0,59	25,17	10,92	63,91	25,17	10,92	63,91
	50	30	5,29	29,11	65,60	23,51	76,49	0,00	5,32	24,76	69,92	5,32	24,76	69,92
		60	13,88	20,25	65,87	11,57	88,43	0,00	10,91	14,68	74,41	10,91	14,68	74,41
		100	20,36	13,90	65,74	5,35	94,65	0,00	17,33	8,70	73,97	17,33	8,70	73,97
		200	27,81	5,79	66,40	2,33	97,67	0,00	28,57	2,48	68,95	28,57	2,48	68,95
6	10	30	1,97	39,08	58,95	3,46	72,92	23,62	3,43	32,97	63,60	3,43	32,97	63,60
		60	4,03	36,37	59,60	6,34	82,24	11,42	7,06	26,01	66,93	7,06	26,01	66,93
		100	5,12	33,33	61,55	5,19	89,09	5,72	13,22	20,19	66,59	13,22	20,19	66,59
		200	7,41	27,54	65,05	3,17	96,02	0,81	20,25	11,56	68,19	20,25	11,56	68,19
	50	30	3,70	29,54	66,76	24,14	75,86	0,00	3,18	24,70	72,12	3,18	24,70	72,12
		60	10,75	20,97	68,28	11,74	88,26	0,00	7,05	15,65	77,30	7,05	15,65	77,30
		100	15,67	14,39	69,94	5,72	94,28	0,00	14,31	8,86	76,83	14,31	8,86	76,83
		200	23,03	6,44	70,53	1,28	98,72	0,00	24,00	2,65	73,35	24,00	2,65	73,35

3.1.2 Inflacionamento em zero e um

Para os cenários de 1 a 9, quando os dados são gerados pela distribuição BI, de acordo com os critérios, foi escolhida a distribuição GUI com maior frequência. Percebeu-se que nos cenários 7, 8 e 9 (Tabela 3.6), com uma precisão maior ($\phi = 50$), os critérios indicaram a distribuição GUI cerca 80% das vezes quando o tamanho das amostras foram de 200.

No que se refere aos testes de hipóteses, considerando a hipótese nula H_0 : os dados seguem distribuição BI, 5% de significância, é possível observar (Tabelas A.7, A.7 e A.9) que a proporção de não rejeição de H_0 esteve, em geral, entre 92% e 95% para os testes KS e CVM, já considerando o teste de AD, observamos um percentuais mais inferiores chegando até a zero, como por exemplo o cenário 6 (Tabela A.8) quando $n = 200$.

É importante citar que mesmo os dados sendo gerados de uma distribuição beta inflacionada, a hipótese nula de que os dados seguem distribuição gama unitária inflacionada, a proporção de não rejeição nos cenários de 1 a 6 (Tabelas A.7 e A.8) foram altos ($n = 30$, $n = 60$ e $n = 100$), com um percentual de não rejeição de até 90%.

Considerando que os dados foram gerados de uma distribuição KI, de acordo com os critérios, foi escolhida a distribuição KI com maior frequência. Percebeu-se que nos cenários 1, 2 e 3 (Tabela 3.4), com uma precisão maior ($\phi = 30$), os critérios indicaram a distribuição KI 99% das vezes quando o tamanho da amostra foi de 200.

Já sobre os testes de hipóteses (Tabelas A.10, A.11 e A.12), é possível verificar proporções de não rejeição altas quando a hipótese nula é de que os dados segue distribuição KI, com valores um pouco menor nos cenários com precisão maior. Por exemplo, ao observar a proporção de não rejeição da distribuição KI nos cenários 1, 2 e 3 (Tabela A.10), a proporção de não rejeição nos cenários com precisão menor ($\phi = 10$) é mais alta do que os nos cenários com precisão maior ($\phi = 10$). A mesma observação pode ser percebida na Tabela A.11.

É importante citar que a porcentagem de vezes hipótese nula foi não rejeitada considerando a distribuição BI e GUI foi zero na maioria dos cenários, com poucas exceções quando $n = 30$ e H_0 de a distribuição GUI e BI é adequada.

Considerando que os dados foram gerados de uma distribuição GUI, de acordo com os critérios, foi escolhida com maior frequência a própria distribuição inflacionada. Percebeu-se que no cenário 9 (Tabela 3.6) com uma precisão maior ($\phi = 50$), os critérios indicam a distribuição GUI 95,42% das vezes quando o tamanho da amostra foi de 200.

No que se refere aos testes de hipóteses, considerando a hipótese nula H_0 : os dados seguem distribuição GUI, com 5% de significância, é possível observar (Tabelas

A.13, A.14 e A.15) que a proporção de vezes que H_0 não foi rejeitado esteve, em geral, entre 94% e 95%, com exceção de alguns casos, como por exemplo os cenários 9 (Tabela A.15), quando $n = 200$, porcentagem de inflacionamento de 10% e considerando o teste de KS. Considerando o teste de AD a porcentagem de não rejeição não foram altas como os de KS e CVM.

É importante citar que a proporção de vezes que H_0 foi não rejeitada, considerando a distribuição KI, foi zero na maioria dos cenários de 1 a 6, com poucas exceções quando $n = 30$ ou $n = 60$. Já a proporção de vezes que H_0 não foi rejeitada, considerando distribuição BI nos cenários de 1 a 6, foi alta, mas não superior à da distribuição GUI. Para os cenários de 7 a 9, quando considerado a KI na hipótese nula os resultados foram melhores que quando considerado a BI na hipótese nula.

Tabela 3.4: Resultados da proporção de escolha dos critérios para dados gerados com média 0, 3.

Cenários	ϕ	n	$y \sim \text{BI}[0, 1]$			$y \sim \text{KI}[0, 1]$			$y \sim \text{GUI}[0, 1]$		
			% de escolha			% de escolha			% de escolha		
			BI[0, 1]	KI[0, 1]	GUI[0, 1]	BI[0, 1]	KI[0, 1]	GUI[0, 1]	BI[0, 1]	KI[0, 1]	GUI[0, 1]
1	10	30	7,18	39,68	53,14	13,06	77,69	9,25	9,77	30,84	59,39
		60	12,73	35,51	51,76	9,53	87,41	3,06	16,50	22,93	60,57
		100	19,42	32,19	48,39	6,32	93,11	0,57	23,67	16,62	59,71
		200	30,13	25,25	44,62	1,51	98,47	0,02	29,72	8,14	62,14
	30	30	13,45	31,03	55,52	23,91	76,09	0,00	15,03	25,42	59,55
		60	23,59	23,20	53,21	11,00	89,00	0,00	23,12	16,28	60,60
		100	31,04	16,74	52,22	5,33	94,64	0,00	31,59	9,60	58,81
		200	43,98	8,18	47,84	0,74	99,26	0,00	38,52	3,07	58,41
	10	30	6,69	39,75	53,56	12,20	77,39	10,41	8,74	30,75	60,51
		60	12,09	36,21	51,70	9,21	87,25	3,54	16,30	23,28	60,42
		100	18,61	32,37	49,02	6,12	92,98	0,90	22,32	17,20	60,48
		200	29,73	25,72	44,68	1,48	98,45	0,07	28,72	8,45	62,83
2	30	30	12,49	31,05	56,46	24,19	75,81	0,00	13,51	25,40	61,09
		60	22,79	23,57	53,64	11,29	88,71	0,00	22,24	16,54	61,22
		100	29,71	17,26	53,03	5,56	94,44	0,00	30,47	10,00	59,53
		200	43,63	8,44	47,93	0,73	99,27	0,00	38,57	2,90	58,53
	10	30	5,73	40,03	54,24	11,37	77,43	11,20	7,87	30,71	61,42
		60	11,07	36,80	52,13	8,88	87,00	4,12	15,50	23,61	60,80
		100	17,33	33,22	49,45	6,25	92,50	1,25	22,15	17,34	60,51
		200	27,94	26,09	45,97	1,64	98,14	0,22	27,43	8,68	63,89
	30	30	11,13	30,83	58,04	24,43	75,57	0,00	11,33	25,89	62,78
		60	21,80	23,74	54,46	11,63	88,37	0,00	20,79	16,94	62,27
		100	28,13	17,68	54,19	5,32	94,68	0,00	28,82	10,79	60,39
		200	41,54	8,60	49,86	0,96	99,04	0,00	36,65	3,07	60,28

Tabela 3.5: Resultados da proporção de escolha dos critérios para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{BI}[0, 1]$			$y \sim \text{KI}[0, 1]$			$y \sim \text{GUI}[0, 1]$		
			% de escolha			% de escolha			% de escolha		
			BI[0, 1]	KI[0, 1]	GUI[0, 1]	BI[0, 1]	KI[0, 1]	GUI[0, 1]	BI[0, 1]	KI[0, 1]	GUI[0, 1]
4	10	30	4,60	37,84	57,56	6,76	73,50	19,74	6,80	31,51	61,69
		60	7,67	34,91	57,42	9,52	82,64	7,84	14,31	24,89	60,80
		100	12,91	31,11	55,98	8,33	89,28	2,39	21,84	18,68	59,48
		200	43,63	8,44	47,93	3,36	96,42	0,22	28,80	10,62	60,58
	50	30	8,98	27,69	63,33	24,39	75,61	0,00	8,53	23,70	67,77
		60	18,96	19,72	61,32	11,19	88,81	0,00	18,54	14,87	66,59
		100	28,64	12,87	58,49	5,07	94,93	0,00	30,10	7,91	61,99
		200	39,75	5,26	54,99	2,12	97,88	0,00	36,54	2,12	61,34
	10	30	3,62	38,62	57,76	5,49	73,11	21,40	5,60	32,01	62,39
		60	6,49	35,42	58,09	8,65	82,63	8,72	13,02	25,43	61,55
		100	11,50	31,66	56,84	8,13	89,39	2,48	19,92	19,57	60,51
		200	20,19	24,99	54,82	3,30	96,39	0,31	27,49	10,89	61,62
5	50	30	6,74	28,62	64,64	24,23	75,77	0,00	6,39	24,71	68,90
		60	17,79	20,20	62,01	11,29	88,71	0,00	17,45	15,07	67,48
		100	25,99	13,71	60,30	5,30	94,70	0,00	27,14	8,58	64,28
		200	37,57	5,85	56,58	2,15	97,85	0,00	34,24	2,68	63,08
	10	30	2,85	38,81	58,34	3,56	73,35	23,09	4,03	32,93	63,04
		60	5,12	35,74	59,14	7,85	82,42	9,73	11,41	25,59	63,00
		100	10,52	32,37	57,11	7,29	89,22	3,49	18,46	19,87	61,67
		200	17,73	26,05	56,22	3,63	96,03	0,34	25,50	11,77	62,73
	6	30	4,85	29,19	65,96	24,80	75,20	0,00	4,23	25,35	70,42
		60	15,52	20,48	64,00	11,81	88,19	0,00	14,06	15,74	70,20
		100	23,50	14,09	62,41	5,59	94,41	0,00	24,09	9,03	66,88
		200	35,52	5,78	58,70	1,02	98,98	0,00	32,61	2,53	64,86

Tabela 3.6: Resultados da proporção de escolha dos critérios para dados gerados com média 0, 8.

Cenários	ϕ	n	$y \sim \text{BI}[0, 1]$				$y \sim \text{KI}[0, 1]$				$y \sim \text{GUI}[0, 1]$			
			% de escolha				% de escolha				% de escolha			
			BI[0, 1]	KI[0, 1]	GUI[0, 1]	BI[0, 1]	KI[0, 1]	GUI[0, 1]	BI[0, 1]	KI[0, 1]	GUI[0, 1]	BI[0, 1]	KI[0, 1]	GUI[0, 1]
7	10	30	0,63	40,33	59,04	2,14	56,20	41,66	4,30	32,04	63,66	4,30	32,04	63,66
		60	0,73	40,69	58,58	2,29	62,21	35,50	3,88	25,64	70,48	3,88	25,64	70,48
		100	1,04	39,44	59,52	3,07	66,47	30,46	4,83	19,93	75,24	4,83	19,93	75,24
		200	2,22	37,34	60,44	5,01	73,73	21,26	7,64	11,74	80,62	7,64	11,74	80,62
	50	30	4,31	32,24	63,45	10,16	77,40	12,44	5,51	24,37	70,12	5,51	24,37	70,12
		60	3,68	25,84	70,48	3,90	87,32	8,87	2,53	14,95	82,52	2,53	14,95	82,52
		100	4,74	20,29	74,48	1,52	93,53	4,95	1,56	9,02	89,42	1,56	9,02	89,42
		200	7,75	12,11	80,14	0,19	98,53	1,28	4,59	2,50	92,91	4,59	2,50	92,91
	10	30	0,50	40,97	58,53	1,30	56,68	42,02	2,92	32,78	64,30	2,92	32,78	64,30
		60	0,68	40,38	58,94	1,84	61,58	36,58	2,19	25,93	64,30	2,19	25,93	64,30
		100	0,83	40,41	58,76	2,56	66,70	30,74	3,71	20,47	75,82	3,71	20,47	75,82
		200	1,91	37,80	60,29	4,57	74,37	21,06	6,74	11,93	81,33	6,74	11,93	81,33
8	50	30	2,89	32,96	64,15	9,41	77,87	12,72	2,92	25,20	71,86	2,92	25,20	71,86
		60	2,29	26,20	71,51	4,08	86,83	9,09	1,34	15,09	83,57	1,34	15,09	83,57
		100	3,78	20,83	75,39	1,42	93,32	5,26	0,93	8,94	90,13	0,93	8,94	90,13
		200	6,92	12,16	80,92	0,14	98,32	1,54	3,46	2,50	94,04	3,46	2,50	94,04
	10	30	0,38	40,55	59,07	0,88	55,31	43,81	1,45	33,13	65,42	1,45	33,13	65,42
		60	0,38	40,42	59,40	1,18	61,09	37,73	1,39	26,41	72,20	1,39	26,41	72,20
		100	0,69	39,39	59,92	2,03	66,03	31,94	2,54	20,62	76,84	2,54	20,62	76,84
		200	1,39	37,12	61,49	4,13	73,43	22,44	5,84	12,24	81,92	5,84	12,24	81,92
	50	30	1,42	33,28	65,30	9,17	76,63	14,20	1,63	25,33	73,04	1,63	25,33	73,04
		60	1,37	26,70	71,93	3,75	86,54	9,71	0,60	15,68	83,72	0,60	15,68	83,72
		100	2,53	20,95	76,52	1,60	92,33	6,07	0,47	9,14	90,39	0,47	9,14	90,39
		200	5,88	12,53	81,59	0,19	98,19	1,62	1,92	2,66	95,42	1,92	2,66	95,42

3.1.3 Inflacionamento em um

Para os cenários de 4 a 9, quando os dados são gerados pela distribuição BI, de acordo com os critérios, foi escolhida a distribuição GUI com maior frequência. Percebeu-se que no cenário 9 (Tabela 3.8), com uma precisão maior ($\phi = 50$), os critérios indicaram a distribuição GUI 80,84% das vezes quando o tamanho das amostras foram de 200.

No que se refere aos testes de hipóteses, considerando a hipótese nula H_0 : os dados seguem distribuição BI, 5% de significância, é possível observar (Tabelas A.16 e A.17) que a proporção de não rejeição de H_0 esteve, em geral, entre 89% e 95% para os testes KS e CVM, com exceção do cenário 6 com $n = 100$ e $n = 200$ para o teste de KS. Considerando o teste de AD, observamos percentuais mais inferiores chegando até a zero, como por exemplo o cenário 6 (Tabela A.16) quando $n = 200$.

Considerando que os dados foram gerados de uma distribuição KI, de acordo com os critérios, foi escolhida a distribuição KI com maior frequência. Percebeu-se que nos cenários 6, 7, 8 e 9 (Tabela 3.7 e 3.8), com uma precisão maior ($\phi = 50$), os critérios indicaram a distribuição KI cerca de 99% das vezes quando o tamanho da amostra foi de 200.

Já sobre os testes de hipóteses (Tabelas A.18 e A.19), é possível verificar proporções de não rejeição altas quando a hipótese nula é de que os dados seguem distribuição KI, com valores um pouco menor nos cenários com precisão maior. Por exemplo, ao observar a proporção de não rejeição da distribuição KI nos cenários 4, 5 e 6 (Tabela A.18), a proporção de não rejeição nos cenários com precisão menor ($\phi = 10$) é mais alta do que os nos cenários com precisão maior ($\phi = 10$). A mesma observação pode ser percebida na Tabela A.19.

É importante citar que a porcentagem de vezes hipótese nula foi não rejeitada considerando a distribuição BI e GUI foi zero na maioria dos cenários, com algumas exceções quando $n = 30$ ou $n = 60$.

Considerando que os dados foram gerados de uma distribuição GUI, de acordo com os critérios, foi escolhida a própria distribuição inflacionada com maior frequência. Percebeu-se que no cenário 9 (Tabela 3.8) com uma precisão maior ($\phi = 50$), os critérios indicam a distribuição GUI 94,34% das vezes quando o tamanho da amostra foi de 200.

No que se refere aos testes de hipóteses, considerando a hipótese nula H_0 : os dados seguem distribuição GUI, com 5% de significância, é possível observar (Tabelas A.20 e A.21) que a proporção de vezes que H_0 não foi rejeitado esteve, em geral, entre 89% e 95%, com exceção de alguns casos, como por exemplo os cenários 6 e 9 (Tabelas A.20 e A.21), quando $n = 200$ ou $n = 100$, porcentagem de inflacionamento de 10% e considerando o teste de KS. Considerando o teste de AD a porcentagem de não

rejeição não foram altas como os de KS e CVM.

É importante citar que a proporção de vezes que H_0 foi não rejeitada, considerando a distribuição KI, foi zero na maioria dos cenários de 4 a 9, com algumas exceções quando $n = 30$ ou $n = 60$. Já a proporção de vezes que H_0 não foi rejeitada, considerando distribuição BI nos cenários de 4 a 6, foram resultados altos quando $n = 30$, mas não superior à da distribuição GUI.

Tabela 3.7: Resultados da proporção de escolha dos critérios para dados gerados com média 0, 5.

Cenários	ϕ	n	gerado pela BI(0, 1]				$y \sim \text{KI}(0, 1]$				$y \sim \text{GUI}(0, 1]$			
			% de escolha				% de escolha				% de escolha			
			BI(0, 1]	KI(0, 1]	GUI(0, 1]	BI(0, 1]	KI(0, 1]	GUI(0, 1]	BI(0, 1]	KI(0, 1]	GUI(0, 1]	BI(0, 1]	KI(0, 1]	GUI(0, 1]
4	10	30	4,59	38,44	56,97	5,63	73,52	20,85	7,15	31,90	60,95	7,15	31,90	60,95
		60	7,60	34,11	58,29	8,58	82,79	8,63	12,64	24,71	62,65	12,64	24,71	62,65
		100	11,70	31,38	56,92	6,66	89,27	4,07	19,18	19,31	61,51	19,18	19,31	61,51
		200	16,99	25,47	57,54	3,37	96,30	0,33	27,84	10,56	61,60	27,84	10,56	61,60
	50	30	8,80	28,24	62,96	24,01	75,99	0,00	8,11	24,05	67,84	8,11	24,05	67,84
		60	18,12	19,45	62,43	11,15	88,85	0,00	16,41	14,76	68,83	16,41	14,76	68,83
		100	25,44	13,21	61,35	5,14	94,93	0,00	23,76	8,75	67,49	23,76	8,75	67,49
		200	34,13	5,33	60,54	2,09	97,91	0,00	35,20	2,17	62,63	35,20	2,17	62,63
	10	30	3,97	38,38	57,65	4,56	73,07	22,37	6,24	31,76	62,00	6,24	31,76	62,00
		60	7,45	34,18	58,37	7,64	82,37	9,99	11,88	24,43	63,69	11,88	24,43	63,69
		100	10,20	31,92	57,88	5,88	89,09	5,03	17,62	18,99	63,39	17,62	18,99	63,39
		200	15,58	25,63	58,79	3,13	96,41	0,46	27,45	10,44	62,11	27,45	10,44	62,11
5	50	30	6,91	28,41	64,68	24,20	75,80	0,00	6,74	24,30	68,98	6,74	24,30	68,98
		60	17,74	19,42	62,84	11,64	88,36	0,00	14,83	14,77	70,40	14,83	14,77	70,40
		100	24,32	13,12	62,56	5,44	94,56	0,00	21,03	8,43	70,54	21,03	8,43	70,54
		200	32,27	5,39	62,34	2,22	97,78	0,00	34,71	2,36	62,93	34,71	2,36	62,93
	10	30	3,36	38,87	57,77	3,28	72,50	24,22	5,21	32,31	62,45	5,21	32,31	62,45
		60	6,66	35,44	57,90	6,33	81,96	11,71	9,62	25,72	64,66	9,62	25,72	64,66
		100	8,65	32,65	58,70	5,45	88,75	5,80	14,27	19,89	65,84	14,27	19,89	65,84
		200	12,81	26,33	60,86	2,91	96,33	0,76	24,90	11,26	63,84	24,90	11,26	63,84
6	50	30	5,86	28,63	65,51	24,44	75,56	0,00	5,67	24,59	69,74	5,67	24,59	69,74
		60	15,65	20,10	64,25	11,76	88,24	0,00	13,49	15,38	71,13	13,49	15,38	71,13
		100	20,89	13,66	65,45	5,38	94,62	0,00	18,39	8,93	72,68	18,39	8,93	72,68
		200	29,34	5,65	65,01	1,27	98,73	0,00	32,25	2,53	65,22	32,25	2,53	65,22

Tabela 3.8: Resultados da proporção de escolha dos critérios para dados gerados com média 0, 8.

Cenários	ϕ	n	$y \sim \text{BI}(0, 1]$				$y \sim \text{KI}(0, 1]$				$y \sim \text{GUI}(0, 1]$			
			% de escolha				% de escolha				% de escolha			
			BI(0, 1]	KI(0, 1]	GUI(0, 1]	BI(0, 1]	KI(0, 1]	GUI(0, 1]	BI(0, 1]	KI(0, 1]	GUI(0, 1]	BI(0, 1]	KI(0, 1]	GUI(0, 1]
7	10	30	0,78	40,67	58,55	2,25	56,34	41,41	4,55	32,31	63,14	4,55	32,31	63,14
		60	0,97	38,83	60,20	2,37	60,64	36,99	4,01	25,43	70,56	4,01	25,43	70,56
		100	1,20	38,83	59,96	2,80	65,98	31,22	5,78	20,26	73,96	5,78	20,26	73,96
		200	2,24	36,68	61,08	4,93	73,79	21,28	9,54	11,73	78,73	9,54	11,73	78,73
	50	30	4,65	32,19	63,16	10,06	77,47	12,47	5,76	24,23	70,01	5,76	24,23	70,01
		60	4,06	25,26	70,68	3,82	87,25	8,93	3,21	15,00	81,79	3,21	15,00	81,79
		100	5,85	20,04	74,11	1,74	93,00	5,26	1,97	8,97	89,06	1,97	8,97	89,06
		200	9,90	11,52	78,58	0,13	98,42	1,45	7,52	2,31	90,17	7,52	2,31	90,17
	10	30	0,54	40,28	58,18	1,61	56,00	42,39	3,22	32,18	64,60	3,22	32,18	64,60
		60	0,72	39,14	60,14	1,90	61,09	37,01	3,09	25,15	71,76	3,09	25,15	71,76
		100	0,98	39,11	59,91	2,45	66,03	3,52	4,58	20,02	75,40	4,58	20,02	75,40
		200	1,77	36,82	61,41	3,92	73,77	22,31	8,74	11,59	79,67	8,74	11,59	79,67
8	50	30	3,35	31,97	64,68	9,40	77,28	13,32	3,14	24,48	72,38	3,14	24,48	72,38
		60	3,07	24,87	72,06	3,92	87,01	9,07	1,92	15,02	83,06	1,92	15,02	83,06
		100	4,74	19,60	75,66	1,56	92,91	5,53	1,35	8,63	90,02	1,35	8,63	90,02
		200	8,99	11,22	79,79	0,15	98,23	1,62	4,85	2,62	92,53	4,85	2,62	92,53
	10	30	0,42	40,28	59,30	0,84	55,82	43,34	1,66	32,69	65,65	1,66	32,69	65,65
		60	0,48	39,54	54,98	1,39	60,75	37,86	2,06	26,45	71,49	2,06	26,45	71,49
		100	0,72	38,18	61,10	2,01	66,14	31,85	3,28	20,89	75,83	3,28	20,89	75,83
		200	1,73	36,27	62,00	2,68	73,99	23,33	7,24	12,51	80,25	7,24	12,51	80,25
9	50	30	1,72	32,30	65,98	9,38	76,38	14,24	1,69	24,68	73,63	1,69	24,68	73,63
		60	1,91	25,74	72,35	3,82	86,37	9,81	1,30	15,58	83,12	1,30	15,58	83,12
		100	3,27	20,16	76,57	1,66	92,77	5,57	0,97	9,16	89,87	0,97	9,16	89,87
		200	7,34	11,82	80,84	0,12	98,32	1,56	2,97	2,69	94,34	2,97	2,69	94,34

Capítulo 4

Aplicações das Distribuições Inflacionadas

4.1 Introdução

Neste Capítulo serão apresentadas sete aplicações a dados reais: nas seções 4.2, 4.3 e 4.4 são apresentadas aplicações para dados Inflacionados em zero, nas seções 4.5 e 4.6 são apresentadas aplicações para dados Inflacionados em zero e um, nas seções 4.7 e 4.8 são apresentadas aplicações para dados Inflacionados em um.

As tabelas de medidas descritivas da variável de interesse apresentam as seguintes informações: o valor mínimo, $Q_{1/4}$, mediana, média, $Q_{3/4}$, valor máximo, DP e CV, em que $Q_{1/4}$ é o primeiro quartil, $Q_{3/4}$ é o terceiro quartil, DP é o desvio padrão e CV que é o coeficiente de variação.

Com o intuito de avaliar a adequabilidade das distribuições aos dados, foi realizada uma comparação a partir das medidas de bondade de ajuste: critério de informação de Akaike (AIC), critério de informação de Akaike corrigido (AICc), critério de informação Bayesiano (BIC), critério de informação Bayesiano corrigido (BICc), critério de Hannan-Quinn (HQ) e critério de Hannan-Quinn corrigido (HQc). Estes resultados foram sumarizados nas tabelas de critérios de adequabilidade de cada aplicação.

4.2 Proporção de pessoas que usa internet

A variável de interesse (*Internet*) é a proporção de pessoas por país que utilizaram internet no ano de 2000 em 209 países (<https://ourworldindata.org/>). Vale ressaltar que, de acordo com os dados, há 17 nações que apresentaram valor igual a zero, ou seja, apresentando 8,13% de inflacionamento em zero. De acordo com a Tabela 4.1, a proporção média de pessoas que utilizaram internet é de 0,0647.

Tabela 4.1: Medidas descritivas da proporção de pessoas que utilizaram internet.

Mínimo	$Q_{1/4}$	Mediana	Média	$Q_{3/4}$	Máximo	DP	CV
0,0000	0,0020	0,0140	0,0647	0,0650	0,5130	0,1096	169,25%

A Tabela 4.2 apresenta os p -valores dos testes de hipóteses realizados para verificar a adequação dos dados às distribuições abordadas, a partir dos seguintes testes de hipótese: Kolmogorov–Smirnov (KS), Anderson–Darling (AD) e T Cramer–Von Mises (CVM). Ao nível de significância de 5%, os testes de Kolmogorov–Smirnov (KS) e Cramér–Von Mises (CVM) não rejeitam a hipótese que os dados seguem distribuição GUI e, ao mesmo nível de significância, apenas o teste de CVM não rejeitou a hipótese que os dados seguem distribuição KI. A Figura 4.1 apresenta o histograma, em que a barra vertical representa a frequência de zeros. Já a Figura 4.2 apresenta os gráficos qq-plot das três distribuições ajustadas, em que o eixo x apresenta as probabilidades teóricas e o eixo y apresenta as probabilidades empíricas. Observando os gráficos, vemos que as distribuições Beta Inflacionada (BI) e Kumaraswamy Inflacionada (KI) tiveram desempenho semelhantes, na Gama unitária Inflacionada (GUI), os pontos ficaram próximos da diagonal, mas para o intervalo de 0,4 a 0,8 os pontos ficaram um pouco afastados da diagonal.

Tabela 4.2: p-valores dos testes de hipóteses.

Distribuição	Testes		
	KS	CVM	AD
BI	0,0033	0,0469	0,0198
KI	0,0292	0,0699	0,0332
GUI	0,0877	0,1098	0,0473

A tabela 4.3 apresenta os resultados sumarizados dos critérios de adequabilidade. Para todas as medidas analisadas, há uma melhor adequabilidade da distribuição Gama unitária inflacionada quando comparadas com as outras medidas.

Tabela 4.3: Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - dados da proporção de pessoas utilizaram a internet em 209 países.

Distribuição	AIC	AICc	BIC	BICc	HQ	HQc
BI	−609,094	−608,976	−599,067	−598,754	−605,040	−604,843
KI	−621,409	−621,292	−611,382	−611,069	−617,355	−617,159
GUI	−630,198	−630,081	−620,171	−619,859	−626,144	−625,948

Desta forma, considerando os resultados dos critérios e dos testes de hipóteses, podemos concluir que a distribuição que melhor representa os dados da proporção de pessoas que utilizaram internet é a distribuição gama unitária inflacionada.




Figura 4.1: Histograma da proporção de pessoas dos países que utilizaram internet em 209 países.




Figura 4.2: QQ-Plot da proporção de pessoas que utilizaram internet em 209 países.

4.3 Proporção de nascidos vivos com 4000 gramas ou mais

A variável de interesse (*Nascidos vivos*) é a proporção de crianças do estado da Paraíba que nasceram vivas com 4000 gramas ou mais, no ano de 2021 em 223 municípios(<https://datasus.saude.gov.br/>). Vale ressaltar que, de acordo com os dados, há 13 municípios que apresenta valor igual a zero, ou seja, apresentando

5,83% de inflacionamento em zero. De acordo com a Tabela 4.4, a proporção média de crianças que nasceram vivas com 4000 gramas ou mais é de 0,0625.

Tabela 4.4: Medidas descritivas da proporção de nascidos vivos com 4000 gramas ou mais.

Mínimo	$Q_{1/4}$	Mediana	Média	$Q_{3/4}$	Máximo	DP	CV
0,0000	0,0430	0,0625	0,0625	0,0827	0,1429	0,0309	49,40%

A tabela 4.5 apresenta os p -valores dos teste de hipóteses realizados para verificar a adequação dos dados às distribuições abordadas, a partir dos seguintes testes de hipótese: Kolmogorov–Smirnov (KS), Anderson–Darling (AD) e Cramér–Von Mises (CVM). Ao nível de significância de 5%, os três testes não rejeitaram a hipótese de que os dados seguem distribuição GUI e KI, o teste de KS foi o único que não rejeitou a hipótese de que os dados seguem distribuição BI. A Figura 4.3 apresenta o histograma, em que a barra vertical representa a frequência de zeros. A Figura 4.4 apresenta os gráficos qq-plot das três distribuições ajustadas, em que o eixo x apresenta as probabilidades teóricas e o eixo y apresenta as probabilidades empíricas. Podemos observar que para essa aplicação a distribuição BI teve pontos mais próximos da linha vertical que as demais distribuições.

Tabela 4.5: P-valores dos testes de hipóteses.

Distribuição	Testes		
	KS	CVM	AD
BI	0,0570	0,0431	0,0399
KI	0,4347	0,7899	0,5458
GUI	0,4347	0,5934	0,4567

A Tabela 4.6 apresenta os resultados sumarizados dos critérios de adequabilidade. Para todas medidas analisadas, há uma melhor adequabilidade da distribuição Beta inflacionada quando comparadas com as outras medidas.

Desta forma, considerando os resultados dos critérios e testes de hipóteses, podemos concluir que a distribuição que melhor representa os dados da proporção de crianças que nasceram vivas com 4000 gramas ou mais é a distribuição beta inflacionada.




Figura 4.3: Histograma da proporção de nascidos com 4000 gramas ou mais em 223 municípios.




Figura 4.4: QQ-Plot da proporção de nascidos vivos com 4000 gramas ou mais em 223 municípios.

Tabela 4.6: Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - dados da proporção de nascidos com 4000 gramas ou mais nos 223 municípios.

Distribuição	AIC	AICc	BIC	BICc	HQ	HQc
BI	-820,922	-820,813	-810,701	-810,405	-816,796	-816,611
KI	-820,831	-820,722	-810.610	-810,313	-816,705	-816,520
GUI	-817,609	-817,499	-807.387	-807.091	-813,483	-813,298

4.4 Proporção de pacientes com tuberculose e HIV

A variável de interesse (*Pacientes*) é a proporção pacientes por país que além de ter a Tuberculose, também têm HIV no ano de 2005 em 178 países(<https://ourworldindata.org/>). Vale ressaltar que, de acordo com os dados, há 13 nações que apresenta valor igual a zero, ou seja apresentando 5,06% de inflacionamento em zero. De acordo com a Tabela 4.7, a proporção média de pacientes que têm tuberculose e também têm HIV é de 0,1365.

Tabela 4.7: Medidas descritivas da proporção de pacientes com tuberculose e HIV.

Mínimo	$Q_{1/4}$	Mediana	Média	$Q_{3/4}$	Máximo	DP	CV
0,0000	0,0095	0,0535	0,1365	0,1975	0,7900	0,1876	137,49%

A Tabela 4.8 apresenta os resultados dos p -valores dos testes de hipóteses realizados para verificar a adequação dos dados às distribuições abordadas, a partir dos seguintes testes de hipótese: Kolmogorov–Smirnov (KS), Anderson–Darling (AD) e Cramér–Von Mises (CVM). Ao nível de significância de 5%, as três distribuições não são rejeitadas a hipótese de os dados seguem as distribuições BI, KI e GUI. A Figura 4.5 apresenta o histograma, em que a barra vertical representa a frequência de zeros. A Figura 4.6 apresenta os gráficos qq-plot das três distribuições ajustadas, em que o eixo x apresenta as probabilidades teóricas e o eixo y apresenta as probabilidades empíricas. Podemos ver que para essa aplicação nenhuma das três distribuições foi boa de modo geral para os gráficos qq-plot.

Tabela 4.8: P-valores dos testes de hipóteses.

Distribuição	Testes		
	KS	CVM	AD
BI	0,370	0,332	0,228
KI	0,326	0,305	0,265
GUI	0,502	0,427	0,349

A Tabela 4.9 apresenta os resultados sumarizados dos critérios de adequabilidade. Para todas as medidas analisadas, há uma melhor adequabilidade da distribuição Gama Unitária inflacionada quando comparadas com as outras medidas.

Diante do que foi apresentado e a partir dos resultados dos critérios e testes de hipóteses, podemos concluir que a distribuição que melhor representa os dados da proporção de pacientes com tuberculose e HIV é a gama unitária inflacionada.




Figura 4.5: Histograma da proporção de pacientes com tuberculose e HIV em 178 países.




Figura 4.6: QQ-Plot da proporção de pacientes com tuberculose e HIV em 178 países.

Tabela 4.9: Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de pacientes com tuberculose e HIV em 178 países.

Distribuição	AIC	AICc	BIC	BICc	HQ	HQc
BI	-285,380	-285,242	-275,835	-275,477	-281,509	-281,282
KI	-290,143	-290,005	-280,598	-280,241	-286,272	-286,045
GUI	-293,642	-293,504	-284,096	-283,739	-289,771	-289,544

4.5 Proporção da população urbana que reside em domicílios com rede de esgoto sanitário nos municípios do estado do Espírito Santo

A variável de interesse (*Esgoto sanitário ES*) é a proporção de pessoas que reside em zona urbana com domicílio ligado à rede de esgoto sanitário no ano de 2013 em 52 municípios do Espírito Santo (<http://www.atlasbrasil.org.br/>). É importante mencionar que, de acordo com os dados, há 1 município que apresentou valor igual a zero e 4 municípios apresentou valor igual a um, ou seja, apresentando 1,92% de inflacionamento em zero e 7,69% de inflacionamento em um. De acordo com Tabela 4.10 a proporção média de pessoas que residem em domicílios com rede de esgoto sanitário é de 0,5987.

Tabela 4.10: Medidas descritivas da proporção de pessoas que residem em domicílios com rede de esgoto sanitário.

Mínimo	$Q_{1/4}$	Mediana	Média	$Q_{3/4}$	Máximo	DP	CV
0,0000	0,4078	0,5985	0,5987	0,8790	1,0000	0,3034	50,67%

A Tabela 4.11 apresenta os p -valores dos testes de hipóteses realizados para verificar a adequação dos dados às distribuições abordadas, a partir dos seguintes testes de hipóteses: Kolmogorov–Smirnov (KS), Anderson–Darling (AD) e Cramér–Von Mises (CVM). Ao nível de significância de 5%, o teste de AD rejeitou a hipótese que os dados seguem distribuição BI, KI ou GUI, já para os testes KS e CVM não foi rejeitada a hipótese de que os dados seguem a distribuição BI, KI e GUI. A Figura 4.7 apresenta o histograma, em que as barras verticais representam a frequência de zero e a frequência de uns. A Figura 4.8 apresenta os gráficos qq-plot das três distribuições ajustadas, em que o eixo x apresenta as probabilidades teóricas e o eixo y apresentam as probabilidades empíricas. Podemos observar que de os resultados destes gráficos não foram tão bom, pois para essa aplicação nas três distribuições os valores ficaram um pouco afastado da reta diagonal dos gráficos qq-plot.

Tabela 4.11: P-valores dos testes de hipóteses.

Distribuição	Testes		
	KS	CVM	AD
BI	0,9180	0,9406	$< 1 \times 10^{-05}$
KI	0,9180	0,9141	$< 1 \times 10^{-05}$
GUI	0,9180	0,9150	$< 1 \times 10^{-05}$




Figura 4.7: Histograma da proporção de pessoas que residem em domicílio com rede esgoto sanitário em 52 municípios.




Figura 4.8: QQ-Plot da proporção de pessoas que residem em domicílio com rede de esgoto sanitário em 52 municípios.

A Tabela 4.12 apresenta os resultados sumarizados dos critérios de adequabilidade. Para todas as medidas analisadas, há uma melhor adequabilidade da distribuição gama unitária inflacionada quando comparada com as outras medidas.

Desta forma, considerando os resultados dos critérios e testes de hipóteses, podemos concluir que a distribuição que melhor representa os dados da proporção de pessoas que reside em domicílios urbanos com acesso a rede de esgoto sanitário é a distribuição gama unitária inflacionada.

Tabela 4.12: Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de pessoas que reside em domicílio com rede de esgoto sanitário em 52 municípios.

Distribuição	AIC	AICc	BIC	BICc	HQ	HQc
BI	42,790	43,641	50,595	52,276	45,782	46,951
KI	42,358	43,209	50,163	51,845	45,350	46,520
GUI	42,315	43,166	50,119	51,801	45,307	46,476

4.6 Proporção de população urbana residente em domicílios ligados a rede de esgoto sanitário nos municípios do estado do Rio Grande do Norte

A variável de interesse (*Esgoto sanitário RN*) é a proporção de pessoas que residem em zona urbana com domicílio conectado à rede de esgoto sanitário no ano de 2016 em 55 municípios do Rio Grande do Norte (<http://www.atlasbrasil.org.br/>). Vale ressaltar que, de acordo com os dados, um município que apresenta valor igual a zero e sete municípios com valor igual a um, ou seja, apresentando 1,82% de inflacionamento em zero e 12,73% de inflacionamento em um. De acordo com a Tabela 4.13, a proporção média de pessoas que residem em domicílios ligados a rede de esgoto sanitário é de 0,5471.


Tabela 4.13: Medidas descritivas da proporção de pessoas que residem em domicílios com rede de esgoto sanitário.

Mínimo	$Q_{1/4}$	Mediana	Média	$Q_{3/4}$	Máximo	DP	CV
0,0000	0,2639	0,4994	0,5471	0,8917	1,0000	0,3411	62,34%

A Tabela 4.14 apresenta os p -valores referentes aos testes de hipóteses realizados para verificar a adequação dos dados às distribuições abordadas, a partir dos seguintes testes de hipótese: Kolmogorov–Smirnov (KS), Anderson–Darling (AD) e Cramér–Von Mises (CVM). Ao nível de significância de 5%, o teste de AD rejeitou a hipótese que os dados seguem a distribuição distribuição BI, KI, ou GUI, já para os testes de KS e CVM não foi rejeitada a hipótese de que os dados seguem a distribuição BI, KI e GUI. A Figura 4.9 apresenta o histograma, em que as barras verticais representam a frequência de zero e a frequência de uns. A Figura 4.10 apresenta os gráficos qq-plot das três distribuições ajustadas, em que o eixo x apresenta as probabilidades teóricas e o eixo y apresenta as probabilidades empíricas. Podemos ver que os resultados destes gráficos não foram tão bom, assim como também podemos observar que o gráfico qq-plot da distribuição beta inflacionada foi um pouco pior que os demais pelo fato dos pontos estarem mais afastado da diagonal em comparação com os outros dois gráficos.

Tabela 4.14: P-valores dos testes de hipóteses

Distribuição	Testes		
	KS	CVM	AD
BI	0,3351	0,3936	$< 1, 1 \times 10^{-05}$
KI	0,3351	0,7669	$< 1, 1 \times 10^{-05}$
GUI	0,3351	0,7671	$< 1, 1 \times 10^{-05}$

**Figura 4.9: Histograma da proporção da população que residem em domicílio com rede esgoto sanitário em 55 municípios.**

A Tabela 4.15 os resultados sumarizados dos critérios de adequabilidade. Para todas as medidas analisadas, há uma melhor adequabilidade da distribuição kumaraswamy inflacionada comparadas com as outras medidas.

Diante do que foi apresentado e a partir dos resultados dos critérios e testes de hipóteses podemos concluir que a distribuição que melhor representa os dados da proporção de pessoas que residem em domicílios ligados a rede de esgoto é a distribuição kumaraswamy inflacionada.




Figura 4.10: QQ-Plot da porcentagem da população que residem em domicílios com rede de esgoto sanitário em 55 municípios.

Tabela 4.15: Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de pessoas que residem em domicílio com rede de esgoto sanitário em 55 municípios.

Distribuição	AIC	AICc	BIC	BICc	HQ	HQc
BI	58,430	59,230	66,459	68,062	61,535	62,645
KI	58,179	58,979	66,209	67,812	61,285	62,395
GUI	58,281	59,081	66,311	67,914	61,386	62,497

4.7 Proporção de votos para o candidato Jair Bolsonaro por seções eleitorais da cidade de Chaves—PA

A variável de interesse (*Eleio*) é a proporção de votos que o candidato Jair Bolsonaro obteve nas seções eleitorais do município de Chaves-PA no segundo turno das eleições no ano de 2022 em 53 seções (<https://www.tse.jus.br/>). Vale ressaltar que, de acordo com os dados, há uma seção que apresentou valor igual a um, ou seja, apresentando 1,89% inflacionamento em um. De acordo com a Tabela 4.16 a proporção média de votos para candidato em questão nas seções do 2º turno é de 0,3274. Mesmo com o inflacionamento em um, a média ficou bem abaixo de 0,5, o que se deve ao fato do inflacionamento ser abaixo de 2% e o valor mínimo dos dados é 0,0833.

Tabela 4.16: Medidas descritivas da proporção de votos para o candidato Jair Bolsonaro.

Mínimo	$Q_{1/4}$	Mediana	Média	$Q_{3/4}$	Máximo	DP	CV
0,0833	0,1829	0,2749	0,3274	0,4148	1,0000	0,1912	58,40%

A Tabela 4.17 apresenta os p -valores referentes aos testes de hipóteses realizados para verificar a adequação dos dados às distribuições abordadas, a partir dos

seguintes testes de hipótese: Kolmogorov–Smirnov (KS), Anderson–Darling (AD) e Cramér–Von Mises (CVM). Ao nível de significância de 5%, o teste de Anderson–Darling (AD) rejeitou a hipótese de que os dados seguem distribuição BI, KI ou GUI, já para os outros dois testes (KS e CVM), não rejeitaram a hipótese de que os dados seguem as distribuições BI, KI e GUI. A Figura 4.11 apresenta o histograma, em que a barra vertical representa a frequência de um. Observando o histograma, é possível entender o motivo em que mesmo com inflacionamento em 1, esses dados teve uma média abaixo de 0,5, os dados estão mais concentrados no intervalo de 0,1 a 0,5. A Figura 4.12 apresenta os gráficos qq-plot das três distribuições ajustadas, em que o eixo x apresenta as probabilidades teóricas e o eixo y apresenta as probabilidades empíricas. Podemos observar que a partir dos gráficos, o da GUI teve um resultado um pouco melhor com exceção dos últimos três pontos.

Tabela 4.17: P-valores dos testes de hipóteses.

Distribuição	Testes		
	KS	CVM	AD
BI	0,4067	0,2686	$< 1,2 \times 10^{-05}$
KI	0,8210	0,5345	$< 1,2 \times 10^{-05}$
GUI	0,7654	0,7044	$< 1,2 \times 10^{-05}$

A Tabela 4.18 apresenta os resultados sumarizados dos critérios de adequabilidade. Para todas medidas analisadas, há uma melhor adequabilidade da distribuição Gama Unitária Inflacionada quando comparadas com as outras medidas.

Desta forma, considerando os resultados dos critérios e testes de hipóteses, podemos concluir que a distribuição que melhor representa os dados da proporção de votos para o candidato Jair Bolsonaro por seções eleitorais do segundo turno na cidade de Chaves–PA é a distribuição gama unitária inflacionada.

Tabela 4.18: Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de votos para o candidato Jair Bolsonaro em 53 seções eleitorais.

Distribuição	AIC	AICc	BIC	BICc	HQ	HQc
BI	−31,1810	−30,691	−25,270	−24,298	−28,908	−28,233
KI	−28,745	−28,255	−22,834	−21,862	−26,472	−25,797
GUI	−32,396	−31,906	−26,485	−25,512	−30,123	−29,447




Figura 4.11: Histograma da proporção de votos para Bolsonaro em 53 seções eleitorais.




Figura 4.12: QQ-Plot da proporção de votos para Bolsonaro em 53 seções eleitorais.

4.8 Proporção de pessoas que residem em domicílios com acesso a energia elétrica

A variável de interesse (*Energia elétrica*) é a proporção de pessoas que residem em domicílio com acesso a energia elétrica no ano de 1991 em 293 municípios do estado de Santa Catarina (<http://www.atlasbrasil.org.br/>). Vale ressaltar que, de acordo com os dados, há 9 municípios que apresentaram valor igual a um, ou

seja, apresentando 3,07% de inflacionamento em um. De acordo com a Tabela 4.19 a proporção média de pessoas que reside em domicílio com acesso a energia elétrica é de 0,8906 e o mínimo observado foi de 0,3570. A Tabela 4.20 apresenta

Tabela 4.19: Medidas descritivas da proporção de pessoas que residem em domicílios com acesso a energia elétrica.

Mínimo	$Q_{1/4}$	Mediana	Média	$Q_{3/4}$	Máximo	DP	CV
0,3570	0,8406	0,9361	0,8906	0,9870	1,0000	0,1283	144,03%

os p -valores dos testes de hipóteses realizados para verificar a adequação dos dados às distribuições abordadas, a partir dos seguintes testes de hipótese: Kolmogorov–Smirnov (KS), Anderson–Darling (AD) e Cramér–Von Mises (CVM). Ao nível de significância de 5%, para o teste de Anderson–Darling(AD) foi rejeitado a hipótese de que os dados seguem as distribuições BI, KI ou GUI, entretanto, para os outros dois testes (KS e CVM), não foi rejeitada a hipótese de que os dados seguem as distribuições BI, KI e GUI. A Figura 4.13 apresenta o histograma, em que a barra vertical representa a frequência de uns. Em comparação com a aplicação anterior, mesmo sendo as duas inflacionadas em 1, esta aplicação tem uma média de 0,89. Quando observamos o histograma, percebemos o motivo da média ser bem próxima de 0,9: os dados estão concentrados no intervalo de 0,9 a 1. A Figura 4.14 apresenta os gráficos qq-plot das três distribuições ajustadas, em que o eixo x apresenta as probabilidades teóricas e o eixo y apresenta as probabilidades empíricas. Observando esses gráficos, podemos notar que no gráfico da GUI houve um melhor resultado, por os pontos do gráfico dessa distribuição ficarem mais próximos da diagonal do que nas outras duas distribuições.

Tabela 4.20: P-valores dos testes de hipóteses.

Distribuição	Testes		
	KS	CVM	AD
BI	0,8338	0,7988	$< 2,1 \times 10^{-06}$
KI	0,5378	0,448	$< 2,1 \times 10^{-06}$
GUI	0,5471	0,5133	$< 2,1 \times 10^{-06}$

A Tabela 4.21 apresenta os resultados sumarizados dos critérios de adequabilidade. Ao analisar os critérios utilizados, percebe-se que a distribuição GUI obteve uma melhor adequabilidade aos dados quando comparadas com as outras medidas.

Desta forma, considerando os resultados dos critérios e testes de hipóteses, podemos concluir que a distribuição que melhor representa os dados da proporção de pessoas que reside em domicílio com acesso à energia elétrica é a distribuição gama unitária inflacionada.




Figura 4.13: Histograma da proporção de pessoas que residem em domicílio com acesso a energia elétrica em 293 municípios.




Figura 4.14: QQ-Plot da proporção de pessoas que residem em domicílio com acesso a energia elétrica em 293 municípios.

Tabela 4.21: Critérios de adequabilidade das distribuições: AIC, AICc, BIC, BICc, HQ e HQc - Dados sobre a proporção de pessoas que reside em domicílios com acesso a energia elétrica por municípios do estado de Santa Catarina.

Distribuição	AIC	AICc	BIC	BICc	HQ	HQc
BI	-611,987	-611,903	-600,946	-600,711	-607,565	-607,421
KI	-611,424	-611,340	-600,383	-600,147	-607,002	-606,857
GUI	-612,043	-611,960	-601,002	-600,766	-607,621	-607,477

Capítulo 5

Conclusão

Quando os dados são gerados pela distribuição beta inflacionada (BI), para os três tipos de inflacionamentos, de acordo com os critérios, foi escolhida com maior frequência a distribuição gama unitária inflacionada (GUI). Para inflacionamento em zero, os melhores resultados foram quando os dados tinham média 0,5 e proporção de inflacionamento de 10%. Já para o inflacionamento em zero e um ou em um, os melhores resultados foram quando os dados tinha média de 0,8 e uma precisão mais alta ($\phi = 50$).

Para os dados gerados pela distribuição kumaraswamy inflacionada (KI), para todos 3 tipos de inflacionamento, de acordo com os critérios, foi escolhida a distribuição KI com maior frequência. Para o inflacionamento em zero, os melhores resultados foram quando os dados tinha uma precisão maior. Para o inflacionamento em zero e um, os melhores resultados foram quando os dados tinha média 0,3 e precisão maior ($\phi = 50$). E para o inflacionamento em um, os melhores resultados foram quando os dados pertenciam aos cenários 6, 7, 8 e 9 com precisão maior.

Para os dados gerados pela distribuição GUI, para os três tipos de inflacionamento, de acordo com os critérios, foi escolhida a distribuição GUI com maior frequência. Para o inflacionamento em zero os melhores resultados foram quando os dados tinham média 0,5, proporção de inflacionamento de 7% ou 10% e uma precisão maior ($\phi = 50$). Para o inflacionamento em zero e um ou em um, os melhores resultados foram quando os dados tinha média 0,5 e uma precisão maior ($\phi = 50$).

Para uma melhor compreensão, a Tabela 5.1 apresenta um pequeno resumo dos melhores cenários e distribuições mais escolhidas a partir dos critérios, para cada tipo de amostra gerada, assim como também algumas características evidentes.

Com relação aos testes de hipóteses, quando os dados são gerados pela distribuição BI, a própria distribuição BI foi mais escolhida. É possível perceber que, quando os dados são inflacionados em zero, os resultados não são tão bons quando a proporção de inflacionamento é 10%. Para os cenários de inflacionamento em zero e um, o teste Cramér-von Mises (CVM) indica que todos cenários têm bons resultados, mas

Tabela 5.1: Melhores cenários e distribuições mais escolhidas de acordo com os critérios.

Amostra	mais escolhida	melhores cenários	características
$y \sim \text{BI}[0,1)$	GUI[0,1)	6	$\phi = 50$ e $\mu = 0,5$
$y \sim \text{GUI}[0,1)$			
$y \sim \text{KI}[0,1)$	KI[0,1)	1	$\phi = 30$ e $\mu = 0,3$
$y \sim \text{BI}[0,1]$	GUI[0,1]	7, 8 e 9	$\phi = 50$ e $\mu = 0,8$
$y \sim \text{GUI}[0,1]$			
$y \sim \text{KI}[0,1]$	KI[0,1]	1, 2 e 3	$\phi = 30$ e $\mu = 0,3$
$y \sim \text{BI}(0,1]$	GUI(0,1]	7,8 e 9	$\phi = 50$ e $\mu = 0,8$
$y \sim \text{GUI}(0,1]$			
$y \sim \text{KI}(0,1]$	KI[0,1)	6, 7, 8 e 9	$\phi = 50$ e $\mu = 0,5; 0,8$

para o teste Kolmogorov-Smirnov (KS) indica que, com uma média 0,8 e proporção de inflacionamento de 10%, os resultados não são tão bons quando o tamanho da amostra é 200. Para os cenários de inflacionamento em um, o teste CVM indicou os melhores os resultados para quando o inflacionamento é 5% ou 7%, enquanto o teste KS indicou apenas quando o inflacionamento é de 5%.

Com relação aos testes de hipóteses, quando os dados são gerados pela distribuição KI, a própria KI foi mais escolhida. É possível perceber que, quando os dados são inflacionados em zero, os melhores resultados para os três testes são quando os dados tem proporção de inflacionamento de 5% ou 7% e uma precisão mais baixa ($\phi = 10$), tanto para média de 0,3 quanto para 0,5. Para os cenários com inflacionamento em zero e um, o teste de CVM indica que todos cenários têm bons resultados, entretanto, para o teste KS indica que todos resultados são bons quando a precisão é mais baixa ($\phi = 10$), com exceção quando a média é 0,8 e a proporção de inflacionamento é de 10% (cenário 9). Para os cenários com inflacionamento em um, o teste de CVM indicou que todos cenários têm bons resultados, enquanto o teste de KS indica que os melhores resultados serão quando a média é 0,5, proporção de inflacionamento de 5% ou 7%, uma precisão mais baixa, e para média de 0,8 o teste KS indicou os cenários em que havia uma proporção de inflacionamento de 5% ou 7%.

Com relação aos testes de hipóteses, quando os dados são gerados pela distribuição GUI, a própria GUI foi a melhor. É possível perceber que, quando os dados são inflacionados em zero, para os três testes todos resultados foram bom com exceção quando a proporção era de 10% de inflacionamento. Para dados com inflacionamento em zero e um, para o teste de KS, os resultados não são tão bons quando a média é 0,8 e a proporção de inflacionamento é de 10%. Ainda para dados com inflacionamento em zero e um, para teste CVM, todos cenários teve bons resultados. Para dados com inflacionamento em um, o teste CVM e KS, os melhores resultados

foram quando os dados tinha uma proporção de inflacionamento de 5% ou 7%.

Para uma melhor compreensão, a Tabela 5.2 apresenta um pequeno resumo dos melhores cenários e distribuições mais escolhidas a partir dos testes de hipótese para cada tipo de amostra gerada, assim como também algumas características evidentes.

Tabela 5.2: Melhores cenários e distribuições mais escolhidas de acordo com os testes de hipótese.

Amostra	mais escolhida	melhores cenários	características
$y \sim \text{BI}[0,1)$	$\text{BI}[0,1)$	1, 2, 4 e 5	5% ou 7% inflacionamento
$y \sim \text{GUI}[0,1)$	$\text{GUI}[0,1)$		
$y \sim \text{KI}[0,1)$	$\text{KI}[0,1)$		
$y \sim \text{BI}[0,1]$	$\text{BI}[0,1]$	1-8	
$y \sim \text{GUI}[0,1]$	$\text{GUI}[0,1]$		
$y \sim \text{KI}[0,1]$	$\text{KI}[0,1]$		
$y \sim \text{BI}(0,1]$	$\text{BI}(0,1]$	4, 5, 7 e 8	5% ou 7% inflacionamento
$y \sim \text{GUI}(0,1]$	$\text{GUI}(0,1]$		
$y \sim \text{KI}(0,1]$	$\text{KI}(0,1]$		

Em relação às aplicações, quando o inflacionamento é em zero e a média é próxima a zero, a distribuição escolhida foi a GUI quando o CV foi maior (130%; 169%. Ainda com inflacionamento em zero, a distribuição BI foi escolhida quando o CV foi próximo 50%. Para a aplicação com inflacionamento em zero e um, em relação aos CV, média e tamanho da amostra, os dois conjuntos de dados das duas aplicações têm características semelhantes, a maior diferença esta na proporção de inflacionamento, a distribuição KI foi escolhida quando a proporção foi próximo a 15% e a GUI quando a proporção foi próximo a 10%. Para aplicação com inflacionamento um, em relação ao CV, média e tamanho da amostra, são um pouco diferentes, mas a proporção de inflacionamento (1, 89% e 3, 07%) são valores semelhantes e, para os dois conjuntos de dados, a GUI foi a escolhida.

Para uma melhor compreensão a Tabela 5.3 é apresentado o resumo das aplicações, na primeira coluna é a primeira aplicação é a 1, a segunda aplicação é a 2 e assim por diante, a segunda coluna apresenta a proporção de inflacionamento, a terceira coluna a distribuição que melhor representou o conjunto de dados, a quarta coluna o coeficiente de variação, a quinta coluna e média do conjunto e na ultima coluna o tamanho do conjunto de dados.

Tabela 5.3: Resumo das aplicações.

Aplicação	% inflacionamento	distribuição	CV	μ	n
1	8,13%	GUI	169,25%	0,0647	209
2	5,83%	BI	49,40%	0,0625	223
3	5,06%	GUI	137,49%	0,1365	178
4	9,61%	GUI	50,67%	0,5987	52
5	14,55%	KI	62,43%	0,5471	55
6	1,89%	GUI	58,40%	0,3274	53
7	3,07%	GUI	144,03%	0,8906	293

Referências Bibliográficas

- [1] AKAIKE, H. Information theory and an extension of the maximum likelihood principle. In: **Selected papers of hirotugu akaike**. New York, NY: Springer New York, 1998. p. 199-213.
- [2] ANDERSON, Theodore W.; DARLING, Donald A. Asymptotic theory of certain "goodness of fit" criteria based on stochastic processes. **The annals of mathematical statistics**, p. 193-212, 1952.
- [3] BAYER, Fábio M.; CRIBARI-NETO, Francisco; SANTOS, Jéssica. Inflated Kumaraswamy regressions with application to water supply and sanitation in Brazil. **Statistica Neerlandica**, v. 75, n. 4, p. 453-481, 2021.
- [4] BARNDORFF-NIELSEN, O. E. JØRGENSEN, B. some parametric models on the simplex. **Journal of Multivariate analysis**, v. 39, n. 1, p. 106-116, 1991.
- [5] BAPAT, Sudeep R.; BHARDWAJ, Rohit. On an inflated Unit-Lindley distribution. **arXiv preprint arXiv:2102.04687**, 2021.
- [6] BERNARDI, P. B. Análise de risco de Investimento Imobiliário por Simulação . 117p. Dissertação de mestrado - UFSC, Florianópolis-SC, 2002.
- [7] BOLFARINE, H.; SANDOVAL, M. C. **Introdução à inferência estatística**, 2ª Ed. Rio de Janeiro: SBM, 2010.
- [8] BROEK, J. Van den. A score test for zero inflation in a Poisson distribution. **Biometrics**, p. 738-743, 1995.
- [9] CHAKRABORTY, Subrata; BHATTACHARJEE, Sahana. Modeling proportion of success in high school leaving examination-A comparative study of Inflated Unit Lindley and Inflated Beta distribution. **arXiv preprint arXiv:2103.08916**, 2021.
- [10] CRIBARI-NETO, F.; SANTOS, J. Inflated Kumaraswamy distributions. **Anais da Academia Brasileira de Ciências**, v. 91, 2019.

- [11] CSÖRGŐ, Sándor; FARAWAY, Julian J. The exact and asymptotic distributions of Cramér-von Mises statistics. **Journal of the Royal Statistical Society Series B: Statistical Methodology**, v. 58, n. 1, p. 221-234, 1996.
- [12] DARLING, Donald A. The kolmogorov-smirnov, cramer-von mises tests. **The Annals of Mathematical Statistics**, v. 28, n. 4, p. 823-838, 1957.
- [13] FERRARI, Silvia; CRIBARI-NETO, Francisco. Beta regression for modelling rates and proportions. **Journal of applied statistics**, v. 31, n. 7, p. 799-815, 2004.
- [14] GOKHALE, D. V.; KULLBACK, S. The minimum discrimination information approach in analyzing categorical data: The minimum discrimination information. **Communications in Statistics-Theory and Methods**, v. 7, n. 10, p. 987-1005, 1978.
- [15] GRASSIA, A. On a family of distributions with argument between 0 and 1 obtained by transformation of the gamma and derived compound distributions. **Australian Journal of Statis**, Wiley Online Library, V.19, n.2, p. 108-114, 1977.
- [16] HALTON, John H. A retrospective and prospective survey of the Monte Carlo method. **Siam review**, v. 12, n. 1, p. 1-63, 1970.
- [17] HANNAN, Edward J.; QUINN, Barry G. The determination of the order of an autoregression. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 41, n. 2, p. 190-195, 1979.
- [18] HELU, Siosaia Langitoto. Statistical model selection criteria and their application to the Stock Synthesis assessment program.1998.
- [19] HURVICH, C M.; TSAI, Chih-Ling. Regression and time series model selection in small samples. **Biometrika**, v. 76, n. 2, p. 297-307, 1989.
- [20] KOLMOGOROFF, Andrey. Confidence limits for an unknown distribution function. **The annals of mathematical statistics**, v. 12, n. 4, p. 461-463, 1941.
- [21] KUMARASWAMY, Ponnambalam. A generalized probability density function double-bounded random processes. **Journal of hydrology**, v. 46, n. 1-2, p. 79-88, 1980.
- [22] MARSAGLIA, George; MARSAGLIA, John. Evaluating the anderson-darling distribution. **Journal of statistical software**, v. 9, p. 1-5, 2004.

- [23] MAZUCHELI, J.; MENEZES, A. F. B.; GHITANY, M. E. The unit-Weibull distribution and associated inference. **J. Appl. Probab. Stat**, v. 13, n. 2, p. 1-22, 2018.
- [24] MAZUCHELI, Josmar; MENEZES, André Felipe; DEY, Sanku. Unit-Gompertz distribution with applications. **Statistica**, v. 79, n. 1, p. 25-43, 2019.
- [25] MITNIK, P. A.; BAEK, S. The Kumaraswamy distribution: median-dispersion re-parameterizations for regression modeling and simulation-based estimation. **Statistical Papers**, v. 54, p. 177-192, 2013.
- [26] MCQUARRIE, Allan D. A small-sample correction for the Schwarz SIC model selection criterion. **Statistics & probability letters**, v. 44, n. 1, p. 79-86, 1999.
- [27] OSPINA, Raydonal. **Modelos de regressão beta inflacionados** 174P. Tese de doutorado - USP, São Paulo: SP, 2008.
- [28] NOBRE, Aline Araújo et al. Multinomial model and zero-inflated gamma model to study time spent on leisure time physical activity: an example of ELSA-Brasil. **Revista de saude publica**, v. 51, p. 76, 2017.
- [29] OSPINA, R.; FERRARI, S. L.P. Inflated beta distributions Statistical papers, v. 51, p. 111-126, 2010.
- [30] RIGBY, Robert A. et al. **Distributions for modeling location, scale, and shape: Using GAMLSS in R**. Chapman and Hall/CRC, 2019.
- [31] RIGBY, Robert A.; STASINOPOULOS, D. Mikis. Generalized additive models for location, scale and shape. **Journal of the Royal Statistical Society Series C: Applied Statistics**, v. 54, n. 3, p. 507-554, 2005.
- [32] RIPLEY, Brian et al. Package ‘mass’. **Cran r**, v. 538, p. 113-120, 2013.
- [33] SANTOS, J. P. R. Modelos kumaraswamy inflacionados. 115p. Tese de doutorado - UFPE, Recife-PE, 2018.
- [34] SCHWARZ, G., Estimating the dimension of a model. **The annals of statistics**, p. 461-464, 1978.
- [35] SILVA, C.R. (2023), **Gráfico de controle do tipo shewhart considerando a distribuição gama unitária inflacionada**. Tese de doutorado - Programa de Pós Graduação em Biometria e Estatística Aplicada, Universidade Federal Rural de Pernambuco.

- [36] SMIRNOFF, N. Sur les écarts de la courbe de distribution empirique. **Matematicheskii Sbornik**, v. 48, n. 1, p. 3-26, 1939.
- [37] SONG, P. X. -K., **Correlated Data Analysis: Modeling, Analytics, and Applications**. Springer Series in Statistics New York: 2007.
- [38] SUGIURA, N. Further analysis of the data by Akaike's information criterion and the finite corrections: further analysis of the data by Akaike's. **Communications in Statistics-theory and Methods**, v. 7, n. 1, p. 13-26, 1978.
- [39] TONG, Edward NC; MUES, Christophe; THOMAS, Lyn. A zero-adjusted gamma model for mortgage loan loss given default. **International Journal of Forecasting**, v. 29, n. 4, p. 548-562, 2013.
- [40] WOŁODZKO, Tymoteusz; WOŁODZKO, Maintainer Tymoteusz. Package 'extraDistr'. 2020.
- [41] YEE, Thomas W. The VGAM package. **R News**, v. 8, n. 2, p. 28-39, 2008.

Apêndice A

Tabela A.1: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 3.

Cenários	ϕ	n	$y \sim \text{BI}[0, 1)$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
1	10	30	95,42	0,95	89,25		95,07	0,00	82,43		94,84	0,79	88,90	
		60	95,27	0,00	83,53		94,55	0,00	70,77		94,76	0,00	84,23	
		100	95,35	0,00	75,95		94,59	0,00	52,27		94,82	0,00	75,35	
		200	95,53	0,00	51,32		93,86	0,00	16,78		95,01	0,00	46,68	
	30	30	95,42	0,00	89,71		95,07	0,00	82,69		94,84	0,00	89,29	
		60	95,27	0,00	84,31		94,55	0,00	71,45		94,76	0,00	85,20	
		100	95,35	0,00	77,67		94,59	0,00	53,92		94,82	0,00	77,14	
		200	95,53	0,00	54,90		93,86	0,00	17,89		95,01	0,00	49,79	
	10	30	95,60	1,32	89,61		95,06	0,00	83,27		94,80	1,24	89,11	
		60	95,33	0,00	84,06		94,31	0,00	71,89		94,72	0,00	84,71	
		100	95,35	0,00	76,38		93,76	0,00	52,53		94,64	0,00	75,88	
		200	95,53	0,00	52,66		91,73	0,00	14,65		94,63	0,00	47,05	
2	30	30	95,60	0,00	90,01		95,06	0,00	83,46		94,80	0,00	89,48	
		60	95,33	0,00	84,75		94,31	0,00	72,25		94,72	0,00	85,51	
		100	95,35	0,00	77,81		93,76	0,00	53,62		94,64	0,00	77,50	
		200	95,53	0,00	56,11		91,73	0,00	15,48		94,63	0,00	49,96	
	10	30	95,78	1,81	90,07		94,88	0,00	83,93		94,78	1,67	89,42	
		60	95,34	0,00	84,68		93,61	0,00	71,07		94,40	0,00	84,69	
		100	95,35	0,00	77,23		91,79	0,00	48,49		94,16	0,00	75,35	
		200	0,00	0,00	0,00		83,53	0,00	7,29		93,00	0,00	43,46	
	30	30	95,78	0,00	90,46		94,88	0,00	84,12		94,78	0,01	89,85	
		60	95,34	0,00	85,28		93,61	0,00	71,34		94,40	0,00	85,63	
		100	95,35	0,00	78,40		91,79	0,00	49,37		94,16	0,00	76,87	
		200	0,00	0,00	0,00		83,53	0,00	7,55		93,00	0,00	45,77	

Tabela A.2: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários ϕ n		$y \sim \text{BI}[0, 1)$											
		% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
		BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
4	10	30	95,42	8,22	80,08	95,07	0,05	56,56		94,84	9,97	80,82	
		60	95,27	0,09	64,57	94,55	0,00	26,82		94,76	0,11	62,31	
		100	95,35	0,00	40,71	94,59	0,00	6,95		94,82	0,00	33,99	
		200	95,53	0,00	6,65	93,86	0,00	0,01		95,01	0,00	3,09	
	50	30	95,42	0,02	80,92	95,07	0,00	58,46		94,84	0,02	81,42	
		60	95,27	0,00	66,07	94,55	0,00	29,55		94,76	0,00	64,23	
		100	95,35	0,00	43,73	94,59	0,00	8,26		94,82	0,00	36,93	
		200	95,53	0,00	8,07	93,86	0,00	0,04		95,01	0,00	4,05	
	10	30	95,60	6,43	80,37	95,06	0,02	57,13		94,80	8,50	81,00	
		60	95,33	0,03	64,45	94,31	0,00	26,52		94,72	0,06	62,43	
		100	95,35	0,00	39,95	93,76	0,00	6,20		94,64	0,00	33,57	
		200	95,53	0,00	6,34	91,73	0,00	0,00		94,63	0,00	2,67	
5	50	30	95,60	0,00	81,21	95,06	0,00	59,08		94,80	0,00	81,69	
		60	95,33	0,00	66,07	94,31	0,00	28,95		94,72	0,00	64,38	
		100	95,35	0,00	42,96	93,76	0,00	7,48		94,64	0,00	36,25	
		200	95,53	0,00	7,89	91,73	0,00	0,01		94,63	0,00	3,58	
	10	30	95,78	3,31	80,61	94,88	0,00	56,35		94,78	3,74	81,06	
		60	95,34	0,00	63,56	93,61	0,00	23,53		94,40	0,00	61,65	
		100	95,35	0,00	39,26	91,80	0,00	3,96		94,16	0,00	31,06	
		200	0,00	0,00	0,00	83,55	0,00	0,00		93,00	0,00	1,55	
6	50	30	95,78	0,00	81,40	94,88	0,00	58,59		94,78	0,00	81,79	
		60	95,34	0,00	65,44	93,61	0,00	26,32		94,40	0,00	63,51	
		100	95,35	0,00	42,20	91,80	0,00	5,12		94,16	0,00	33,88	
		200	0,00	0,00	0,00	83,55	0,00	0,00		93,00	0,00	2,17	

Tabela A.3: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 3.

Cenários ϕ n		$y \sim \text{KI}[0, 1)$											
		% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
		BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
1	10	30	0,00	95,42	0,01	0,00	95,07	0,01		0,00	94,84	0,05	
		60	0,00	95,27	0,00	0,00	94,55	0,00		0,00	94,76	0,00	
		100	0,00	95,35	0,00	0,00	94,59	0,00		0,00	94,82	0,00	
		200	0,00	95,53	0,00	0,00	93,86	0,00		0,00	95,01	0,00	
	30	30	0,00	74,67	0,00	0,00	83,20	0,00		0,00	90,26	0,00	
		60	0,00	39,76	0,00	0,00	62,60	0,00		0,00	83,90	0,00	
		100	0,00	0,00	0,00	0,00	17,36	0,00		0,00	66,02	0,00	
		200	0,00	0,00	0,00	0,00	0,00	0,00		0,00	0,00	0,00	
	10	30	0,00	95,60	0,00	0,00	95,06	0,02		0,00	94,80	0,00	
		60	0,00	95,33	0,00	0,00	94,31	0,00		0,00	94,72	0,00	
		100	0,00	95,35	0,00	0,00	93,76	0,00		0,00	94,64	0,00	
		200	0,00	95,53	0,00	0,00	91,73	0,00		0,00	94,63	0,00	
2	30	30	0,00	75,35	0,00	0,00	86,20	0,00		0,00	90,35	0,00	
		60	0,00	39,39	0,00	0,00	71,01	0,00		0,00	84,63	0,00	
		100	0,00	0,00	0,00	0,00	30,67	0,00		0,00	68,77	0,00	
		200	0,00	0,00	0,00	0,00	0,00	0,00		0,00	0,00	0,00	
	10	30	0,00	95,78	0,00	0,00	94,88	0,02		0,00	94,78	0,03	
		60	0,00	95,34	0,00	0,00	93,61	0,00		0,00	94,40	0,00	
		100	0,00	95,35	0,00	0,00	91,80	0,00		0,00	94,16	0,00	
		200	0,00	0,00	0,00	0,00	83,55	0,00		0,00	93,00	0,00	
	30	30	0,00	77,37	0,00	0,00	87,95	0,00		0,00	90,85	0,00	
		60	0,00	46,28	0,00	0,00	76,14	0,00		0,00	85,21	0,00	
		100	0,00	5,84	0,00	0,00	37,95	0,00		0,00	69,95	0,00	
		200	0,00	0,00	0,00	0,00	0,00	0,00		0,00	0,00	0,00	

Tabela A.4: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{KI}[0, 1)$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
4	10	30	0,26	95,42	29,53		0,18	95,07	31,62		0,53	94,84	37,36	
		60	0,00	95,27	0,25		0,00	94,55	0,08		0,00	94,76	0,42	
		100	0,00	95,35	0,00		0,00	94,59	0,00		0,00	94,82	0,00	
		200	0,00	95,53	0,00		0,00	93,86	0,00		0,00	95,01	0,00	
	50	30	0,00	94,87	0,00		0,00	94,59	0,00		0,00	94,57	0,00	
		60	0,00	93,56	0,00		0,00	93,56	0,00		0,00	94,48	0,00	
		100	0,00	91,43	0,00		0,00	93,21	0,00		0,00	94,21	0,00	
		200	0,00	85,75	0,00		0,00	90,99	0,00		0,00	93,67	0,00	
	10	30	0,08	95,60	18,97		0,10	95,06	21,63		0,21	94,80	25,47	
		60	0,00	95,33	0,07		0,00	94,31	0,02		0,00	94,72	0,11	
		100	0,00	95,35	0,00		0,00	93,76	0,00		0,00	94,64	0,00	
		200	0,00	95,53	0,00		0,00	91,73	0,00		0,00	94,63	0,00	
5	50	30	0,00	94,37	0,00		0,00	94,91	0,00		0,00	94,59	0,00	
		60	0,00	93,37	0,00		0,00	93,80	0,00		0,00	94,41	0,00	
		100	0,00	91,27	0,00		0,00	92,69	0,00		0,00	94,02	0,00	
		200	0,00	84,87	0,00		0,00	88,65	0,00		0,00	93,33	0,00	
	10	30	0,02	95,78	7,47		0,05	94,88	7,68		0,10	94,78	9,79	
		60	0,00	95,34	0,03		0,00	93,61	0,00		0,00	94,40	0,02	
		100	0,00	95,35	0,00		0,00	91,80	0,00		0,00	94,16	0,00	
		200	0,00	0,00	0,00		0,00	83,55	0,00		0,00	93,00	0,00	
6	30	30	0,00	94,46	0,00		0,00	94,56	0,00		0,00	94,46	0,00	
		60	0,00	93,60	0,00		0,00	93,03	0,00		0,00	94,09	0,00	
		100	0,00	90,96	0,00		0,00	90,68	0,00		0,00	93,54	0,00	
		200	0,00	0,00	0,00		0,00	78,69	0,00		0,00	91,36	0,00	

Tabela A.5: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 3.

Cenários	ϕ	n	$y \sim \text{GUI}[0, 1)$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
1	10	30	93,43	3,27	95,42		95,20	0,00	95,07		94,43	2,80	94,84	
		60	89,12	0,01	95,27		88,29	0,00	94,55		90,28	0,00	94,76	
		100	81,30	0,00	95,35		72,56	0,00	94,59		81,12	0,00	94,82	
		200	54,44	0,00	95,53		26,87	0,00	93,86		48,50	0,00	95,01	
	30	30	93,85	0,00	95,42		95,55	0,00	95,07		94,82	0,00	94,84	
		60	90,11	0,00	95,27		89,12	0,00	94,55		91,10	0,00	94,76	
		100	83,52	0,00	95,35		74,35	0,00	94,59		83,26	0,00	94,82	
		200	58,50	0,00	95,53		29,05	0,00	93,86		52,76	0,00	95,01	
	10	30	93,54	4,89	95,60		95,05	0,00	95,06		94,37	5,46	94,80	
		60	89,30	0,02	95,33		88,07	0,00	94,31		90,35	0,03	94,72	
		100	81,67	0,00	95,35		71,93	0,00	93,76		81,27	0,00	94,64	
		200	55,72	0,00	95,53		23,00	0,00	91,73		49,13	0,00	94,63	
2	30	30	93,89	0,00	95,60		95,39	0,00	95,06		94,77	0,00	94,80	
		60	90,28	0,00	95,33		88,91	0,00	94,31		91,08	0,00	94,72	
		100	83,54	0,00	95,35		73,43	0,00	93,76		83,17	0,00	94,64	
		200	59,55	0,00	95,53		24,55	0,00	91,73		52,81	0,00	94,63	
	10	30	93,51	3,31	95,78		94,72	0,00	94,88		94,24	3,57	94,78	
		60	89,45	0,01	95,34		86,74	0,00	93,61		89,95	0,01	94,40	
		100	82,17	0,00	95,35		66,83	0,00	91,79		80,55	0,00	94,16	
		200	0,00	0,00	0,00		11,24	0,00	83,53		44,96	0,00	93,00	
	30	30	93,99	0,00	95,78		94,96	0,00	94,88		94,51	0,01	94,78	
		60	90,46	0,00	95,34		87,46	0,00	93,61		90,61	0,00	94,40	
		100	83,81	0,00	95,35		67,96	0,00	91,79		82,27	0,00	94,16	
		200	0,00	0,00	0,00		11,69	0,00	83,53		48,28	0,00	93,00	

Tabela A.6: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{GUI}[0, 1)$											
			% de não rejeição de KS			% de não rejeição de AD			% de não rejeição de CVM					
			BI	KI	GUI	BI	KI	GUI	BI	KI	GUI	BI	KI	GUI
4	10	30	89,69	23,30	95,42	90,69	1,52	95,07	91,43	27,63	94,84			
		60	75,36	2,49	95,27	61,25	0,01	94,55	71,98	3,02	94,76			
		100	47,49	0,05	95,35	19,12	0,00	94,59	36,57	0,07	94,82			
		200	5,06	0,00	95,53	0,13	0,00	93,86	1,57	0,00	95,01			
	50	30	90,06	0,00	95,42	91,22	0,00	95,07	91,88	0,05	94,84			
		60	76,82	0,00	95,27	63,60	0,00	94,55	74,11	0,00	94,76			
		100	50,49	0,00	95,35	22,20	0,00	94,59	40,20	0,00	94,82			
		200	6,63	0,00	95,53	0,17	0,00	93,86	2,34	0,00	95,01			
	10	30	89,72	14,98	95,60	90,42	0,59	95,06	91,29	16,92	94,80			
		60	74,92	0,83	95,33	60,35	0,00	94,31	71,92	1,00	94,72			
		100	46,86	0,00	95,35	17,28	0,00	93,76	35,95	0,00	94,64			
		200	4,90	0,00	95,53	0,06	0,00	91,73	1,40	0,00	94,63			
5	50	30	90,07	0,00	95,60	90,94	0,00	95,06	91,69	0,00	94,80			
		60	76,79	0,00	95,33	63,05	0,00	94,31	73,98	0,00	94,72			
		100	49,92	0,00	95,35	10,19	0,00	93,76	40,01	0,00	94,64			
		200	6,60	0,00	95,53	0,09	0,00	91,73	2,08	0,00	94,63			
	10	30	89,54	4,05	95,78	89,80	0,10	94,88	90,83	3,00	94,78			
		60	74,32	0,00	95,34	55,87	0,00	93,61	70,56	0,00	94,40			
		100	45,54	0,00	95,35	11,25	0,00	91,80	32,96	0,00	94,16			
		200	0,00	0,00	0,00	0,00	0,00	83,55	0,00	0,00	93,00			
6	50	30	89,85	0,00	95,78	90,47	0,00	94,88	91,17	0,00	94,78			
		60	76,22	0,00	95,34	59,14	0,00	93,61	72,85	0,00	94,40			
		100	49,23	0,00	95,35	14,09	0,00	91,80	36,94	0,00	94,16			
		200	0,00	0,00	0,00	0,00	0,00	83,55	1,25	0,00	93,00			

Tabela A.7: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 3.

Cenários		$y \sim \text{BI}[0, 1]$									
		% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM	
		BI	KI	GUI		BI	KI	GUI		BI	GUI
1	10	30	95,36	0,49	89,33	61,20	0,00	54,57	94,84	0,36	89,05
		60	95,24	0,00	83,95	38,40	0,00	31,68	94,80	0,00	84,83
		100	95,35	0,00	76,69	21,31	0,00	14,26	94,90	0,00	76,53
		200	95,53	0,00	53,11	4,72	0,00	1,60	95,12	0,00	49,75
	30	30	95,36	0,00	89,57	61,20	0,00	55,07	94,84	0,05	89,50
		60	95,24	0,00	84,79	38,40	0,00	32,32	94,80	0,00	85,74
		100	95,35	0,00	78,67	21,31	0,00	15,16	94,90	0,00	78,40
		200	95,53	0,00	57,08	4,72	0,00	1,83	95,12	0,00	53,47
	10	30	95,55	0,72	89,82	50,89	0,00	46,14	94,84	0,57	89,38
		60	95,34	0,00	84,53	26,12	0,00	22,16	94,76	0,00	85,61
		100	95,35	0,00	77,55	11,34	0,00	8,01	94,81	0,00	77,78
		200	95,53	0,00	55,24	1,38	0,00	0,46	94,98	0,00	52,33
2	30	30	95,55	0,00	90,13	50,89	0,00	46,65	94,84	0,00	89,55
		60	95,34	0,00	85,47	26,12	0,00	22,68	94,76	0,00	86,43
		100	95,35	0,00	79,45	11,34	0,00	8,49	94,81	0,00	79,64
		200	95,53	0,00	59,13	1,38	0,00	0,55	94,98	0,00	56,23
	10	30	95,72	1,29	90,30	38,38	0,00	35,40	94,79	0,90	89,78
		60	95,38	0,00	85,39	15,30	0,00	13,36	94,65	0,00	86,38
		100	95,35	0,00	78,64	4,26	0,00	3,17	94,56	0,00	79,29
		200	95,53	0,00	58,27	0,17	0,00	0,05	94,52	0,00	55,13
	30	30	95,72	0,00	90,85	38,38	0,00	35,74	94,79	0,00	90,34
		60	95,38	0,00	86,23	15,30	0,00	13,72	94,65	0,00	87,16
		100	95,35	0,00	86,23	4,26	0,00	13,72	94,56	0,00	87,16
		200	95,53	0,00	6,71	0,17	0,00	0,06	94,52	0,00	58,73

Tabela A.8: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários ϕ n		$y \sim \text{BI}[0, 1]$										
		% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM		
		BI	KI	GUI		BI	KI	GUI		BI	KI	GUI
4	10	30	95,38	8,87	81,64	44,98	0,13	34,34		94,84	8,32	82,43
		60	95,23	0,14	68,16	20,52	0,00	11,15		94,80	0,06	67,05
		100	95,35	0,00	47,84	7,36	0,00	1,94		94,87	0,00	42,31
		200	95,53	0,00	59,13	1,38	0,00	0,55		94,98	0,00	56,23
	50	30	95,38	0,01	82,31	44,98	0,00	34,82		94,84	0,01	83,08
		60	95,23	0,00	69,52	20,52	0,00	11,65		94,80	0,00	68,92
		100	95,35	0,00	50,20	7,36	0,00	2,18		94,87	0,00	44,89
		200	95,53	0,00	12,75	0,60	0,00	0,03		95,09	0,00	7,68
	10	30	95,53	10,15	82,62	32,81	0,25	26,55		94,84	10,00	83,43
		60	95,33	0,18	69,90	11,04	0,00	6,90		94,70	0,12	69,49
		100	95,35	0,00	50,00	2,65	0,00	0,82		94,81	0,00	46,00
		200	95,53	0,00	12,89	0,03	0,00	0,00		95,02	0,00	7,91
5	50	30	95,53	0,00	83,20	32,81	0,00	26,76		94,84	0,02	84,01
		60	95,33	0,00	71,18	11,04	0,00	7,13		94,70	0,00	71,03
		100	95,35	0,00	52,14	2,65	0,00	0,89		94,81	0,00	48,90
		200	95,53	0,00	14,67	0,03	0,00	0,00		95,02	0,00	9,69
	10	30	95,74	11,60	83,88	20,52	0,39	35,40		94,77	12,72	84,59
		60	95,38	0,29	71,88	4,21	0,00	10,53		94,58	0,14	72,55
		100	95,31	0,00	53,12	0,55	0,00	1,64		94,67	0,00	51,01
		200	95,31	0,00	16,06	0,00	0,00	0,00		94,71	0,00	10,69
	6	30	95,74	0,02	84,48	20,52	0,00	36,00		94,77	0,05	85,13
		60	95,38	0,00	73,07	4,21	0,00	10,87		94,58	0,00	73,92
		100	95,31	0,00	55,68	0,55	0,00	1,82		94,67	0,00	53,89
		200	95,31	0,00	18,40	0,00	0,00	0,00		94,71	0,00	12,64

Tabela A.9: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 8.

Cenários ϕ n		$y \sim \text{BI}[0, 1]$											
		% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
		BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
7	10	30	95,40	49,98	25,25	28,19	11,20	2,11		94,85	49,82	22,74	
		60	95,22	39,74	2,37	8,07	3,61	0,01		94,72	40,64	1,20	
		100	95,33	16,17	0,03	1,52	0,30	0,00		94,83	15,94	0,01	
		200	95,53	0,02	0,00	0,02	0,00	0,00		95,00	0,01	0,00	
	50	30	95,40	3,27	31,29	28,19	0,02	2,48		94,85	3,81	27,53	
		60	95,22	0,03	3,48	8,07	0,00	0,02		94,72	0,03	1,99	
		100	95,33	0,00	0,05	1,52	0,00	0,00		94,83	0,00	0,02	
		200	95,53	0,00	0,00	0,02	0,00	0,00		95,00	0,00	0,00	
	10	30	95,59	45,57	28,36	16,93	7,45	2,19		94,74	44,68	26,22	
		60	95,30	42,47	3,19	2,94	1,74	0,01		94,60	43,76	1,83	
		100	95,24	18,27	0,06	0,24	0,10	0,00		94,67	18,61	0,03	
		200	94,65	0,00	0,00	0,00	0,00	0,00		94,81	0,00	0,00	
8	50	30	95,59	3,39	34,62	16,93	0,03	2,33		94,74	4,17	31,04	
		60	95,30	0,01	4,79	2,94	0,00	0,01		94,60	0,01	2,89	
		100	95,24	0,00	0,08	0,24	0,00	0,00		94,67	0,00	0,02	
		200	94,65	0,00	0,00	0,00	0,00	0,00		94,81	0,00	0,00	
	10	30	95,63	39,56	32,98	7,72	3,75	2,51		94,53	37,75	31,44	
		60	94,81	9,46	4,81	0,63	0,13	0,05		94,23	9,31	2,97	
		100	92,81	1,05	0,11	0,02	0,00	0,00		94,14	0,88	0,05	
		200	79,17	0,00	0,00	0,00	0,00	0,00		93,75	0,00	0,00	
9	50	30	95,63	3,20	39,17	7,72	0,05	2,90		94,53	4,81	36,34	
		60	94,81	0,00	6,88	0,63	0,00	0,05		94,23	0,01	4,38	
		100	92,81	0,00	0,19	0,02	0,00	0,00		94,14	0,00	0,07	
		200	79,17	0,00	0,00	0,00	0,00	0,00		93,75	0,00	0,00	

Tabela A.10: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 3.

Cenários	ϕ	n	$y \sim \text{KI}[0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
1	10	30	0,16	95,36	2,00		0,00	61,20	0,02		0,08	94,84	1,17	
		60	0,00	95,24	0,00		0,00	38,40	0,00		0,00	94,80	0,00	
		100	0,00	95,35	0,00		0,00	21,31	0,00		0,00	94,90	0,00	
		200	0,00	95,53	0,00		0,00	4,72	0,00		0,00	95,12	0,00	
	30	30	0,00	73,44	0,00		0,00	50,41	0,00		0,00	90,25	0,00	
		60	0,00	38,86	0,00		0,00	21,98	0,00		0,00	84,24	0,00	
		100	0,00	0,00	0,00		0,00	1,80	0,00		0,00	66,21	0,00	
		200	0,00	0,00	0,00		0,00	0,00	0,00		0,00	0,00	0,00	
	10	30	0,48	95,55	3,42		0,00	50,89	0,05		0,23	94,84	2,53	
		60	0,00	95,34	0,00		0,00	26,12	0,00		0,00	94,76	0,00	
		100	0,00	95,35	0,00		0,00	11,34	0,00		0,00	94,81	0,00	
		200	0,00	95,53	0,00		0,00	1,38	0,00		0,00	94,98	0,00	
2	30	30	0,00	73,47	0,02		0,00	44,20	0,00		0,00	90,59	0,02	
		60	0,00	45,57	0,00		0,00	17,06	0,00		0,00	85,11	0,00	
		100	0,00	0,00	0,00		0,00	2,34	0,00		0,00	69,65	0,00	
		200	0,00	0,00	0,00		0,00	0,00	0,00		0,00	0,00	0,00	
	10	30	1,10	95,72	6,12		0,00	38,38	0,04		1,05	94,79	5,47	
		60	0,00	95,38	0,00		0,00	15,30	0,00		0,00	94,65	0,00	
		100	0,00	95,35	0,00		0,00	4,26	0,00		0,00	94,56	0,00	
		200	0,00	95,53	0,00		0,00	0,17	0,00		0,00	94,52	0,00	
3	30	30	0,02	78,75	0,06		0,00	34,37	0,00		0,03	90,97	0,11	
		60	0,00	46,97	0,00		0,00	11,09	0,00		0,00	86,07	0,00	
		100	0,00	5,36	0,00		0,00	1,32	0,00		0,00	73,36	0,00	
		200	0,00	0,00	0,00		0,00	0,00	0,00		0,00	0,00	0,00	

Tabela A.11: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{KI}[0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
4	10	30	8,49	95,38	60,16		0,11	44,98	17,93		5,73	94,84	61,75	
		60	0,03	95,23	10,66		0,00	20,52	0,05		0,01	94,80	8,06	
		100	0,00	95,35	0,16		0,00	7,36	0,00		0,00	94,87	0,08	
		200	0,00	95,53	0,00		0,00	0,60	0,00		0,00	95,09	0,00	
	50	30	0,01	94,53	0,16		0,00	44,58	0,00		0,00	94,55	0,09	
		60	0,00	93,16	0,00		0,00	20,29	0,00		0,00	94,46	0,00	
		100	0,00	91,26	0,00		0,00	7,24	0,00		0,00	94,23	0,00	
		200	0,00	86,29	0,00		0,00	0,58	0,00		0,00	93,83	0,00	
	10	30	11,91	95,53	63,05		0,02	32,81	12,69		9,20	94,84	65,22	
		60	0,02	95,33	13,64		0,00	11,04	0,01		0,01	94,70	11,64	
		100	0,00	95,35	0,47		0,00	2,65	0,00		0,00	94,81	0,17	
		200	0,00	95,53	0,00		0,00	0,03	0,00		0,00	95,02	0,00	
5	50	30	0,02	94,82	0,39		0,00	32,53	0,00		0,00	94,57	0,29	
		60	0,00	93,65	0,00		0,00	10,94	0,00		0,00	94,49	0,00	
		100	0,00	91,09	0,00		0,00	2,60	0,00		0,00	94,30	0,00	
		200	0,00	85,99	0,00		0,00	0,03	0,00		0,00	93,80	0,00	
	10	30	17,74	95,74	66,71		0,02	20,52	10,60		15,48	94,77	69,62	
		60	0,17	95,38	18,72		0,00	4,21	0,00		0,05	94,58	17,72	
		100	0,00	95,31	1,27		0,00	0,55	0,00		0,00	94,67	0,70	
		200	0,00	95,31	0,00		0,00	0,00	0,00		0,00	94,71	0,00	
6	50	30	0,07	95,24	1,01		0,00	20,36	0,00		0,04	94,55	0,94	
		60	0,00	93,96	0,00		0,00	4,16	0,00		0,00	94,41	0,00	
		100	0,00	91,76	0,00		0,00	0,53	0,00		0,00	93,98	0,00	
		200	0,00	87,04	0,00		0,00	0,00	0,00		0,00	93,47	0,00	

Tabela A.12: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 8.

Cenários	ϕ	n	$y \sim \text{KI}[0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
7	10	30	71,05	95,40	76,43		15,11	28,19	16,76		73,36	94,85	77,60	
		60	36,25	95,22	56,46		0,26	8,07	2,47		38,04	94,72	54,56	
		100	10,17	95,33	30,52		0,00	1,52	0,08		9,64	94,83	25,51	
		200	0,11	95,53	2,55		0,00	0,02	0,00		0,00	95,00	1,20	
	50	30	2,85	95,40	88,86		0,00	28,19	23,86		1,98	94,85	91,22	
		60	0,00	95,22	68,53		0,00	8,07	68,53		0,00	94,72	76,09	
		100	0,00	95,33	36,24		0,00	1,52	0,03		0,00	94,83	47,21	
		200	0,00	95,53	2,76		0,00	0,02	0,00		0,00	95,00	4,95	
	10	30	72,41	95,59	77,83		7,61	16,93	10,60		74,72	94,74	78,82	
		60	39,93	95,30	58,74		0,04	2,94	1,10		41,81	94,60	57,18	
		100	12,96	95,24	32,90		0,00	0,24	0,02		12,52	94,67	28,26	
		200	0,15	94,65	3,43		0,00	0,00	0,00		0,15	94,81	1,72	
8	50	30	5,10	95,59	89,04		0,00	16,93	13,42		3,70	94,74	91,31	
		60	0,00	95,30	70,25		0,00	2,94	0,47		0,00	94,60	77,28	
		100	0,00	95,24	39,83		0,00	0,24	0,00		0,00	94,67	51,03	
		200	0,00	94,65	3,99		0,00	0,00	0,00		0,00	94,81	6,73	
	10	30	74,82	95,63	79,78		2,44	7,72	13,83		76,55	94,53	80,18	
		60	43,85	94,81	61,76		0,00	0,63	1,09		46,73	94,23	60,60	
		100	15,07	92,81	36,07		0,00	0,02	0,04		16,08	94,14	32,11	
		200	0,04	79,17	4,67		0,00	0,00	0,00		0,16	93,75	2,66	
9	50	30	8,75	95,63	88,92		0,00	7,72	14,11		6,94	94,53	91,44	
		60	0,00	94,81	71,57		0,00	0,63	0,12		0,00	94,23	79,13	
		100	0,00	92,81	42,40		0,00	0,02	0,00		0,00	94,14	55,13	
		200	0,00	79,17	1,91		0,00	0,00	0,00		0,00	93,75	8,02	

Tabela A.13: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 3.

Cenários	ϕ	n	$y \sim \text{GUI}[0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
1	10	30	93,66	2,28	95,36		60,98	0,05	61,20		94,69	2,43	94,84	
		60	89,55	0,00	95,24		35,26	0,00	38,40		90,80	0,00	94,80	
		100	82,34	0,00	95,35		15,24	0,00	21,31		82,52	0,00	94,90	
		200	55,96	0,00	95,53		0,82	0,00	4,72		51,83	0,00	95,12	
	30	30	93,97	0,00	95,36		60,98	0,00	61,20		94,95	0,00	94,80	
		60	90,68	0,00	95,24		35,57	0,00	38,40		91,68	0,00	94,80	
		100	84,31	0,00	95,35		15,54	0,00	21,31		84,56	0,00	94,90	
		200	60,84	0,00	95,53		0,93	0,00	4,72		56,25	0,00	95,12	
	10	30	93,82	4,53	95,55		50,73	0,10	50,89		94,69	3,32	94,84	
		60	89,99	0,00	95,34		24,05	0,00	26,12		91,06	0,00	94,76	
		100	82,82	0,00	95,35		7,88	0,00	11,34		83,44	0,00	94,81	
		200	58,07	0,00	95,53		0,19	0,00	1,38		54,92	0,00	94,98	
2	30	30	94,10	0,00	95,55		50,67	0,00	50,89		94,98	0,02	94,84	
		60	90,90	0,00	95,34		24,06	0,00	26,12		91,87	0,00	94,76	
		100	84,71	0,00	95,35		8,00	0,00	11,34		85,32	0,00	94,81	
		200	62,23	0,00	95,53		0,18	0,00	1,38		54,19	0,00	94,98	
	10	30	94,07	6,51	95,72		38,21	0,25	38,38		94,68	5,32	94,79	
		60	90,42	0,06	95,38		13,99	0,00	15,30		91,28	0,00	94,65	
		100	83,58	0,00	95,35		2,91	0,00	4,26		84,27	0,00	94,56	
		200	61,11	0,00	95,53		0,02	0,00	0,17		57,48	0,00	94,52	
	30	30	94,35	0,02	95,72		38,20	0,00	38,38		94,95	0,04	94,79	
		60	91,21	0,00	95,38		13,85	0,00	15,30		92,04	0,00	94,65	
		100	85,03	0,00	95,35		2,88	0,00	4,26		85,98	0,00	94,56	
		200	65,01	0,00	95,53		0,03	0,00	0,17		61,47	0,00	94,52	

Tabela A.14: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{GUI}[0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
4	10	30	90,87	48,10	95,38		41,77	11,38	44,98		92,16	50,26	94,84	
		60	78,55	13,98	95,23		10,97	0,57	20,52		77,00	12,11	94,80	
		100	54,64	1,24	95,35		0,76	0,00	7,36		46,23	0,62	94,87	
		200	9,86	0,00	95,53		0,00	0,00	0,60		4,32	0,00	95,09	
	50	30	91,18	0,55	95,38		41,77	0,00	44,98		92,47	0,41	94,84	
		60	79,69	0,00	95,23		11,57	0,00	20,52		78,58	0,00	94,80	
		100	57,40	0,00	95,35		0,97	0,00	7,36		49,76	0,00	94,87	
		200	11,96	0,00	95,53		0,00	0,00	0,60		5,44	0,00	95,09	
	10	30	91,19	50,95	95,53		30,16	11,50	32,81		92,45	53,60	94,84	
		60	79,67	16,45	95,33		5,48	0,56	11,04		78,70	14,33	94,70	
		100	56,65	1,72	95,35		0,27	0,00	2,65		50,60	1,03	94,81	
		200	11,93	0,00	95,53		0,00	0,00	0,03		5,94	0,00	95,02	
5	50	30	91,43	0,61	95,53		30,38	0,01	32,81		92,81	0,62	94,84	
		60	80,71	0,00	95,33		5,81	0,00	11,04		80,06	0,00	94,70	
		100	59,18	0,00	95,35		0,35	0,00	2,65		53,38	1,00	94,81	
		200	14,38	0,00	95,53		0,00	0,00	0,03		7,52	0,00	95,02	
	10	30	91,65	44,09	95,74		18,73	5,76	49,19		92,91	49,54	94,77	
		60	81,04	10,37	95,38		1,79	0,09	20,65		80,99	12,13	94,58	
		100	59,55	0,67	95,31		0,03	0,01	8,90		55,48	0,80	94,67	
		200	15,77	0,00	95,31		0,00	0,00	0,26		8,91	0,00	94,71	
6	50	30	91,94	0,87	95,74		18,84	0,01	49,19		93,10	0,87	94,77	
		60	81,85	0,00	95,38		1,88	0,00	20,65		82,08	0,00	94,58	
		100	61,84	0,00	95,31		0,04	0,00	8,90		58,38	0,00	94,67	
		200	18,29	0,00	95,31		0,00	0,00	0,26		10,79	0,00	94,71	

Tabela A.15: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 8.

Cenários	ϕ	n	$y \sim \text{GUI}[0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
7	10	30	28,39	87,22	95,40		0,43	24,34	28,19		22,12	89,00	94,85	
		60	1,09	66,34	95,22		0,00	2,13	8,07		0,26	62,95	94,72	
		100	0,01	31,45	95,33		0,00	0,03	1,52		0,00	23,40	94,83	
		200	0,00	0,96	95,53		0,00	0,00	0,02		0,00	0,34	95,00	
	50	30	40,76	80,73	95,40		1,15	24,35	28,19		30,83	82,79	94,85	
		60	2,49	64,37	95,22		0,00	6,02	8,07		0,55	69,72	94,72	
		100	0,01	40,93	95,33		0,00	0,80	1,52		0,00	48,68	94,83	
		200	0,00	7,14	95,53		0,00	0,00	0,02		0,00	10,81	95,00	
	10	30	33,29	88,17	95,59		0,10	14,40	16,93		27,33	89,62	94,74	
		60	1,94	68,75	95,30		0,00	0,58	2,94		0,44	65,85	94,60	
		100	0,02	34,62	95,24		0,00	0,00	0,24		0,00	26,87	94,67	
		200	0,00	1,38	94,65		0,00	0,00	0,00		0,00	0,59	94,81	
8	50	30	44,56	81,77	95,59		0,49	15,75	16,93		36,90	83,55	94,74	
		60	3,86	66,18	95,30		0,00	2,54	2,94		1,06	71,39	94,60	
		100	0,1	43,25	95,24		0,00	0,19	0,24		0,00	51,57	94,67	
		200	0,00	8,94	94,65		0,00	0,00	0,00		0,00	13,02	94,81	
	10	30	39,32	89,28	95,63		0,04	6,33	25,52		34,89	90,30	94,53	
		60	3,43	71,02	94,81		0,00	0,13	4,05		1,07	69,17	94,23	
		100	0,01	38,25	92,81		0,00	0,00	0,62		0,00	31,86	94,14	
		200	0,00	1,91	79,17		0,00	0,00	0,00		0,00	0,82	93,75	
9	50	30	50,43	82,96	95,63		0,15	7,64	25,52		44,21	84,28	94,53	
		60	6,16	68,26	94,81		0,00	0,58	4,05		2,04	73,06	94,23	
		100	0,05	46,91	92,81		0,00	0,03	0,62		0,00	54,64	94,14	
		200	0,00	12,02	79,17		0,00	0,00	0,00		0,00	16,12	93,75	

Tabela A.16: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{BI}(0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
4	10	30	95,48	15,28	83,60		20,41	0,21	14,88		94,78	13,02	83,78	
		60	95,25	0,41	72,29		4,21	0,00	2,17		94,62	0,15	70,99	
		100	95,31	0,00	54,47		0,56	0,00	0,11		94,73	0,00	49,10	
		200	95,31	0,00	16,50		0,00	0,00	0,00		94,90	0,00	9,82	
	50	30	95,48	0,02	84,20		20,41	0,00	15,31		94,74	0,02	84,36	
		60	95,25	0,00	73,40		4,21	0,00	2,24		94,62	0,00	72,42	
		100	95,31	0,00	56,78		0,56	0,00	0,16		94,73	0,00	51,72	
		200	95,31	0,00	18,54		0,00	0,00	0,00		94,90	0,00	11,83	
	10	30	95,56	13,99	85,11		10,77	0,06	8,01		94,63	12,75	84,91	
		60	95,12	0,38	74,92		1,24	0,00	0,65		94,38	0,18	73,67	
		100	94,42	0,00	58,51		0,06	0,00	0,02		94,35	0,00	54,26	
		200	89,14	0,00	20,65		0,00	0,00	0,00		94,36	0,00	13,48	
5	50	30	95,56	0,00	85,54		10,77	0,00	8,24		94,63	0,00	85,53	
		60	95,12	0,00	75,92		1,24	0,00	0,70		94,38	0,00	75,20	
		100	94,42	0,00	60,42		0,06	0,00	0,02		94,35	0,00	56,78	
		200	89,14	0,00	23,18		0,00	0,00	0,00		94,36	0,00	15,85	
	10	30	95,25	8,69	86,59		3,93	0,0,00	2,97		94,23	8,62	85,88	
		60	92,32	0,16	76,92		0,13	0,00	0,06		93,77	0,09	76,42	
		100	84,05	0,00	59,40		0,00	0,00	0,00		93,34	0,00	58,59	
		200	45,03	0,00	16,89		0,00	0,00	0,00		91,76	0,00	17,75	
6	50	30	95,25	0,00	87,09		3,93	0,00	3,04		94,23	0,00	86,19	
		60	92,32	0,00	77,84		0,13	0,00	0,09		93,77	0,00	77,58	
		100	84,05	0,00	61,26		0,00	0,00	0,00		93,34	0,00	60,82	
		200	45,03	0,00	18,80		0,00	0,00	0,00		91,76	0,00	20,37	

Tabela A.17: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 8.

Cenários	ϕ	n	$y \sim \text{BI}(0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
7	10	30	95,48	79,84	29,38		20,41	16,62	1,04		94,78	80,62	26,13	
		60	95,25	64,06	3,43		4,21	2,60	0,01		94,62	64,48	1,84	
		100	95,31	42,58	0,06		0,56	0,26	0,00		94,73	40,24	0,03	
		200	95,31	8,60	0,00		0,00	0,00	0,00		94,90	5,89	0,00	
	50	30	95,48	8,19	35,06		20,41	0,10	1,17		94,78	5,77	30,59	
		60	95,25	0,03	5,05		4,21	0,00	0,01		94,62	0,02	2,93	
		100	95,31	0,00	0,13		0,56	0,00	0,00		94,73	0,00	0,02	
		200	95,31	0,00	0,00		0,00	0,00	0,00		94,90	0,00	0,00	
	10	30	95,56	83,29	33,97		10,77	8,86	0,97		94,63	84,16	31,23	
		60	95,12	71,35	5,35		1,24	0,78	0,00		94,38	71,83	3,04	
		100	94,42	52,81	0,17		0,06	0,03	0,00		94,35	50,29	0,05	
		200	89,14	16,28	0,00		0,00	0,00	0,00		94,36	10,91	0,00	
8	50	30	95,56	9,21	39,28		10,77	0,06	0,99		94,63	6,26	35,33	
		60	95,12	0,08	7,37		1,24	0,00	0,00		94,38	0,01	4,30	
		100	94,42	0,00	0,27		0,06	0,00	0,00		94,35	0,00	0,07	
		200	89,14	0,00	0,00		0,00	0,00	0,00		94,36	0,00	0,00	
	10	30	95,25	85,49	40,97		3,93	2,83	0,61		94,23	85,03	37,91	
		60	92,32	74,10	9,02		0,13	0,06	0,00		93,77	74,13	5,64	
		100	84,05	54,02	0,36		0,00	0,00	0,00		93,34	54,18	0,13	
		200	45,03	12,63	0,00		0,00	0,00	0,00		91,76	13,27	0,00	
9	50	30	95,63	7,73	45,64		3,93	0,00	0,52		94,23	5,51	42,38	
		60	92,32	0,03	11,40		0,13	0,00	0,00		93,77	0,04	7,30	
		100	84,05	0,00	0,75		0,00	0,00	0,00		93,34	0,00	0,17	
		200	45,03	0,00	0,00		0,00	0,00	0,00		91,76	0,00	0,00	

Tabela A.18: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{KI}(0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
4	10	30	14,12	95,48	61,44		0,01	20,41	7,22		5,98	94,78	56,44	
		60	0,03	95,25	16,65		0,00	4,21	0,00		0,00	94,62	8,17	
		100	0,00	95,31	0,88		0,00	0,56	0,00		0,00	94,73	0,11	
		200	0,00	95,31	0,00		0,00	0,00	0,00		0,00	94,90	0,00	
	50	30	0,00	94,17	0,01		0,00	5,54	0,00		0,00	94,41	0,00	
		60	0,00	93,85	0,00		0,00	0,26	0,00		0,00	94,29	0,00	
		100	0,00	92,02	0,00		0,00	0,00	0,00		0,00	94,26	0,00	
		200	0,00	87,26	0,00		0,00	0,00	0,00		0,00	93,54	0,00	
	10	30	14,26	95,56	53,36		0,01	10,77	3,46		6,56	94,63	48,68	
		60	0,01	95,12	11,87		0,00	1,24	0,01		0,00	94,38	5,85	
		100	0,00	94,42	0,53		0,00	0,06	0,00		0,00	94,35	0,05	
		200	0,00	89,14	0,00		0,00	0,00	0,00		0,00	94,36	0,00	
5	50	30	0,00	95,08	0,00		0,00	2,78	0,00		0,00	94,41	0,00	
		60	0,00	93,55	0,00		0,00	0,08	0,00		0,00	94,09	0,00	
		100	0,00	91,15	0,00		0,00	0,00	0,00		0,00	93,81	0,00	
		200	0,00	81,72	0,00		0,00	0,00	0,00		0,00	92,93	0,00	
	10	30	11,42	95,25	37,37		0,00	3,93	1,03		5,16	94,23	32,30	
		60	0,02	92,32	4,21		0,00	0,13	0,00		0,00	93,77	1,77	
		100	0,00	84,05	0,07		0,00	0,00	0,00		0,00	93,34	0,00	
		200	0,00	45,03	0,00		0,00	0,00	0,00		0,00	91,76	0,00	
6	50	30	0,00	94,38	0,00		0,00	0,96	0,00		0,00	94,01	0,00	
		60	0,00	91,00	0,00		0,00	0,01	0,00		0,00	93,45	0,00	
		100	0,00	81,44	0,00		0,00	0,00	0,00		0,00	92,82	0,00	
		200	0,00	41,65	0,00		0,00	0,00	0,00		0,00	90,23	0,00	

Tabela A.19: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 8.

infl.	ϕ	n	$y \sim \text{KI}(0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
7	10	30	84,97	95,48	76,58		14,87	20,41	11,86		87,26	94,78	75,66	
		60	62,84	95,25	56,90		0,49	4,21	1,22		63,95	94,62	52,49	
		100	33,70	95,31	32,19		0,00	0,56	0,05		31,19	94,73	23,96	
		200	2,94	95,31	2,93		0,00	0,00	0,00		1,31	94,90	1,13	
	50	30	7,59	95,48	65,53		0,00	20,41	16,05		2,47	94,78	64,09	
		60	0,01	95,25	35,70		0,00	4,21	1,41		0,00	94,62	60,96	
		100	0,00	95,31	11,34		0,00	0,56	0,03		0,00	94,73	7,90	
		200	0,00	95,31	0,33		0,00	0,00	0,00		0,00	94,90	0,10	
	10	30	88,26	95,56	74,77		7,82	10,77	7,06		90,53	94,63	73,76	
		60	72,92	95,12	53,58		0,16	1,24	0,55		74,10	94,38	49,62	
		100	47,39	94,42	28,93		0,00	0,06	0,01		44,23	94,35	22,51	
		200	6,28	89,14	2,55		0,00	0,00	0,00		3,65	94,36	0,96	
8	50	30	8,02	95,56	40,63		0,00	10,77	5,87		2,53	94,63	35,73	
		60	0,00	95,12	9,58		0,00	1,24	0,13		0,00	94,38	6,74	
		100	0,00	94,42	0,96		0,00	0,06	0,00		0,00	94,35	0,50	
		200	0,00	89,14	0,00		0,00	0,00	0,00		0,00	94,36	0,00	
	10	30	91,23	95,25	69,88		2,93	3,93	3,07		92,61	94,23	67,79	
		60	79,08	92,32	44,78		0,01	0,13	0,09		81,11	93,77	41,27	
		100	53,34	84,05	20,54		0,00	0,00	0,00		55,16	93,34	16,00	
		200	4,12	45,03	1,28		0,00	0,00	0,00		5,38	91,76	0,50	
	50	30	4,62	95,25	11,54		0,00	3,93	0,86		1,43	94,23	7,80	
		60	0,00	92,32	0,44		0,00	0,13	0,00		0,00	93,77	0,14	
		100	0,00	84,05	0,01		0,00	0,00	0,00		0,00	93,34	0,00	
		200	0,00	45,03	0,00		0,00	0,00	0,00		0,00	91,76	8,00	

Tabela A.20: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 5.

Cenários	ϕ	n	$y \sim \text{GUI}(0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
4	10	30	91,79	38,22	95,48		18,42	2,62	20,41		92,89	37,79	94,78	
		60	81,89	8,10	95,25		1,61	0,03	4,21		80,76	6,30	94,62	
		100	61,45	0,62	95,31		0,01	0,00	0,56		54,29	0,32	94,73	
		200	15,78	0,00	95,31		0,00	0,00	0,00		7,00	0,00	94,90	
	50	30	92,10	0,05	95,48		18,56	0,00	20,41		93,14	0,01	94,78	
		60	82,90	0,00	95,25		1,71	0,00	4,21		82,02	0,00	94,62	
		100	63,86	0,00	95,31		0,02	0,00	0,56		57,30	0,00	94,73	
		200	18,73	0,00	95,31		0,00	0,00	0,00		8,94	0,00	94,90	
	10	30	92,53	25,39	95,56		9,54	0,45	10,77		93,18	24,40	94,63	
		60	83,76	3,00	95,12		0,34	0,00	1,24		82,95	2,01	94,38	
		100	65,12	0,11	94,42		0,00	0,00	0,06		59,97	0,04	94,35	
		200	19,493	0,00	89,14		0,00	0,00	0,00		9,72	0,00	94,36	
5	50	30	92,72	0,00	95,56		9,56	0,00	10,77		93,43	0,00	94,63	
		60	84,57	0,00	95,12		0,36	0,00	1,24		84,15	0,00	94,38	
		100	67,36	0,00	94,42		0,00	0,00	0,06		62,76	0,00	94,35	
		200	22,39	0,00	89,93		0,00	0,00	0,00		12,11	0,00	94,36	
	10	30	92,68	9,72	95,25		3,28	0,00	3,93		93,35	8,61	94,23	
		60	83,53	0,20	92,32		0,02	0,00	0,13		85,41	0,15	93,77	
		100	62,33	0,00	84,05		0,0	0,00	0,00		65,21	0,00	93,34	
		200	9,82	0,00	45,03		0,00	0,00	0,00		11,68	0,00	91,76	
	50	30	92,77	0,00	95,25		3,25	0,00	3,93		93,45	0,00	94,23	
		60	83,99	0,00	92,32		0,02	0,00	0,13		86,02	0,00	93,77	
		100	63,52	0,00	84,05		0,0	0,00	0,00		67,58	0,00	93,34	
		200	10,84	0,00	45,03		0,00	0,00	0,00		14,39	0,00	91,76	

Tabela A.21: Resultado da proporção de não rejeição dos testes de hipóteses para dados gerados com média 0, 8.

Cenários	ϕ	n	$y \sim \text{GUI}(0, 1]$											
			% de não rejeição de KS				% de não rejeição de AD				% de não rejeição de CVM			
			BI	KI	GUI		BI	KI	GUI		BI	KI	GUI	
7	10	30	34,60	84,21	95,48		0,25	13,90	20,41		27,401	85,58	94,78	
		60	2,13	62,15	95,25		0,00	0,29	4,21		0,43	57,99	94,62	
		100	0,01	32,59	95,31		0,00	0,00	0,56		0,00	22,47	94,73	
		200	0,00	1,72	95,31		0,00	0,00	0,00		0,00	0,41	94,90	
	50	30	45,63	49,37	95,48		0,68	6,05	20,41		36,56	46,64	94,78	
		60	3,95	19,62	95,25		0,00	0,25	4,21		0,88	16,46	94,62	
		100	0,00	4,25	95,31		0,00	0,00	0,56		0,00	2,87	94,73	
		200	0,00	0,03	95,31		0,00	0,00	0,00		0,00	0,00	94,90	
	10	30	41,02	77,94	95,56		0,09	4,73	10,77		35,00	78,44	94,63	
		60	4,06	50,94	95,12		0,00	0,03	1,24		1,03	48,35	94,38	
		100	0,01	22,25	94,42		0,00	0,00	0,06		0,00	16,73	94,35	
		200	0,00	0,56	89,14		0,00	0,00	0,00		0,00	0,16	94,36	
8	50	30	51,97	24,97	95,56		0,23	0,66	10,77		44,07	20,66	94,63	
		60	6,49	3,24	95,12		0,00	0,00	1,24		1,75	2,15	94,63	
		100	0,04	0,11	94,42		0,00	0,00	0,06		0,00	0,07	94,35	
		200	0,00	0,00	89,14		0,00	0,00	0,00		0,00	0,00	94,36	
	10	30	49,45	65,42	95,25		0,00	0,40	3,93		44,85	65,72	94,23	
		60	6,92	30,41	92,32		0,00	0,00	0,13		1,94	30,21	93,77	
		100	0,01	5,33	84,05		0,00	0,00	0,00		0,00	5,73	93,34	
		200	0,00	0,00	45,03		0,00	0,00	0,00		0,00	0,00	91,76	
9	50	30	59,29	4,70	95,25		0,01	0,00	3,93		53,53	3,04	94,23	
		60	11,18	0,04	92,32		0,00	0,00	0,13		3,20	0,02	93,77	
		100	0,08	0,00	84,05		0,00	0,00	0,00		0,00	0,00	93,34	
		200	0,00	0,00	45,03		0,00	0,00	0,00		0,00	0,00	91,76	

Apêndice B

```
1                                     ##ikumafit.R##
2 source("ikum-omega-phi.R")
3 # library(optimx)
4 library(rootSolve)
5 library(VGAM)
6 # library(fitdistrplus)
7
8 "ikumafit" <- function(y){
9
10   y <- as.vector(y)
11
12   n <- length(y)
13   n0<- sum(y==0) # number of zeros
14   n1<- sum(y==1) # number of ones
15
16   lambda <- (n0+n1)/n # lambda estimator
17   p <- n1/(n0+n1) # p estimator
18
19   u<-1
20   if(n0 == 0)
21   {
22     p=1
23     u=0
24   }
25
26   if(n1 == 0)
27   {
28     p=0
29     u=0
30   }
31
32   i01 <- (y==0)+(y==1)
33
34   loglik <- function(theta)
35   {
36     omega <- theta[1]
```



```

37 phi <- theta[2]
38
39 #####
40 l2 = 0
41 if(u!=0)
42 {
43   l2a = ifelse((y == 1), log(p), 0)
44   l2b = ifelse((y == 0), log(1-p), 0)
45   l2 = l2a + l2b
46 }
47
48 l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
49
50 l3 = ifelse((i01 == 1), 0,
51 log(phi)+
52 log(log(0.5)/log(1-omega^phi))+
53 (phi-1)*log(y)+
54 ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
55 )
56
57 sum(l1 + l2 + l3)
58 }
59
60 escore <- function(theta)
61 {
62   omega <- theta[1]
63   phi <- theta[2]
64
65   delta = log(0.5)/log(1-omega^phi)
66   ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
67     +1)
68
69   c = ifelse((y == 0), 0, ci)
70   c = ifelse((y == 1), 0, c)
71
72   Uomega <- phi*sum(c)
73
74   v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
75     (delta-1)*((y^phi)*log(y)/(1-y^phi)))
76   v = ifelse((y == 1), 0, v)
77
78   Uphi <- sum(v)
79
80   derivada=c(Uomega,Uphi)
81   derivada
82 }

```

```

83  ### initial values
84  ys01<- y
85  if(any(y==0)) ys01<- ys01[-which(y==0)]
86  if(any(y==1)) ys01<- ys01[-which(ys01==1)]
87
88  # fit <- vglm(ys01 ~ 1, kumar)
89  # par<-Coef(fit)
90
91  phi <- 5 #par[1]
92  omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
93
94  #print(c(lambda,p,omega,phi))
95  ini <- c(omega,phi)
96
97  #####
98
99  opt <- optim(ini, loglik, escore, # hessian = T,
100 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
101
102 # opt <- optim(ini, loglik, escore,
103 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
104 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
105 # # upper = rep(.Machine$double.xmax,(r+2))
106 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
107 # upper = rep(.Machine$double.xmax,(r+2))
108 # )
109
110 # opt <- optim(ini, loglik, escore)
111
112 # print(opt$par)
113
114 # print(names(opt))
115 # print(summary(opt) )
116 # print(summary(opt)[1:6] )
117 # print(opt$kkt1)
118
119
120 if (opt$conv != 0)
121 warning("FUNCTION DID NOT CONVERGE!")
122
123 k <- c()
124
125 # print("AQUI1")
126 # print(gradient(escore, opt$par))
127

```

```

128 coef <- c(lambda,p,opt$par)
129 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
130 # print(coef)
131 k$coef <- coef
132 k$conv <- opt$conv
133 k$loglik <- opt$value
134 k$counts <- as.numeric(opt$counts[1])
135
136 # library(rootSolve)
137 # library(numDeriv)
138 # escores<-rbind(
139 #   escore(coef),
140 #   gradient(loglik, coef),
141 #   grad(loglik, coef))
142 # print(round(escores,5))
143
144 # k$Knum<-gradient(escore, coef)
145
146 # print(k$Knum)
147 # k$Knum<-hessian(escore, coef, method="complex")
148 # print(k$Knum)
149
150
151 # # Expected information matrix
152 #
153 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
154 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
155 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
156 #
157 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
158 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
159 # delta <- log(0.5)/log(1-k$omega^k$phi)
160 #
161 # kapa<- 0.5772156649
162 # k0<- (pi^2)/6+kapa^2-2*kapa
163 #
164 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
165 #   log(1-y^k$phi)+1)
166 #
167 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
168 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
169 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
170 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
171 #
172 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
173 #
174 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)

```

```

174 #
175 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
176 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
    phi)) -
177 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
    k$phi^3))
178 # #
179 # # si <- (1-k$lambda)*(b2) # ifelse(y==c,0,b2) #
180 #
181 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
    +1)-kapa)/((delta-1)*k$phi)) )
182 #
183 # L = diag(-1/(k$lambda*(1-k$lambda)))
184 # V = diag((k$lambda-1)*k$phi^2*h2)
185 # M = diag(mi)
186 # S = diag(si)
187 #
188 #
189 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
190 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
191 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
192 # Isb = t(Ibs)
193 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
194 #
195 # if(u!=0)
196 # {
197 #   k$pi <- as.vector(coef[(m+1):(m+u)])
198 #   eta_hat2 <- as.vector(w1%*%k$pi)
199 #   k$p <- as.vector(linkinv2(eta_hat2))
200 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
201 #   P = diag(-k$lambda/(k$p*(1-k$p)))
202 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
203 #
204 #   I <- rbind(
205 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
        ncol=s)),
206 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
        ncol=s)),
207 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
208 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
209 #   )
210 #
211 # }else{
212 #   I <- rbind(
213 #     cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
214 #     cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
215 #     cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)

```

```

216     # )
217     # }
218     #
219     # k$I <- I
220     #
221     #
222     # #####
223     #
224     # # print(-k$Knum)
225     # # print(k$I)
226     #
227     # # vcov <- try(solve(-k$Knum))
228     # vcov <- try(solve(k$I))
229     # # vcov <- chol2inv(chol(k$I))
230     # #vcov <- K #somente para nao trancar simulacao
231     #
232     # k$cov_ok = 0
233     # if (class(vcov) == "try-error")
234     # {
235         # vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
            # with inversion
236         # k$cov_ok = 1
237         #
238         # if (class(vcov) == "try-error") #
239         # {
240             # vcov <- k$Knum^2
241             # warning("Problem with the variance and covariance matrix. The p-values
                # are not correct.")
242             # k$cov_ok = 2
243             # }
244         # }
245
246
247     # k$vcov <- vcov
248     # stderr <- sqrt(diag(k$vcov))
249     # k$stderr <- stderr
250
251     return(k)
252 }

```

```

1                                     ##iuga_fitv4.R##
2     source("iuga_v2.R")
3     # library(optimx)
4     library(rootSolve)
5     library(VGAM)
6     # library(fitdistrplus)
7

```

```

8
9 diuGA <- function(y, alpha0, alpha1, gama, phi)
10
11 {
12   n <- length(y) # sample size
13   n0 <- sum(y == 0) # number of zeros
14   n1 <- sum(y == 1) # number of ones
15   m <- n0 + n1
16
17   alpha0 = ifelse(n0 == 0, 0, alpha0)
18   alpha1 = ifelse(n1 == 0, 0, alpha1)
19
20   c <- 1- alpha0*(1-gama)-alpha1*gama
21   mu <- gama*(1-alpha1)/c
22
23
24   f0 <- ifelse((y == 0), alpha0*(1-gama), 0)
25   f1 <- ifelse((y == 1), alpha1*gama, 0)
26
27   f <- ifelse((y == 0), 0, (1- alpha0*(1-gama)-alpha1*gama)*dGU(y,(gama*(1-
28     alpha1))/((1-alpha0*(1-gama)-alpha1*gama),phi))
29   f <- ifelse((y == 1), 0, f)
30
31   return (f0 + f1 + f)
32 }
33
34 iuGAfit <- function(y)
35
36 {
37
38   n <- length(y) # sample size
39   n0 <- sum(y == 0) # number of zeros
40   n1 <- sum(y == 1) # number of ones
41   m <- n0 + n1
42
43   ys01 <- y
44   if(any(y==0)) ys01<- ys01[-which(y==0)]
45   if(any(y==1)) ys01<- ys01[-which(ys01==1)]
46
47   i01 <- (y==0)+(y==1)
48
49   #Maxima verossimilhanca
50
51   loglik <- function (par){
52
53     alpha0 <- par[1]

```

```

54 alpha1 <- par[2]
55 gama <- par[3]
56 phi <- par[4]
57
58 alpha0 = ifelse(n0 == 0, 0, alpha0)
59 alpha1 = ifelse(n1 == 0, 0, alpha1)
60
61 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
62 mu <- gama * (1 - alpha1) / c
63 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
64
65 l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
66 l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
67 l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
68 l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))
69 ))
70
71 #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
72
73 sum(l0 + l1 + l2 + l3)
74
75 }
76
77 escore <- function (par) {
78
79 alpha0 <- par[1]
80 alpha1 <- par[2]
81 gama <- par[3]
82 phi <- par[4]
83
84 alpha0 <- ifelse(n0 == 0, 0, alpha0)
85 alpha1 <- ifelse(n1 == 0, 0, alpha1)
86
87 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
88 mu <- gama * (1 - alpha1) / c
89 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
90 ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
91 mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
92
93 Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
94 Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d
95 ) / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) /
96 (c ^ 2))
97 Ualpha0 <- sum(Ualpha01 + Ualpha03)
98
99 Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)

```

```

98   Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
99   Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d))
      / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c
      ^ 2))
100  Ualpha1 <- sum(Ualpha11 + Ualpha13)
101
102  Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
103
104
105  Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
106  Ugama02 <- ifelse((y == 1), 1 / gama, 0)
107  Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d *
      (1 + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1)
      / (c ^ 2))
108
109  Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
110
111  Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu
      ))/phi - ((d^2) *log(mu)* log(y)) / ((phi^2) * (mu ^ (1 / phi))) -
      digamma(phi) - log(mu^(1/phi)))
112
113  Uphi = sum(Uphi0)
114
115
116  c(Ualpha0, Ualpha1, Ugama, Uphi)
117 }
118
119
120 #Inicializacao
121
122 y_bar <- mean(y)
123 y_bar0 <- mean(ys01)
124
125 delta0 <- n0/n
126 delta1 <- n1/n
127
128 a0 <- delta0/(1-y_bar)
129 a1 <- delta1/(y_bar)
130
131
132 #fit <- vglm(ys01 ~ 1, gamma2)
133 #par<-Coef(fit)
134
135 #mu <-(y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
136 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
137 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
138 #phi_til = 5

```



```

139 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
140
141 par_ini <- c(a0, a1, y_bar, phi_til)
142
143
144 max<-optim(par_ini, loglik, escore,method = "BFGS",
145 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
146 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
147 control=list(fnscale=-1))
148
149 if(max$convergence != 0) print("Non-convergence")
150 # return
151 z <- c()
152 z$ini = max$par_ini
153 z$mv <- max$par
154 z$conv <- max$convergence
155 z$loglik <- max$value
156 return(z)
157 }

```

```

1                                     ##ibetafit.R##
2 ibetafit<-function(x)
3 {
4
5   n<- length(x) # sample size
6   n0<- sum(x==0) # number of zeros
7   n1<- sum(x==1) # number of ones
8   m<- n0 + n1
9
10  xm0<-x[which(x>0)]
11  x01<-xm0[which(xm0<1)]
12
13  #MV
14  loglik<-function(par)
15  {
16    alpha0<-par[1]
17    alpha1<-par[2]
18    gama<-par[3]
19    phi<-par[4]
20
21    alpha0 = ifelse(n0==0,0,alpha0)
22    alpha1 = ifelse(n1==0,0,alpha1)
23
24    c<- 1- alpha0*(1-gama)-alpha1*gama
25    mu<- gama*(1-alpha1)/c

```

```

26
27
28 10 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
29 11 = ifelse( (x == 1), log(alpha1*gama), 0)
30 12 = ifelse(((x == 0) | (x == 1)), 0, log(c))
31 13 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
    - mu) * phi, log = TRUE)))
32
33 #print("soma")
34 #print(sum(10 + 11 + 12+ 13))
35 sum(10 + 11 + 12+ 13)
36 }
37
38 escore<-function(par)
39 {
40   alpha0<-par[1]
41   alpha1<-par[2]
42   gama<-par[3]
43   phi<-par[4]
44
45   c<- 1- alpha0*(1-gama)-alpha1*gama
46   mu<- (gama*(1-alpha1))/c
47
48   a= mu * phi
49   b = a * (1 - mu)/mu
50
51   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
52   mustar <- digamma(a) - digamma(b)
53
54   Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
55   #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
56   Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
    mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
57   Ualpha0 = sum(Ualpha01 + Ualpha03)
58
59   Ualpha0 = ifelse(n0==0,0,Ualpha0)
60
61
62   Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
63   #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
64   Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
    gama*(1-gama)*(1-alpha0))/ (c^2) ) )
65   #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
    digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
66   Ualpha1 = sum(Ualpha11 - Ualpha13)
67
68   Ualpha1 = ifelse(n1==0,0,Ualpha1)

```

```

69
70 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
71 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
72 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
      mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
73
74 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
75
76 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
77 # (mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
78 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
79 )
80 Uphi = sum(Uphi0)
81
82
83 c(Ualpha0,Ualpha1,Ugama,Uphi)
84 }
85
86 # metodo dos momentos para iniciarlizacao
87 x_bar<-mean(x01)
88 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
89
90 p<-x_bar*((x_bar*(1-x_bar))/sigma2_hat)-1)
91 q<-(1-x_bar)*((x_bar*(1-x_bar))/sigma2_hat)-1)
92
93 #print(c(x_bar,sigma2_hat,p,q))
94
95 delta0<- n0/n
96 delta1<- n1/n
97
98 a0<- delta0/(1-x_bar)
99 a1<- delta1/(x_bar)
100
101 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
102 par_ini<-c(a0,a1,p/(p+q),p+q)
103
104 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
105
106 #print("par_ini")
107 #print(par_ini)
108
109 max<-optim(par_ini,loglik,
110     escore,
111     method="BFGS",
112     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),

```

```

113 control=list(fnscale=-1))
114
115 if(max$convergence != 0) print("Non-convergence")
116 # return
117 z<-c()
118 z$mv<-max$par
119 #print(z$mv)
120 z$conv<-max$convergence
121 z$loglik <- max$value
122 return(z)
123 }

```

```

1                                     ##iuga_v2.R##
2 rm(list=ls(all=TRUE))
3 # density function
4 library(extraDistr)
5 library(expint)
6
7 # if p=0 then y is zero inflated
8 # if p=1 then y is one inflated
9
10 # funcao densidade de probabilidade da gama unit?ria
11
12 dGU <- function (y, mu, phi) {
13
14   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
15
16   (d ^ phi) / gamma(phi) * y ^ (d - 1) * (log(1 / y) ^ (phi - 1))
17
18 }
19
20 #funcao distribuicao acumulada da gama unitaria
21 pGU <- function (y, mu, phi) {
22   alpha <- phi
23   beta <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
24   p <- 1 - pgamma(beta * (-log(y)), alpha, lower.tail = TRUE)
25   return(p)
26 }
27
28 #funcao densidade de probabilidade da gama unitaria inflacionada
29 dgui <- function (y, alpha0 = 0.2, alpha1 = 0.2, gama = 0.5, phi = 5) {
30
31   f0 <- ifelse((y == 0), alpha0*(1-gama), 0)
32   f1 <- ifelse((y == 1), alpha1*gama, 0)
33
34   # f <- ifelse((y == 0), 0, (1-alpha0*(1-gama) - alpha1*gama)*dGU(y,phi,(gama*
      (1-alpha1))/(1-alpha0*(1-gama)-alpha1*gama)))

```

```

35 # f <- ifelse((y == 1), 0, f)
36 c = 1-alpha0*(1-gama) - alpha1*gama
37 f = ifelse(((y == 0) | (y == 1)), 0, c*suppressWarnings(dGU(y,(gama*(1-alpha1))
    /(1-alpha0*(1-gama)-alpha1*gama),phi)))
38
39 return (f0 + f1 + f)
40
41 }
42
43 #funcao distribuicao acumulada da gama unitaria inflacionada
44 pgui <- function (y, alpha0 = 0.2, alpha1 = 0.2, gama = 0.5, phi = 5) {
45
46     mu <- (gama * (1 - alpha1)) / (1 - alpha0 * (1 - gama) - alpha1 * gama)
47
48     p0 <- alpha0 * (1 - gama)
49     p1 <- ifelse(y == 1, alpha1 * gama, 0)
50     p <- (1 - alpha0 * (1 - gama) - alpha1 * gama) * pGU(y, mu, phi)
51     ret <- ifelse(y == 1, p0 + p1 + p, p0 + p)
52
53     return (ret)
54
55 }
56
57 # Gu's quantile function
58 qGU <- function (u, mu, phi) {
59     alpha <- phi
60     beta <- mu ^ (1 / phi) / (1 - mu ^ (1 / phi))
61     qGA <- qgamma(1-u, scale = 1 / beta, shape = alpha, lower.tail = TRUE)
62     exp(-qGA)
63 }
64
65 # quantile function iGU
66
67 qiGU<-function(u, alpha0 = 0.2, alpha1 = 0.2, gama = 0.5, phi = 5)
68
69 {
70     if(u < (alpha0*(1-gama)) )
71     {
72         ret=0
73
74     }else{
75         if(u > (1- alpha1*gama) )
76         {
77             ret=1
78
79         }else{
80             ret= qGU((u-alpha0*(1-gama))/(1-alpha0*(1-gama)-alpha1*gama),(gama * (1 -

```

```

      alpha1)) / (1 - alpha0 * (1 - gama) - alpha1 * gama), phi)
81   }
82   }
83   ret
84 }
85
86 # inversion method for random generation
87 riGU<-function(n, alpha0 = 0.2, alpha1 = 0.2, gama = 0.5, phi = 5)
88 {
89   ret <- rep(0, n)
90
91   for(i in 1:n)
92   {
93     u <- runif(1)
94
95     ret[i] <- qiGU(u, alpha0 = alpha0, alpha1 = alpha1, gama = gama, phi = phi)
96   }
97   ret
98 }

```

```

1                                     ##ikum-omega-phi.R##
2 # density function
3 library(extraDistr)
4
5 # if p=0 then y is zero inflated
6 # if p=1 then y is one inflated
7
8 # density function
9 dikum<-function(y,lambda=0.2,p=0.2,omega=0.5,phi=5)
10 {
11   f0 = ifelse((y == 0), lambda*(1-p), 0)
12   f1 = ifelse((y == 1), lambda*p, 0)
13
14   f = ifelse((y == 0), 0, (1-lambda)*dkumar(y,phi,log(0.5)/log(1-omega^phi)))
15   f = ifelse((y == 1), 0, f)
16
17   (f0 + f1 + f)
18 }
19
20 # cumulative distribution function
21 pikum<-function(y,lambda=0.2,p=0.2,omega=0.5,phi=5)
22 {
23   p0 = lambda*(1-p)
24   p1 = ifelse((y == 1), lambda*(p), 0)
25   p<- (1-lambda)*(1-(1-(y^phi))^( (log(0.5))/(log(1-(omega^phi))) ))
26   ret = ifelse(y==1, p0+p1+p, p0+p)
27   ret

```

```

28 }
29
30 # quantile function
31 qikum<-function(u,lambda=0.2,p=0.2,omega=0.5,phi=5)
32 {
33   if(u < (lambda*(1-p)) )
34   {
35     ret=0
36   }else{
37     if(u > (1-lambda*p) )
38     {
39       ret=1
40     }else{
41       ret=qkumar((u-lambda*(1-p))/(1-lambda), phi, log(0.5)/log(1-omega^phi))
42     }
43   }
44   ret
45 }
46
47 # inversion method for random generation
48 rikum<-function(n,lambda=0.2,p=0.2,omega=0.5,phi=5)
49 {
50   ret<-rep(0,n)
51   for(i in 1:n)
52   {
53     u <- runif(1)
54     ret[i]<-qikum(u,lambda=lambda,p=p,omega=omega,phi=phi)
55   }
56   ret
57 }

```

```

1  ##Simulacao gerando amostras a partir da beta inflacionada em zero##
2  library(gamlss)
3  library(gamlss.dist)
4  library(gamlss.data)
5  library(betareg)
6  library(MASS)
7  library(goftest)
8
9  source("ikumafit.R")
10 source("iuga_fitv4.R")
11 source("ibetafit.R")
12 source("iuga_v2.R")
13
14
15 set.seed(33) #Fixando a semente
16

```

```

17
18 source("ikum-omega-phi.R")
19 # library(optimx)
20 library(rootSolve)
21 library(VGAM)
22 library(xtable)
23 # library(fitdistrplus)
24
25 "ikumafit" <- function(y){
26
27   y <- as.vector(y)
28
29   n <- length(y)
30   n0<- sum(y==0) # number of zeros
31   n1<- sum(y==1) # number of ones
32
33   lambda <- (n0+n1)/n # lambda estimator
34   p <- n1/(n0+n1) # p estimator
35
36   u<-1
37   if(n0 == 0)
38   {
39     p=1
40     u=0
41   }
42
43   if(n1 == 0)
44   {
45     p=0
46     u=0
47   }
48
49   i01 <- (y==0)+(y==1)
50
51   loglik <- function(theta)
52   {
53     omega <- theta[1]
54     phi <- theta[2]
55
56     #####
57     l2 = 0
58     if(u!=0)
59     {
60       l2a = ifelse((y == 1), log(p), 0)
61       l2b = ifelse((y == 0), log(1-p), 0)
62       l2 = l2a + l2b
63     }

```



```

64
65 l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
66
67 l3 = ifelse((i01 == 1), 0,
68 log(phi)+
69 log(log(0.5)/log(1-omega^phi))+
70 (phi-1)*log(y)+
71 ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
72 )
73
74 sum(l1 + l2 + l3)
75 }
76
77 escore <- function(theta)
78 {
79 omega <- theta[1]
80 phi <- theta[2]
81
82 delta = log(0.5)/log(1-omega^phi)
83 ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
84 +1)
85
86 c = ifelse((y == 0), 0, ci)
87 c = ifelse((y == 1), 0, c)
88
89 Uomega <- phi*sum(c)
90
91 v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
92 (delta-1)*((y^phi)*log(y)/(1-y^phi)))
93 v = ifelse((y == 1), 0, v)
94
95 Uphi <- sum(v)
96
97 derivada=c(Uomega,Uphi)
98 derivada
99 }
100
101 ### initial values
102 ys01<- y
103 if(any(y==0)) ys01<- ys01[-which(y==0)]
104 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
105
106 # fit <- vglm(ys01 ~ 1, kumar)
107 # par<-Coef(fit)
108
109 phi <- 5 #par[1]
110 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)

```

```

110
111 #print(c(lambda,p,omega,phi))
112 ini <- c(omega,phi)
113
114 #####
115
116 opt <- optim(ini, loglik, escore, # hessian = T,
117 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
118
119 # opt <- optim(ini, loglik, escore,
120 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
121 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
122 # # upper = rep(.Machine$double.xmax,(r+2))
123 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
124 # upper = rep(.Machine$double.xmax,(r+2))
125 # )
126
127 # opt <- optim(ini, loglik, escore)
128
129 # print(opt$par)
130
131 # print(names(opt))
132 # print(summary(opt) )
133 # print(summary(opt)[1:6] )
134 # print(opt$kk1)
135
136
137 if (opt$conv != 0)
138 warning("FUNCTION DID NOT CONVERGE!")
139
140 k <- c()
141
142 # print("AQUI1")
143 # print(gradient(escore, opt$par))
144
145 coef <- c(lambda,p,opt$par)
146 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
147 # print(coef)
148 k$coef <- coef
149 k$conv <- opt$conv
150 k$loglik <- opt$value
151 k$counts <- as.numeric(opt$counts[1])
152
153 # library(rootSolve)
154 # library(numDeriv)

```

```

155 # escores<-rbind(
156 #   escore(coef),
157 #   gradient(loglik, coef),
158 #   grad(loglik, coef))
159 # print(round(escores,5))
160
161 # k$Knum<-gradient(escore, coef)
162
163 # print(k$Knum)
164 # k$Knum<-hessian(escore, coef, method="complex")
165 # print(k$Knum)
166
167
168 # # Expected information matrix
169 #
170 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
171 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
172 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
173 #
174 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
175 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
176 # delta <- log(0.5)/log(1-k$omega^k$phi)
177 #
178 # kapa<- 0.5772156649
179 # k0<- (pi^2)/6+kapa^2-2*kapa
180 #
181 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
182 #   log(1-y^k$phi)+1)
183 #
184 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
185 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
186 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
187 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
188 #
189 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
190 #
191 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
192 #
193 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
194 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
195 # #   phi)) -
196 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
197 # #   k$phi^3))
198 # #
199 # # si <- (1-k$lambda)*(b2) # ifelse(y=c,0,b2) #
200 #
201 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta

```

```

+1)-kapa)/((delta-1)*k$phi)) )
199 #
200 # L = diag(-1/(k$lambda*(1-k$lambda)))
201 # V = diag((k$lambda-1)*k$phi^2*h2)
202 # M = diag(mi)
203 # S = diag(si)
204 #
205 #
206 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
207 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
208 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
209 # Isb = t(Ibs)
210 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
211 #
212 # if(u!=0)
213 # {
214 #   k$pi <- as.vector(coef[(m+1):(m+u)])
215 #   eta_hat2 <- as.vector(w1*%k$pi)
216 #   k$p <- as.vector(linkinv2(eta_hat2))
217 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
218 #   P = diag(-k$lambda/(k$p*(1-k$p)))
219 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
220 #
221 #   I <- rbind(
222 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
223 #       ncol=s)),
224 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
225 #       ncol=s)),
226 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
227 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
228 #   )
229 # }else{
230 #   I <- rbind(
231 #     cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
232 #     cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
233 #     cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
234 #   )
235 # }
236 # k$I <- I
237 #
238 #
239 # #####
240 #
241 # # print(-k$Knum)
242 # # print(k$I)

```

```

243 #
244 # # vcov <- try(solve(-k$Knum))
245 # vcov <- try(solve(k$I))
246 # # vcov <- chol2inv(chol(k$I))
247 # #vcov <- K #somente para nao trancar simulacao
248 #
249 # k$cov_ok = 0
250 # if (class(vcov) == "try-error")
251 # {
252 #   vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
253 #   with inversion
254 #   k$cov_ok = 1
255 #   #
256 #   # if (class(vcov) == "try-error") #
257 #   # {
258 #   #   vcov <- k$Knum^2
259 #   #   warning("Problem with the variance and covariance matrix. The p-values
260 #   #   are not correct.")
261 #   #   k$cov_ok = 2
262 #   # }
263 # }
264 # k$vcov <- vcov
265 # stderror <- sqrt(diag(k$vcov))
266 # k$stderror <- stderror
267
268 return(k)
269 }
270
271 ibetafit<-function(x)
272 {
273
274   n<- length(x) # sample size
275   n0<- sum(x==0) # number of zeros
276   n1<- sum(x==1) # number of ones
277   m<- n0 + n1
278
279   xm0<-x[which(x>0)]
280   x01<-xm0[which(xm0<1)]
281
282   #MV
283   loglik<-function(par)
284   {
285     alpha0<-par[1]
286     alpha1<-par[2]
287     gama<-par[3]

```

```

288 phi<-par[4]
289
290 alpha0 = ifelse(n0==0,0,alpha0)
291 alpha1 = ifelse(n1==0,0,alpha1)
292
293 #print(c(alpha0,alpha1,gama,phi))
294
295 c<- 1- alpha0*(1-gama)-alpha1*gama
296 mu<- gama*(1-alpha1)/c
297
298
299 l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
300 l1 = ifelse( (x == 1), log(alpha1*gama), 0)
301 l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
302 l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
    - mu) * phi, log = TRUE)))
303
304
305 #print("soma")
306 #print(sum(l0 + l1 + l2+ l3))
307 sum(l0 + l1 + l2+ l3)
308 }
309
310 escore<-function(par)
311 {
312   alpha0<-par[1]
313   alpha1<-par[2]
314   gama<-par[3]
315   phi<-par[4]
316
317   c<- 1- alpha0*(1-gama)-alpha1*gama
318   mu<- (gama*(1-alpha1))/c
319
320   a= mu * phi
321   b = a * (1 - mu)/mu
322
323   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
324   mustar <- digamma(a) - digamma(b)
325
326
327
328   Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
329   #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
330   Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
    mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
331   Ualpha0 = sum(Ualpha01 + Ualpha03)
332

```

```

333 Ualpha0 = ifelse(n0==0,0,Ualpha0)
334
335
336 Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
337 #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
338 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
339   gama*(1-gama)*(1-alpha0))/(c^2) ) )
340 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
341   digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
342 Ualpha1 = sum(Ualpha11 - Ualpha13)
343
344 Ualpha1 = ifelse(n1==0,0,Ualpha1)
345
346 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
347 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
348 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
349   mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
350
351 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
352
353 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
354   #(mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
355   digamma(b))
356   mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
357 )
358 Uphi = sum(Uphi0)
359
360
361 c(Ualpha0,Ualpha1,Ugama,Uphi)
362 }
363
364 # metodo dos momentos para iniciarlizacao
365 x_bar<-mean(x01)
366 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
367
368 p<-x_bar*((x_bar*(1-x_bar))/sigma2_hat)-1)
369 q<-(1-x_bar)*((x_bar*(1-x_bar))/sigma2_hat)-1)
370
371 #print(c(x_bar,sigma2_hat,p,q))
372
373 delta0<- n0/n
374 delta1<- n1/n
375
376 a0<- delta0/(1-x_bar)
377 a1<- delta1/(x_bar)
378
379 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)

```

```

376 par_ini<-c(a0,a1,p/(p+q),p+q)
377
378 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
379
380 #print("par_ini")
381 #print(par_ini)
382
383 max<-optim(par_ini,loglik,
384     escore,
385     method="BFGS",
386     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
387         (0.99999,0.99999,0.99999,9999999999),
388     control=list(fnscale=-1))
389
390 if(max$convergence != 0) print("Non-convergence")
391 # return
392 z<-c()
393 z$mv<-max$par
394 #print(z$mv)
395 z$conv<-max$convergence
396 z$loglik <- max$value
397 return(z)
398 }
399
400 iuGAfit <- function(y)
401 {
402     n <- length(y) # sample size
403     n0 <- sum(y == 0) # number of zeros
404     n1 <- sum(y == 1) # number of ones
405     m <- n0 + n1
406
407     ys01 <- y
408     if(any(y==0)) ys01<- ys01[-which(y==0)]
409     if(any(y==1)) ys01<- ys01[-which(ys01==1)]
410
411     i01 <- (y==0)+(y==1)
412
413     #Maxima verossimilhanca
414
415     loglik <- function (par){
416
417         alpha0 <- par[1]
418         alpha1 <- par[2]
419         gama <- par[3]

```



```

422 phi <- par[4]
423
424 alpha0 = ifelse(n0 == 0, 0, alpha0)
425 alpha1 = ifelse(n1 == 0, 0, alpha1)
426
427 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
428 mu <- gama * (1 - alpha1) / c
429 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
430
431 l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
432 l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
433 l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
434 l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
435
436 #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
437
438 sum(l0 + l1 + l2 + l3)
439
440 }
441 escore <- function (par) {
442
443   alpha0 <- par[1]
444   alpha1 <- par[2]
445   gama <- par[3]
446   phi <- par[4]
447
448   alpha0 <- ifelse(n0 == 0, 0, alpha0)
449   alpha1 <- ifelse(n1 == 0, 0, alpha1)
450
451   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
452   mu <- gama * (1 - alpha1) / c
453   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
454   ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
455   mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
456
457
458   Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
459   Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
     / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
     ^ 2))
460   Ualpha0 <- sum(Ualpha01 + Ualpha03)
461
462   Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
463
464   Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
465   Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
     (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^

```

```

2))
466 Ualpha1 <- sum(Ualpha11 + Ualpha13)
467
468 Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
469
470
471 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
472 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
473 Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
+ d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
^ 2))
474
475 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
476
477 Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
/phi - ((d^2) *log(mu)* log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
phi) - log(mu^(1/phi)))
478
479 Uphi = sum(Uphi0)
480
481
482 c(Ualpha0, Ualpha1, Ugama, Uphi)
483 }
484
485
486 #Inicializacao
487
488 y_bar <- mean(y)
489 y_bar0 <- mean(ys01)
490
491 delta0 <- n0/n
492 delta1 <- n1/n
493
494 a0 <- delta0/(1-y_bar)
495 a1 <- delta1/(y_bar)
496
497
498 #fit <- vglm(ys01 ~ 1, gamma2)
499 #par<-Coef(fit)
500
501 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
502 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
503 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
504 #phi_til = 5
505 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
506
507 par_ini <- c(a0, a1, y_bar, phi_til)

```

```

508
509
510 max<-optim(par_ini, loglik, escore,method = "BFGS",
511 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
512 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
513 control=list(fnscale=-1))
514
515 if(max$convergence != 0) print("Non-convergence")
516 # return
517 z <- c()
518 z$ini <- par_ini
519 z$mv <- max$par
520 z$conv <- max$convergence
521 z$loglik <- max$value
522 return(z)
523 }
524
525 n=200
526 #n=60
527 #n=100
528 #n=200
529 NR=10000
530 k=3 # numero de parametros
531
532 Cont_AIC_IB=rep(0,NR)
533 Cont_AIC_IK=rep(0,NR)
534 Cont_AIC_IUG=rep(0,NR)
535
536 Cont_AICC_IB=rep(0,NR)
537 Cont_AICC_IK=rep(0,NR)
538 Cont_AICC_IUG=rep(0,NR)
539
540 Cont_BIC_IB=rep(0,NR)
541 Cont_BIC_IK=rep(0,NR)
542 Cont_BIC_IUG=rep(0,NR)
543
544 Cont_BICC_IB=rep(0,NR)
545 Cont_BICC_IK=rep(0,NR)
546 Cont_BICC_IUG=rep(0,NR)
547
548 Cont_HQ_IB=rep(0,NR)
549 Cont_HQ_IK=rep(0,NR)
550 Cont_HQ_IUG=rep(0,NR)
551
552 Cont_HQC_IB=rep(0,NR)

```

```

553 Cont_HQC_IK=rep(0,NR)
554 Cont_HQC_IUG=rep(0,NR)
555
556 Cont_LL_IB =rep(0,NR)
557 Cont_LL_IK=rep(0,NR)
558 Cont_LL_IUG=rep(0,NR)
559
560 contC=0
561 contC1=0
562
563 prop.z = rep(0,NR)
564 prop.u = rep(0,NR)
565 media.l=rep(0,NR)#isaacc
566 sd.l=rep(0,NR) #isaacc
567 var.am=rep(0,NR) #isaac
568
569 cvm.iBE = rep(0,NR)
570 ks.iBE = rep(0,NR)
571 ad.iBE = rep(0,NR)
572
573 cvm.iuGA = rep(0,NR)
574 ks.iuGA = rep(0,NR)
575 ad.iuGA = rep(0,NR)
576
577 cvm.ikum = rep(0,NR)
578 ks.ikum = rep(0,NR)
579 ad.ikum = rep(0,NR)
580
581 alpha0 = 0.1
582 alpha1 = 0
583 gama= 0.3
584 phi = 10
585
586 valores.parametros = c(alpha0, alpha1, gama, phi)
587
588 prob.z = alpha0*(1-gama)
589 prob.o = alpha1*gama
590
591 prob.z # probabilidade de zero
592 prob.o #probabilidade de um
593
594 media.v = gama #infla_0
595
596 var.v=gama*((1+alpha1*phi)/(1+phi)) + (((1-alpha1)*(1-alpha1)*phi)/((1-alpha0*(1-
      gama)-alpha1*gama)*(1+phi)) -1)*gama^(2)
597 media.v
598 var.v

```

```

599
600 c= 1- alpha0*(1-gama)-alpha1*gama
601 mu = gama*(1-alpha1)/c
602 delta0 = alpha0 * (1-gama)
603 delta1 = alpha1 * (gama)
604 p2= 1- delta0-delta1
605
606 mu
607 delta0
608 delta1
609 p2
610 dp = sqrt(1/(phi+1))
611 dp
612
613 cont.ib = 0
614 cont.ik = 0
615 cont.igu = 0
616
617 for(i in 1:NR) {
618
619   #y = riGU(n,alpha0 = alpha0, alpha1=alpha1, gama = gama, phi = phi)
620   y = rBEINFO(n, mu = mu , sigma=dp, nu=delta0/p2) # Inf.0
621   len = length(y)
622   prop.z[i] = sum(ifelse(y==0,1,0))/len
623   prop.u[i] = sum(ifelse(y==1,1,0))/len
624   media.1[i]=mean(y)#isaacc
625   sd.1[i]=sd(y)#isaacc
626   var.am[i]=var(y)#isaac
627
628   fitib = ibetafit(y)
629   if (fitib$conv != 0)
630   {
631     cont.ib = cont.ib+1
632   }
633
634   fitik = ikumafit(y)
635   if (fitik$conv != 0)
636   {
637     cont.ik = cont.ik+1
638   }
639
640   fitigu = iuGAfit(y)
641
642
643   if ((fitigu$conv != 0) ){
644     cont.igu=cont.igu+1
645   }

```

```

646
647 ks.iBE[i] = ifelse(ks.test(y, "pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$p.value
        >0.05,1,0)
648
649 ad.iBE[i] = ifelse(ad.test(y, null="pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$p.
        value>0.05,1,0)
650
651 cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$
        p.value >0.05,1,0)
652
653 ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
        phi=phi)$p.value>0.05,1,0)
654
655 ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
656
657 cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
658
659
660 ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=alpha0, p=alpha1,omega=gama, phi=
        phi)$p.value>0.05,1,0)
661
662 ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=alpha0, p=alpha1,omega=gama,
        phi=phi)$p.value>0.05,1,0)
663
664 cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=alpha0, p=alpha1,omega=
        gama, phi=phi)$p.value>0.05,1,0)
665
666 #Log verossimilhanca
667 log.vero_IB = fitib$loglik #BI(Beta inflacionada)
668 log.vero_IK= fitik$loglik #KI(Kumaraswamy Inflacionada)
669 log.vero_IUG = fitigu$loglik #GUI(Gama Unitaria Inflacionada)
670
671 m.log.vero_IB = -fitib$loglik #BI
672 m.log.vero_IK= -fitik$loglik #KI
673 m.log.vero_IUG = -fitigu$loglik #GUI
674
675 #Menor -log verossimilhanca
676
677 min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
678
679 Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
680 Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
681 Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)
682
683

```

```

684 # Calculando os criterios/quantidades para comparacao
685
686 #criteiro_AIC#
687 AIC_IB = -2*log.vero_IB+2*k #BI
688 AIC_IK= -2*log.vero_IK+2*k #KI
689 AIC_IUG = -2*log.vero_IUG+2*k #GUI
690
691 # Selecionando o menor AIC
692 min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
693
694 Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0)
695 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
696 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
697
698 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1) #BI
699 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1) #KI
700 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1) #GUI
701
702 # Selecionando o menor AICC
703 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
704
705 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0)
706 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
707 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)
708
709 #criterio_BIC#
710 BIC_IB=-2*log.vero_IB+k*log(n) #BI
711 BIC_IK=-2*log.vero_IK+k*log(n) #KI
712 BIC_IUG=-2*fitigu$loglik+k*log(n) #GUI
713
714 # Selecionando o menor BIC
715 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
716
717 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
718 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
719 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)
720
721 #criterio_BICC#
722 BICC_IB=-2*log.vero_IB+(n*k*log(n))/(n-k-1) #BI
723 BICC_IK=-2*log.vero_IK+(n*k*log(n))/(n-k-1) #KI
724 BICC_IUG=-2*fitigu$loglik+(n*k*log(n))/(n-k-1) #GUI
725
726 # Selecionando o menor BICC
727 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
728
729 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
730 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)

```

```

731 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
732
733 #criterio_HQ#
734
735 HQ_IB=-2*log.vero_IB+2*k*log(log(n)) #BI
736 HQ_IK=-2*log.vero_IK+2*k*log(log(n)) #KI
737 HQ_IUG=-2*fitigu$loglik+2*k*log(log(n)) #GUI
738
739 # Selecionando o menor HQ
740 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
741
742 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
743 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
744 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)
745
746 #criterio_HQC#
747 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1) #BI
748 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1) #KI
749 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1) #GUI
750
751 # Selecionando o menor HQC
752 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
753
754
755 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
756 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)
757 Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
758 # FIM DO LACO DE MONTE CARLO
759
760 }
761
762 # Proporcao media de zeros
763 #mean(prop.z)
764 # Proporcao media de uns
765 #mean(prop.u)
766 #media das medias
767 mu=mean(media.1)
768 #media do desvio padrao
769 sd.of=mean(sd.1)
770 var.amostrat=mean(var.am)
771
772 #Calculando percentuais escolha distribuicao(AIC)
773 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
774 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
775 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
776 p_AICIB
777 p_AICIK

```



```

778 p_AICIUG
779
780 #Calculando percentuais escolha distribuicao(AICC)
781 p_AICCIB<-((sum(Cont_AICC_IB))/NR)*100
782 p_AICCIK<-((sum(Cont_AICC_IK))/NR)*100
783 p_AICCIUG<-((sum(Cont_AICC_IUG))/NR)*100
784 p_AICCIB
785 p_AICCIK
786 p_AICCIUG
787
788 #Calculando percentuais escolha distribuicao(BIC)
789 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
790 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
791 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
792 p_BICIB
793 p_BICIK
794 p_BICIUG
795
796 #Calculando percentuais escolha distribuicao(BICC)
797 p_BICCIB<-((sum(Cont_BICC_IB))/NR)*100
798 p_BICCIK<-((sum(Cont_BICC_IK))/NR)*100
799 p_BICCIUG<-((sum(Cont_BICC_IUG))/NR)*100
800 p_BICCIB
801 p_BICCIK
802 p_BICCIUG
803
804 #Calculando percentuais escolha distribuicao(HQ)
805 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
806 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
807 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
808 p_HQIB
809 p_HQIK
810 p_HQIUG
811
812 #Calculando percentuais escolha distribuicao(HQC)
813 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
814 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
815 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
816 p_HQCIB
817 p_HQCIK
818 p_HQCIUG
819
820
821 #Calculando percentuais escolha distribuicao(-LL)
822 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
823 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
824 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100

```

```

825 p_LLIB
826 p_LLIK
827 p_LLIUG
828
829 #resultados -log.vero
830 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)
831 #Recebendo Resultados(AIC)
832 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
833 result_AIC
834 #Recebendo Resultados(AICC)
835 result_AICC=cbind(p_AICCIB,p_AICCIK,p_AICCIUG)
836 result_AICC
837 #Recebendo Resultados(BIC)
838 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
839 result_BIC
840 #Recebendo Resultados(BICC)
841 result_BICC=cbind(p_BICCIB,p_BICCIK,p_BICCIUG)
842 result_BICC
843 #Recebendo Resultados(HQ)
844 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
845 result_HQ
846 #Recebendo Resultados(HQC)
847 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
848 result_HQC
849
850 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100
851
852 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
853
854 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
855
856 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
857
858 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100
859
860 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
861
862 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
863
864 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
865
866 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
867
868 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
    rej.iuGA)
869
870 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.

```

```

      rej.iuGA)
871
872 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
      Nao.rej.iuGA)
873
874 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
      result_HQC,result.taxa.rej.ks,
875 result.taxa.rej.ad,result.taxa.rej.cvm)
876 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
877 rownames(M) <- c("-LogVero","AIC","AICC","BIC", "BICC","HQ","HQC", "Taxa.Nao.Rej.
      ks",
878 "Taxa.Nao.Rej.ad","Taxa.Nao.Rej.cvm")
879
880 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
      .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
881 "\n", "alpha.0: {alpha0}","\n", "alpha.1: {alpha1}", "\n", "gama: {gama}","\n", "
      phi: {phi}","\n", "media: {media.v}",
882 "\n", "var: {round(var.v,4)}")
883 print("Resultados")
884 print(M)
885
886 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
      )
887 colnames(M.res) <- c("BIm.I","Kuma.I","GU.I")
888 rownames(M.res) <- c("criterios", "Taxa.Nao.Rej.ks","Taxa.Nao.Rej.ad","Taxa.Nao.
      Rej.cvm")
889 xtable(M.res)
890
891 cv=sd.of/mu
892 cv
893 var.teste=sd.of*sd.of
894 var.teste
895 #Salvando em um arquivo
896 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")
897 var.amostral

```

```

1  ##Simulacao gerando amostras a partir da beta inflacionada em zero e um##
2  library(gamlss)
3  library(gamlss.dist)
4  library(gamlss.data)
5  library(betareg)
6  library(MASS)
7  library(goftest)
8  source("ikumafit.R")
9  source("iuga_fitv4.R")
10 source("ibetafit.R")
11 source("iuga_v2.R")

```

```

12 set.seed(33) #Fixando a semente
13 source("ikum-omega-phi.R")
14 # library(optimx)
15 library(rootSolve)
16 library(VGAM)
17 library(xtable)
18 # library(fitdistrplus)
19
20 "ikumafit" <- function(y){
21
22   y <- as.vector(y)
23
24   n <- length(y)
25   n0<- sum(y==0) # number of zeros
26   n1<- sum(y==1) # number of ones
27
28   lambda <- (n0+n1)/n # lambda estimator
29   p <- n1/(n0+n1)# p estimator
30
31   u<-1
32   if(n0 == 0)
33   {
34     p=1
35     u=0
36   }
37
38   if(n1 == 0)
39   {
40     p=0
41     u=0
42   }
43
44   i01 <- (y==0)+(y==1)
45
46   loglik <- function(theta)
47   {
48     omega <- theta[1]
49     phi <- theta[2]
50
51     #####
52     l2 = 0
53     if(u!=0)
54     {
55       l2a = ifelse((y == 1), log(p), 0)
56       l2b = ifelse((y == 0), log(1-p), 0)
57       l2 = l2a + l2b
58     }

```

```

59
60 l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
61
62 l3 = ifelse((i01 == 1), 0,
63 log(phi)+
64 log(log(0.5)/log(1-omega^phi))+
65 (phi-1)*log(y)+
66 ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
67 )
68
69 sum(l1 + l2 + l3)
70 }
71
72 escore <- function(theta)
73 {
74 omega <- theta[1]
75 phi <- theta[2]
76
77 delta = log(0.5)/log(1-omega^phi)
78 ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
79 +1)
80
81 c = ifelse((y == 0), 0, ci)
82 c = ifelse((y == 1), 0, c)
83
84 Uomega <- phi*sum(c)
85
86 v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
87 (delta-1)*((y^phi)*log(y)/(1-y^phi)))
88 v = ifelse((y == 1), 0, v)
89
90 Uphi <- sum(v)
91
92 derivada=c(Uomega,Uphi)
93 }
94
95 ### initial values
96 ys01<- y
97 if(any(y==0)) ys01<- ys01[-which(y==0)]
98 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
99
100 # fit <- vglm(ys01 ~ 1, kumar)
101 # par<-Coef(fit)
102
103 phi <- 5 #par[1]
104 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)

```

```

105
106 #print(c(lambda,p,omega,phi))
107 ini <- c(omega,phi)
108
109 #####
110
111 opt <- optim(ini, loglik, escore, # hessian = T,
112 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
113
114 # opt <- optim(ini, loglik, escore,
115 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
116 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
117 # # upper = rep(.Machine$double.xmax,(r+2))
118 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
119 # upper = rep(.Machine$double.xmax,(r+2))
120 # )
121
122 # opt <- optim(ini, loglik, escore)
123
124 # print(opt$par)
125
126 # print(names(opt))
127 # print(summary(opt) )
128 # print(summary(opt)[1:6] )
129 # print(opt$kk1)
130
131
132 if (opt$conv != 0)
133 warning("FUNCTION DID NOT CONVERGE!")
134
135 k <- c()
136
137 # print("AQUI1")
138 # print(gradient(escore, opt$par))
139
140 coef <- c(lambda,p,opt$par)
141 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
142 # print(coef)
143 k$coef <- coef
144 k$conv <- opt$conv
145 k$loglik <- opt$value
146 k$counts <- as.numeric(opt$counts[1])
147
148 # library(rootSolve)
149 # library(numDeriv)

```

```

150 # escores<-rbind(
151 # escore(coef),
152 # gradient(loglik, coef),
153 # grad(loglik, coef))
154 # print(round(escores,5))
155
156 # k$Knum<-gradient(escore, coef)
157
158 # print(k$Knum)
159 # k$Knum<-hessian(escore, coef, method="complex")
160 # print(k$Knum)
161
162
163 # # Expected information matrix
164 #
165 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
166 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
167 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
168 #
169 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
170 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
171 # delta <- log(0.5)/log(1-k$omega^k$phi)
172 #
173 # kapa<- 0.5772156649
174 # k0<- (pi^2)/6+kapa^2-2*kapa
175 #
176 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
177 #   log(1-y^k$phi)+1)
178 #
179 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
180 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
181 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
182 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
183 #
184 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
185 #
186 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
187 #
188 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
189 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
190 # #   phi)) -
191 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
192 # #   k$phi^3))
193 # #
194 # # si <- (1-k$lambda)*(b2) # ifelse(y=c,0,b2) #
195 #
196 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta

```

```

+1)-kapa)/((delta-1)*k$phi)) )
194 #
195 # L = diag(-1/(k$lambda*(1-k$lambda)))
196 # V = diag((k$lambda-1)*k$phi^2*h2)
197 # M = diag(mi)
198 # S = diag(si)
199 #
200 #
201 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
202 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
203 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
204 # Isb = t(Ibs)
205 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
206 #
207 # if(u!=0)
208 # {
209 #   k$pi <- as.vector(coef[(m+1):(m+u)])
210 #   eta_hat2 <- as.vector(w1*%k$pi)
211 #   k$p <- as.vector(linkinv2(eta_hat2))
212 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
213 #   P = diag(-k$lambda/(k$p*(1-k$p)))
214 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
215 #
216 #   I <- rbind(
217 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
218 #       ncol=s)),
219 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
220 #       ncol=s)),
221 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
222 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
223 #   )
224 # }else{
225 #   I <- rbind(
226 #     cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
227 #     cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
228 #     cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
229 #   )
230 # }
231 # k$I <- I
232 #
233 #
234 # #####
235 #
236 # # print(-k$Knum)
237 # # print(k$I)

```



```

238 #
239 # # vcov <- try(solve(-k$Knum))
240 # vcov <- try(solve(k$I))
241 # # vcov <- chol2inv(chol(k$I))
242 # #vcov <- K #somente para nao trancar simulacao
243 #
244 # k$cov_ok = 0
245 # if (class(vcov) == "try-error")
246 # {
247   # vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
   # with inversion
248   # k$cov_ok = 1
249   #
250   # if (class(vcov) == "try-error") #
251   # {
252     # vcov <- k$Knum^2
253     # warning("Problem with the variance and covariance matrix. The p-values
   # are not correct.")
254     # k$cov_ok = 2
255     # }
256   # }
257
258
259 # k$vcov <- vcov
260 # stderror <- sqrt(diag(k$vcov))
261 # k$stderror <- stderror
262
263 return(k)
264 }
265
266 ibetafit<-function(x)
267 {
268
269   n<- length(x) # sample size
270   n0<- sum(x==0) # number of zeros
271   n1<- sum(x==1) # number of ones
272   m<- n0 + n1
273
274   xm0<-x[which(x>0)]
275   x01<-xm0[which(xm0<1)]
276
277   #MV
278   loglik<-function(par)
279   {
280     alpha0<-par[1]
281     alpha1<-par[2]
282     gama<-par[3]

```

```

283 phi<-par[4]
284
285 alpha0 = ifelse(n0==0,0,alpha0)
286 alpha1 = ifelse(n1==0,0,alpha1)
287
288 #print(c(alpha0,alpha1,gama,phi))
289
290 c<- 1- alpha0*(1-gama)-alpha1*gama
291 mu<- gama*(1-alpha1)/c
292
293
294 l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
295 l1 = ifelse( (x == 1), log(alpha1*gama), 0)
296 l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
297 l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
    - mu) * phi, log = TRUE)))
298
299
300 #print("soma")
301 #print(sum(l0 + l1 + l2+ l3))
302 sum(l0 + l1 + l2+ l3)
303 }
304
305 escore<-function(par)
306 {
307   alpha0<-par[1]
308   alpha1<-par[2]
309   gama<-par[3]
310   phi<-par[4]
311
312   c<- 1- alpha0*(1-gama)-alpha1*gama
313   mu<- (gama*(1-alpha1))/c
314
315   a= mu * phi
316   b = a * (1 - mu)/mu
317
318   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
319   mustar <- digamma(a) - digamma(b)
320
321
322
323 Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
324 #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
325 Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
    mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
326 Ualpha0 = sum(Ualpha01 + Ualpha03)
327

```

```

328 Ualpha0 = ifelse(n0==0,0,Ualpha0)
329
330
331 Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
332 #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
333 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
334   gama*(1-gama)*(1-alpha0))/(c^2) ) )
335 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
336   digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
337 Ualpha1 = sum(Ualpha11 - Ualpha13)
338
339 Ualpha1 = ifelse(n1==0,0,Ualpha1)
340
341 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
342 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
343 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
344   mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
345
346 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
347
348 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
349   #(mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
350   digamma(b))
351   mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
352   )
353 Uphi = sum(Uphi0)
354
355 c(Ualpha0,Ualpha1,Ugama,Uphi)
356 }
357
358 # metodo dos momentos para iniciarlizacao
359 x_bar<-mean(x01)
360 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
361
362 p<-x_bar*((x_bar*(1-x_bar))/sigma2_hat)-1)
363 q<-(1-x_bar)*((x_bar*(1-x_bar))/sigma2_hat)-1)
364
365 #print(c(x_bar,sigma2_hat,p,q))
366
367 delta0<- n0/n
368 delta1<- n1/n
369
370 a0<- delta0/(1-x_bar)
371 a1<- delta1/(x_bar)
372
373 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)

```

```

371 par_ini<-c(a0,a1,p/(p+q),p+q)
372
373 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
374
375 #print("par_ini")
376 #print(par_ini)
377
378 max<-optim(par_ini,loglik,
379     escore,
380     method="BFGS",
381     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
382         (0.99999,0.99999,0.99999,9999999999),
383     control=list(fnscale=-1))
384
385 if(max$convergence != 0) print("Non-convergence")
386 # return
387 z<-c()
388 z$mv<-max$par
389 #print(z$mv)
390 z$conv<-max$convergence
391 z$loglik <- max$value
392 return(z)
393 }
394
395 iuGAfit <- function(y)
396 {
397     n <- length(y) # sample size
398     n0 <- sum(y == 0) # number of zeros
399     n1 <- sum(y == 1) # number of ones
400     m <- n0 + n1
401
402     ys01 <- y
403     if(any(y==0)) ys01<- ys01[-which(y==0)]
404     if(any(y==1)) ys01<- ys01[-which(ys01==1)]
405
406     i01 <- (y==0)+(y==1)
407     #Maxima verossimilhanca
408
409     loglik <- function (par){
410
411         alpha0 <- par[1]
412         alpha1 <- par[2]
413         gama <- par[3]
414         phi <- par[4]

```

```

417
418 alpha0 = ifelse(n0 == 0, 0, alpha0)
419 alpha1 = ifelse(n1 == 0, 0, alpha1)
420
421 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
422 mu <- gama * (1 - alpha1) / c
423 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
424
425 l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
426 l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
427 l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
428 l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
429
430 #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
431
432 sum(l0 + l1 + l2 + l3)
433
434 }
435 escore <- function (par) {
436
437   alpha0 <- par[1]
438   alpha1 <- par[2]
439   gama <- par[3]
440   phi <- par[4]
441
442   alpha0 <- ifelse(n0 == 0, 0, alpha0)
443   alpha1 <- ifelse(n1 == 0, 0, alpha1)
444
445   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
446   mu <- gama * (1 - alpha1) / c
447   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
448   ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
449   mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
450
451
452   Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
453   Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
     / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
     ^ 2))
454   Ualpha0 <- sum(Ualpha01 + Ualpha03)
455
456   Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
457
458   Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
459   Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
     (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
     2))

```

```

460   Ualpha1 <- sum(Ualpha11 + Ualpha13)
461
462   Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
463
464
465   Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
466   Ugama02 <- ifelse((y == 1), 1 / gama, 0)
467   Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
      + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
      ^ 2))
468
469   Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
470
471   Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
      /phi - ((d^2) *log(mu)* log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
      phi) - log(mu^(1/phi)))
472
473   Uphi = sum(Uphi0)
474
475
476   c(Ualpha0, Ualpha1, Ugama, Uphi)
477 }
478
479 #Inicializacao
480 y_bar <- mean(y)
481 y_bar0 <- mean(ys01)
482
483 delta0 <- n0/n
484 delta1 <- n1/n
485
486 a0 <- delta0/(1-y_bar)
487 a1 <- delta1/(y_bar)
488
489
490 #fit <- vglm(ys01 ~ 1, gamma2)
491 #par<-Coef(fit)
492
493 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
494 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
495 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
496 #phi_til = 5
497 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
498
499 par_ini <- c(a0, a1, y_bar, phi_til)
500
501
502 max<-optim(par_ini, loglik, escore,method = "BFGS",

```

```

503 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,999999999),
504 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,999999999),
505 control=list(fnscale=-1))
506
507 if(max$convergence != 0) print("Non-convergence")
508 # return
509 z <- c()
510 z$ini <- par_ini
511 z$mv <- max$par
512 z$conv <- max$convergence
513 z$loglik <- max$value
514 return(z)
515 }
516
517 n=100
518 #n=60
519 #n=100
520 #n=200
521 NR=10000
522 k=4 # numero de parametros
523
524 Cont_AIC_IB=rep(0,NR)
525 Cont_AIC_IK=rep(0,NR)
526 Cont_AIC_IUG=rep(0,NR)
527
528 Cont_AICC_IB=rep(0,NR)
529 Cont_AICC_IK=rep(0,NR)
530 Cont_AICC_IUG=rep(0,NR)
531
532 Cont_BIC_IB=rep(0,NR)
533 Cont_BIC_IK=rep(0,NR)
534 Cont_BIC_IUG=rep(0,NR)
535
536 Cont_BICC_IB=rep(0,NR)
537 Cont_BICC_IK=rep(0,NR)
538 Cont_BICC_IUG=rep(0,NR)
539
540 Cont_HQ_IB=rep(0,NR)
541 Cont_HQ_IK=rep(0,NR)
542 Cont_HQ_IUG=rep(0,NR)
543
544 Cont_HQC_IB=rep(0,NR)
545 Cont_HQC_IK=rep(0,NR)
546 Cont_HQC_IUG=rep(0,NR)
547

```

```

548 Cont_LL_IB =rep(0,NR)
549 Cont_LL_IK=rep(0,NR)
550 Cont_LL_IUG=rep(0,NR)
551
552 contC=0
553 contC1=0
554
555 prop.z = rep(0,NR)
556 prop.u = rep(0,NR)
557 media.1=rep(0,NR)#isaacc
558 sd.1=rep(0,NR) #isaacc
559
560 cvm.iBE = rep(0,NR)
561 ks.iBE = rep(0,NR)
562 ad.iBE = rep(0,NR)
563
564 cvm.iuGA = rep(0,NR)
565 ks.iuGA = rep(0,NR)
566 ad.iuGA = rep(0,NR)
567
568 cvm.ikum = rep(0,NR)
569 ks.ikum = rep(0,NR)
570 ad.ikum = rep(0,NR)
571
572 alpha0 = 0.07
573 alpha1 = 0.07
574 gama= 0.8
575 phi = 10
576
577 prob.0=alpha0*(1-gama) #(prob de zero)
578 prob.1=alpha1*gama #(prob de um)
579 prob.0
580 prob.1
581
582
583 lambda = prob.0+prob.1 #(prop.infl ou seja pro.0+prop.1)
584 lambda
585 p=(prob.1)/(lambda)
586 p
587
588
589 valores.parametros = c(alpha0, alpha1, gama, phi)
590
591 prob.z = alpha0*(1-gama)
592 prob.o = alpha1*gama
593
594 prob.z # probabilidade de zero

```



```

595 prob.o #probabilidade de um
596
597
598 media.v = gama
599
600 var.v=gama*((1+alpha1*phi)/(1+phi)) + (((1-alpha1)*(1-alpha1)*phi)/((1-alpha0*(1-
      gama)-alpha1*gama)*(1+phi)) -1)*gama^(2)
601 media.v
602 var.v
603
604 c= 1- alpha0*(1-gama)-alpha1*gama
605 mu = gama*(1-alpha1)/c
606 delta0 = alpha0 * (1-gama)
607 delta1 = alpha1 * (gama)
608 p2= 1- delta0-delta1
609
610 mu
611 delta0
612 delta1
613 p2
614 dp = sqrt(1/(phi+1))
615 dp
616
617
618 teste.cv=dp/media.v
619 teste.cv
620 cont.ib = 0
621 cont.ik = 0
622 cont.igu = 0
623
624 for(i in 1:NR) {
625
626   #y = riGU(n,alpha0 = alpha0, alpha1=alpha1, gama = gama, phi = phi)
627   y = rBEINF(n, mu = mu , sigma=dp, nu=delta0/p2, tau=delta1/p2) # Inf.0
628   len = length(y)
629   prop.z[i] = sum(ifelse(y==0,1,0))/len
630   prop.u[i] = sum(ifelse(y==1,1,0))/len
631   media.1[i]=mean(y)#isaacc
632   sd.1[i]=sd(y)#isaacc
633
634   fitib = ibetafit(y)
635   if (fitib$conv != 0)
636   {
637     cont.ib = cont.ib+1
638   }
639
640   fitik = ikumafit(y)

```

```

641 if (fitik$conv != 0)
642 {
643   cont.ik = cont.ik+1
644 }
645
646 fitigu = iuGAfit(y)
647
648 if ((fitigu$conv != 0) ){
649   cont.igu=cont.igu+1
650 }
651
652
653 ks.iBE[i] = ifelse(ks.test(y, "pBEINF",mu=mu , sigma=dp, nu=delta0/p2, tau=
        delta1/p2)$p.value>0.05,1,0)
654
655 ad.iBE[i] = ifelse(ad.test(y, null="pBEINF",mu=mu , sigma=dp, nu=delta0/p2, tau
        =delta1/p2)$p.value>0.05,1,0)
656
657 cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINF",mu=mu , sigma=dp, nu=delta0/p2,
        tau=delta1/p2)$p.value >0.05,1,0)
658
659 ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
        phi=phi)$p.value>0.05,1,0)
660
661 ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
662
663 cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
664
665
666 ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=lambda, p=p,omega=gama, phi=phi)$
        p.value>0.05,1,0)
667
668 ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=lambda, p=p,omega=gama, phi=
        phi)$p.value>0.05,1,0)
669
670 cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=lambda, p=p,omega=gama,
        phi=phi)$p.value>0.05,1,0)
671
672 #Log verossimilhanca
673 # Beta inflacionada
674 log.vero_IB = fitib$loglik
675 # Kuma inflacionada
676 log.vero_IK= fitik$loglik
677 # Gamma Unitaria inflacionada
678 log.vero_IUG = fitigu$loglik

```

```

679
680 m.log.vero_IB = -fitib$loglik
681 # Kuma inflacionada
682 m.log.vero_IK= -fitik$loglik
683 # Gamma Unitaria inflacionada
684 m.log.vero_IUG = -fitigu$loglik
685
686 #Menor -log verossimilhanca
687
688 min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
689
690 Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
691 Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
692 Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)
693
694
695
696
697 # Calculando os criterios/quantidades para comparacao
698
699 #criteiro_AIC#
700 # Beta inflacionada
701 AIC_IB = -2*log.vero_IB+2*k
702 # Kuma inflacionada
703 AIC_IK= -2*log.vero_IK+2*k
704 # Gamma Unitaria inflacionada
705 AIC_IUG = -2*log.vero_IUG+2*k
706
707 # Selecionando o menor AIC
708 min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
709
710 Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0)
711 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
712 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
713
714
715 # Beta inflacionada
716 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1)
717 # Kuma inflacionada
718 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1)
719 # Gamma Unitaria inflacionada
720 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1)
721
722 # Selecionando o menor AICC
723 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
724
725 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0)

```

```

726 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
727 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)
728
729 #criterio_BIC#
730 # Beta inflacionada
731 BIC_IB=-2*log.vero_IB+k*log(n)
732 #Kuma inflacionada
733 BIC_IK=-2*log.vero_IK+k*log(n)
734 # Gamma Unitaria inflacionada
735 BIC_IUG=-2*fitigu$loglik+k*log(n)
736
737 # Seleccionando o menor BIC
738 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
739
740 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
741 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
742 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)
743
744 #criterio_BICC#
745 # Beta inflacionada
746 BICC_IB=-2*log.vero_IB+(k*log(n))/(n-k-1)
747 #Kuma inflacionada
748 BICC_IK=-2*log.vero_IK+(k*log(n))/(n-k-1)
749 # Gamma Unitaria inflacionada
750 BICC_IUG=-2*fitigu$loglik+(k*log(n))/(n-k-1)
751
752 # Seleccionando o menor BICC
753 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
754
755 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
756 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)
757 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
758
759 #criterio_HQ#
760 # Beta inflacionada
761 HQ_IB=-2*log.vero_IB+2*log(log(n))
762 #Kuma inflacionada
763 HQ_IK=-2*log.vero_IK+2*log(log(n))
764 # Gamma Unitaria inflacionada
765 HQ_IUG=-2*fitigu$loglik+2*log(log(n))
766
767 # Seleccionando o menor HQ
768 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
769
770 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
771 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
772 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)

```

```

773
774 #criterio_HQC#
775 # Beta inflacionada
776 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1)
777 #Kuma inflacionada
778 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1)
779 # Gamma Unitaria inflacionada
780 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1)
781
782 # Selecionando o menor HQC
783 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
784
785
786 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
787 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)
788 Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
789 # FIM DO LACO DE MONTE CARLO
790
791 }
792
793 # Proporcao media de zeros
794 #mean(prop.z)
795 # Proporcao media de uns
796 #mean(prop.u)
797 #media das medias
798 mu.of=mean(media.1)
799 #media do desvio padrao
800 sd.of=mean(sd.1)
801
802
803
804 #Calculando percentuais escolha distribuicao(AIC)
805 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
806 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
807 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
808 p_AICIB
809 p_AICIK
810 p_AICIUG
811
812 #Calculando percentuais escolha distribuicao(AICC)
813 p_AICCIB<-((sum(Cont_AICC_IB))/NR)*100
814 p_AICCIK<-((sum(Cont_AICC_IK))/NR)*100
815 p_AICCIUG<-((sum(Cont_AICC_IUG))/NR)*100
816 p_AICCIB
817 p_AICCIK
818 p_AICCIUG
819

```

```

820 #Calculando percentuais escolha distribuicao(BIC)
821 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
822 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
823 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
824 p_BICIB
825 p_BICIK
826 p_BICIUG
827
828 #Calculando percentuais escolha distribuicao(BICC)
829 p_BICCIB<-((sum(Cont_BICC_IB))/NR)*100
830 p_BICCIK<-((sum(Cont_BICC_IK))/NR)*100
831 p_BICCIUG<-((sum(Cont_BICC_IUG))/NR)*100
832 p_BICCIB
833 p_BICCIK
834 p_BICCIUG
835
836 #Calculando percentuais escolha distribuicao(HQ)
837 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
838 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
839 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
840 p_HQIB
841 p_HQIK
842 p_HQIUG
843
844 #Calculando percentuais escolha distribuicao(HQC)
845 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
846 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
847 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
848 p_HQCIB
849 p_HQCIK
850 p_HQCIUG
851
852
853 #Calculando percentuais escolha distribuicao(-LL)
854 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
855 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
856 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100
857 p_LLIB
858 p_LLIK
859 p_LLIUG
860
861 #resultados -log.vero
862 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)
863 #Recebendo Resultados(AIC)
864 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
865 result_AIC
866 #Recebendo Resultados(AICC)

```

```

867 result_AICC=cbind(p_AICCIB,p_AICCIK,p_AICCIUG)
868 result_AICC
869 #Recebendo Resultados(BIC)
870 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
871 result_BIC
872 #Recebendo Resultados(BICC)
873 result_BICC=cbind(p_BICCIB,p_BICCIK,p_BICCIUG)
874 result_BICC
875 #Recebendo Resultados(HQ)
876 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
877 result_HQ
878 #Recebendo Resultados(HQC)
879 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
880 result_HQC
881
882 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100
883
884 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
885
886 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
887
888 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
889
890 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100
891
892 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
893
894 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
895
896 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
897
898 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
899
900 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
    rej.iuGA)
901
902 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.
    rej.iuGA)
903
904 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
    Nao.rej.iuGA)
905
906
907
908 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
    result_HQC,result.taxa.rej.ks,
909 result.taxa.rej.ad,result.taxa.rej.cvm)

```

```

910 colnames(M) <- c("BIm.I", "Kuma.I", "GU.I")
911 rownames(M) <- c("-LogVero", "AIC", "AICC", "BIC", "BICC", "HQ", "HQC", "Taxa.Nao.Rej.
    ks",
912 "Taxa.Nao.Rej.ad", "Taxa.Nao.Rej.cvm")
913
914 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
    .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
915 "\n", "alpha.0: {alpha0}", "\n", "alpha.1: {alpha1}", "\n", "gama: {gama}", "\n", "
    phi: {phi}", "\n", "media: {media.v}",
916 "\n", "var: {round(var.v,4)}")
917 print("Resultados")
918 print(M)
919
920 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
    )
921 colnames(M.res) <- c("BIm.I", "Kuma.I", "GU.I")
922 rownames(M.res) <- c("criterios", "Taxa.Nao.Rej.ks", "Taxa.Nao.Rej.ad", "Taxa.Nao.
    Rej.cvm")
923 xtable(M.res)
924
925 cv=sd.of/mu.of
926 cv
927 var.teste=sd.of*sd.of
928 #Salvando em um arquivo
929 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")

```

```

1  ##Simulacao gerando amostras a partir da beta inflacionada em um##
2  library(gamlss)
3  library(gamlss.dist)
4  library(gamlss.data)
5  library(betareg)
6  library(MASS)
7  library(goftest)
8
9  source("ikumafit.R")
10 source("iuga_fitv4.R")
11 source("ibetafit.R")
12 source("iuga_v2.R")
13
14
15 set.seed(33) #Fixando a semente
16
17
18 source("ikum-omega-phi.R")
19 # library(optimx)
20 library(rootSolve)
21 library(VGAM)

```



```

22 library(xtable)
23 # library(fitdistrplus)
24
25 "ikumafit" <- function(y){
26
27   y <- as.vector(y)
28
29   n <- length(y)
30   n0<- sum(y==0) # number of zeros
31   n1<- sum(y==1) # number of ones
32
33   lambda <- (n0+n1)/n # lambda estimator
34   p <- n1/(n0+n1) # p estimator
35
36   u<-1
37   if(n0 == 0)
38   {
39     p=1
40     u=0
41   }
42
43   if(n1 == 0)
44   {
45     p=0
46     u=0
47   }
48
49   i01 <- (y==0)+(y==1)
50
51   loglik <- function(theta)
52   {
53     omega <- theta[1]
54     phi <- theta[2]
55
56     #####
57     l2 = 0
58     if(u!=0)
59     {
60       l2a = ifelse((y == 1), log(p), 0)
61       l2b = ifelse((y == 0), log(1-p), 0)
62       l2 = l2a + l2b
63     }
64
65     l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
66
67     l3 = ifelse((i01 == 1), 0,
68     log(phi)+

```

```

69   log(log(0.5)/log(1-omega^phi))+
70   (phi-1)*log(y)+
71   ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
72   )
73
74   sum(l1 + l2 + l3)
75 }
76
77 escore <- function(theta)
78 {
79   omega <- theta[1]
80   phi <- theta[2]
81
82   delta = log(0.5)/log(1-omega^phi)
83   ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
84         +1)
85
86   c = ifelse((y == 0), 0, ci)
87   c = ifelse((y == 1), 0, c)
88
89   Uomega <- phi*sum(c)
90
91   v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
92   (delta-1)*((y^phi)*log(y)/(1-y^phi)))
93   v = ifelse((y == 1), 0, v)
94
95   Uphi <- sum(v)
96
97   derivada=c(Uomega,Uphi)
98   derivada
99 }
100
101 ### initial values
102 ys01<- y
103 if(any(y==0)) ys01<- ys01[-which(y==0)]
104 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
105
106 # fit <- vglm(ys01 ~ 1, kumar)
107 # par<-Coef(fit)
108
109 phi <- 5 #par[1]
110 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
111
112 #print(c(lambda,p,omega,phi))
113 ini <- c(omega,phi)
114 #####

```

```

115
116 opt <- optim(ini, loglik, escore, # hessian = T,
117 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
118
119 # opt <- optim(ini, loglik, escore,
120 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
121 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
122 # # upper = rep(.Machine$double.xmax,(r+2))
123 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
124 # upper = rep(.Machine$double.xmax,(r+2))
125 # )
126
127 # opt <- optim(ini, loglik, escore)
128
129 # print(opt$par)
130
131 # print(names(opt))
132 # print(summary(opt) )
133 # print(summary(opt)[1:6] )
134 # print(opt$kk1)
135
136
137 if (opt$conv != 0)
138 warning("FUNCTION DID NOT CONVERGE!")
139
140 k <- c()
141
142 # print("AQUI1")
143 # print(gradient(escore, opt$par))
144
145 coef <- c(lambda,p,opt$par)
146 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
147 # print(coef)
148 k$coef <- coef
149 k$conv <- opt$conv
150 k$loglik <- opt$value
151 k$counts <- as.numeric(opt$counts[1])
152
153 # library(rootSolve)
154 # library(numDeriv)
155 # escores<-rbind(
156 # escore(coef),
157 # gradient(loglik, coef),
158 # grad(loglik, coef))
159 # print(round(escores,5))

```

```

160
161 # k$Knum<-gradient(escore, coef)
162
163 # print(k$Knum)
164 # k$Knum<-hessian(escore, coef, method="complex")
165 # print(k$Knum)
166
167
168 # # Expected information matrix
169 #
170 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
171 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
172 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
173 #
174 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
175 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
176 # delta <- log(0.5)/log(1-k$omega^k$phi)
177 #
178 # kapa<- 0.5772156649
179 # k0<- (pi^2)/6+kapa^2-2*kapa
180 #
181 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
      log(1-y^k$phi)+1)
182 #
183 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
184 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
185 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
186 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
187 #
188 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
189 #
190 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
191 #
192 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
193 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
      phi)) -
194 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
      k$phi^3))
195 # #
196 # # si <- (1-k$lambda)*(b2) # ifelse(y==c,0,b2) #
197 #
198 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
      +1)-kapa)/((delta-1)*k$phi)) )
199 #
200 # L = diag(-1/(k$lambda*(1-k$lambda)))
201 # V = diag((k$lambda-1)*k$phi^2*h2)
202 # M = diag(mi)

```

```

203 # S = diag(si)
204 #
205 #
206 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
207 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
208 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
209 # Isb = t(Ibs)
210 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
211 #
212 # if(u!=0)
213 # {
214 #   k$pi <- as.vector(coef[(m+1):(m+u)])
215 #   eta_hat2 <- as.vector(w1*%k$pi)
216 #   k$p <- as.vector(linkinv2(eta_hat2))
217 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
218 #   P = diag(-k$lambda/(k$p*(1-k$p)))
219 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
220 #
221 #   I <- rbind(
222 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
223 #       ncol=s)),
224 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
225 #       ncol=s)),
226 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
227 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
228 #   )
229 # }else{
230 #   I <- rbind(
231 #     cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
232 #     cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
233 #     cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
234 #   )
235 # }
236 # k$I <- I
237 #
238 #
239 # #####
240 #
241 # # print(-k$Knum)
242 # # print(k$I)
243 #
244 # # vcov <- try(solve(-k$Knum))
245 # # vcov <- try(solve(k$I))
246 # # vcov <- chol2inv(chol(k$I))
247 # #vcov <- K #somente para nao trancar simulacao

```

```

248 #
249 # k$cov_ok = 0
250 # if (class(vcov) == "try-error")
251 # {
252   # vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
   # with inversion
253   # k$cov_ok = 1
254   #
255   # if (class(vcov) == "try-error") #
256   # {
257     # vcov <- k$Knum^2
258     # warning("Problem with the variance and covariance matrix. The p-values
   # are not correct.")
259     # k$cov_ok = 2
260     # }
261   # }
262
263
264 # k$vcov <- vcov
265 # stderr <- sqrt(diag(k$vcov))
266 # k$stderr <- stderr
267
268 return(k)
269 }
270
271 ibetafit<-function(x)
272 {
273
274   n<- length(x) # sample size
275   n0<- sum(x==0) # number of zeros
276   n1<- sum(x==1) # number of ones
277   m<- n0 + n1
278
279   xm0<-x[which(x>0)]
280   x01<-xm0[which(xm0<1)]
281
282   #MV
283   loglik<-function(par)
284   {
285     alpha0<-par[1]
286     alpha1<-par[2]
287     gama<-par[3]
288     phi<-par[4]
289
290     alpha0 = ifelse(n0==0,0,alpha0)
291     alpha1 = ifelse(n1==0,0,alpha1)
292

```

```

293 #print(c(alpha0,alpha1,gama,phi))
294
295 c<- 1- alpha0*(1-gama)-alpha1*gama
296 mu<- gama*(1-alpha1)/c
297
298
299 l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
300 l1 = ifelse( (x == 1), log(alpha1*gama), 0)
301 l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
302 l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
    - mu) * phi, log = TRUE)))
303
304
305 #print("soma")
306 #print(sum(l0 + l1 + l2+ l3))
307 sum(l0 + l1 + l2+ l3)
308 }
309
310 escore<-function(par)
311 {
312   alpha0<-par[1]
313   alpha1<-par[2]
314   gama<-par[3]
315   phi<-par[4]
316
317   c<- 1- alpha0*(1-gama)-alpha1*gama
318   mu<- (gama*(1-alpha1))/c
319
320   a= mu * phi
321   b = a * (1 - mu)/mu
322
323   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
324   mustar <- digamma(a) - digamma(b)
325
326
327
328   Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
329   #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
330   Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
    mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
331   Ualpha0 = sum(Ualpha01 + Ualpha03)
332
333   Ualpha0 = ifelse(n0==0,0,Ualpha0)
334
335
336   Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
337   #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)

```

```

338 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
      gama*(1-gama)*(1-alpha0))/ (c^2) ) )
339 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
      digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
340 Ualpha1 = sum(Ualpha11 - Ualpha13)
341
342 Ualpha1 = ifelse(n1==0,0,Ualpha1)
343
344 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
345 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
346 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
      mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
347
348 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
349
350 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
351 #((mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
352 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
353 )
354 Uphi = sum(Uphi0)
355
356
357 c(Ualpha0,Ualpha1,Ugama,Uphi)
358 }
359
360 # metodo dos momentos para iniciarlizacao
361 x_bar<-mean(x01)
362 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
363
364 p<-x_bar*(((x_bar*(1-x_bar))/sigma2_hat)-1)
365 q<-(1-x_bar)*(((x_bar*(1-x_bar))/sigma2_hat)-1)
366
367 #print(c(x_bar,sigma2_hat,p,q))
368
369 delta0<- n0/n
370 delta1<- n1/n
371
372 a0<- delta0/(1-x_bar)
373 a1<- delta1/(x_bar)
374
375 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
376 par_ini<-c(a0,a1,p/(p+q),p+q)
377
378 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
379
380 #print("par_ini")

```



```

381 #print(par_ini)
382
383 max<-optim(par_ini,loglik,
384     escore,
385     method="BFGS",
386     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
387         (0.99999,0.99999,0.99999,9999999999),
388     control=list(fnscale=-1))
389
390 if(max$convergence != 0) print("Non-convergence")
391 # return
392 z<-c()
393 z$mv<-max$par
394 #print(z$mv)
395 z$conv<-max$convergence
396 z$loglik <- max$value
397 return(z)
398 }
399
400 iuGAfit <- function(y)
401 {
402
403     n <- length(y) # sample size
404     n0 <- sum(y == 0) # number of zeros
405     n1 <- sum(y == 1) # number of ones
406     m <- n0 + n1
407
408     ys01 <- y
409     if(any(y==0)) ys01<- ys01[-which(y==0)]
410     if(any(y==1)) ys01<- ys01[-which(ys01==1)]
411
412     i01 <- (y==0)+(y==1)
413
414     #Maxima verossimilhanca
415
416     loglik <- function (par){
417
418         alpha0 <- par[1]
419         alpha1 <- par[2]
420         gama <- par[3]
421         phi <- par[4]
422
423         alpha0 = ifelse(n0 == 0, 0, alpha0)
424         alpha1 = ifelse(n1 == 0, 0, alpha1)
425
426

```

```

427 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
428 mu <- gama * (1 - alpha1) / c
429 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
430
431 l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
432 l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
433 l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
434 l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
435
436 #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
437
438 sum(l0 + l1 + l2 + l3)
439
440 }
441 escore <- function (par) {
442
443   alpha0 <- par[1]
444   alpha1 <- par[2]
445   gama <- par[3]
446   phi <- par[4]
447
448   alpha0 <- ifelse(n0 == 0, 0, alpha0)
449   alpha1 <- ifelse(n1 == 0, 0, alpha1)
450
451   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
452   mu <- gama * (1 - alpha1) / c
453   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
454   ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
455   mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
456
457
458   Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
459   Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
      / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
      ^ 2))
460   Ualpha0 <- sum(Ualpha01 + Ualpha03)
461
462   Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
463
464   Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
465   Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
      (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
      2))
466   Ualpha1 <- sum(Ualpha11 + Ualpha13)
467
468   Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
469

```

```

470
471 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
472 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
473 Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
+ d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
^ 2))
474
475 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
476
477 Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
/phi - ((d^2) *log(mu)* log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
phi) - log(mu^(1/phi)))
478
479 Uphi = sum(Uphi0)
480
481
482 c(Ualpha0, Ualpha1, Ugama, Uphi)
483 }
484
485 #Inicializacao
486
487 y_bar <- mean(y)
488 y_bar0 <- mean(ys01)
489
490 delta0 <- n0/n
491 delta1 <- n1/n
492
493 a0 <- delta0/(1-y_bar)
494 a1 <- delta1/(y_bar)
495
496
497 #fit <- vglm(ys01 ~ 1, gamma2)
498 #par<-Coef(fit)
499
500 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
501 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
502 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
503 #phi_til = 5
504 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
505
506 par_ini <- c(a0, a1, y_bar, phi_til)
507
508
509 max<-optim(par_ini, loglik, escore,method = "BFGS",
510 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
(0.99999,0.99999,0.99999,9999999999),
511 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c

```

```

(0.99999,0.99999,0.99999,9999999999),
512 control=list(fnscale=-1))
513
514 if(max$convergence != 0) print("Non-convergence")
515 # return
516 z <- c()
517 z$ini <- par_ini
518 z$mv <- max$par
519 z$conv <- max$convergence
520 z$loglik <- max$value
521 return(z)
522 }
523
524 n=200
525 #n=60
526 #n=100
527 #n=200
528 NR=10000
529 k=3 # numero de parametros
530
531 Cont_AIC_IB=rep(0,NR)
532 Cont_AIC_IK=rep(0,NR)
533 Cont_AIC_IUG=rep(0,NR)
534
535 Cont_AICC_IB=rep(0,NR)
536 Cont_AICC_IK=rep(0,NR)
537 Cont_AICC_IUG=rep(0,NR)
538
539 Cont_BIC_IB=rep(0,NR)
540 Cont_BIC_IK=rep(0,NR)
541 Cont_BIC_IUG=rep(0,NR)
542
543 Cont_BICC_IB=rep(0,NR)
544 Cont_BICC_IK=rep(0,NR)
545 Cont_BICC_IUG=rep(0,NR)
546
547 Cont_HQ_IB=rep(0,NR)
548 Cont_HQ_IK=rep(0,NR)
549 Cont_HQ_IUG=rep(0,NR)
550
551 Cont_HQC_IB=rep(0,NR)
552 Cont_HQC_IK=rep(0,NR)
553 Cont_HQC_IUG=rep(0,NR)
554
555 Cont_LL_IB =rep(0,NR)
556 Cont_LL_IK=rep(0,NR)
557 Cont_LL_IUG=rep(0,NR)

```

```

558
559 contC=0
560 contC1=0
561
562 prop.z = rep(0,NR)
563 prop.u = rep(0,NR)
564
565 cvm.iBE = rep(0,NR)
566 ks.iBE = rep(0,NR)
567 ad.iBE = rep(0,NR)
568
569
570 cvm.iuGA = rep(0,NR)
571 ks.iuGA = rep(0,NR)
572 ad.iuGA = rep(0,NR)
573
574 cvm.ikum = rep(0,NR)
575 ks.ikum = rep(0,NR)
576 ad.ikum = rep(0,NR)
577
578 alpha0 = 0
579 alpha1 = 0.1
580 gama = 0.5
581 phi = 10
582 valores.parametros = c(alpha0, alpha1, gama, phi)
583
584 # Isaac,
585 prob.z = alpha0*(1-gama)
586 prob.o = alpha1*gama
587
588 prob.z # probabilidade de zero
589 prob.o #probabilidade de um
590
591 # Isaac, v
592 media.v =gama
593 var.v =gama*((1+alpha1*phi)/(1+phi)) + (((1-alpha1)*(1-alpha1)*phi)/((1-alpha0*
    (1-gama)-alpha1*gama)*(1+phi)) -1)*gama^(2)
594
595 var.v
596 #Bayes - BEINF
597
598 c= 1- alpha0*(1-gama)-alpha1*gama
599 mu = gama*(1-alpha1)/c
600 delta0 = alpha0 * (1-gama)
601 delta1 = alpha1 * (gama)
602 p2= 1- delta0-delta1
603

```

```

604 mu
605 delta0
606 delta1
607 p2
608 dp = sqrt(1/(phi+1))
609
610
611 cont.ib = 0
612 cont.ik = 0
613 cont.igu = 0
614
615 for(i in 1:NR) {
616
617
618   y = rBEINF1(n, mu = mu , sigma=dp, nu=delta1/p2)
619   len = length(y)
620   prop.z[i] = sum(ifelse(y==0,1,0))/len
621   prop.u[i] = sum(ifelse(y==1,1,0))/len
622
623
624   fitib = ibetafit(y)
625   if (fitib$conv != 0)
626   {
627     cont.ib = cont.ib+1
628   }
629
630   fitik = ikumafit(y)
631   if (fitik$conv != 0)
632   {
633     cont.ik = cont.ik+1
634   }
635
636
637   fitigu = iuGAfit(y)
638
639
640   if ((fitigu$conv != 0) ){
641     cont.igu=cont.igu+1
642   }
643
644
645   ks.iBE[i] = ifelse(ks.test(y, "pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$p.value
646     >0.05,1,0)
647
648   ad.iBE[i] = ifelse(ad.test(y, null="pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$p.
649     value>0.05,1,0)

```

```

649   cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$
        p.value >0.05,1,0)
650
651
652   ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
        phi=phi)$p.value>0.05,1,0)
653
654   ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
655
656   cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
657
658
659   ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=alpha1, p=1,omega=gama, phi=phi)$
        p.value>0.05,1,0)
660
661   ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=alpha1, p=1,omega=gama, phi=
        phi)$p.value>0.05,1,0)
662
663   cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=alpha1, p=1,omega=gama,
        phi=phi)$p.value>0.05,1,0)
664
665
666   #Log verossimilhanca
667   # Beta inflacionada
668   log.vero_IB = fitib$loglik
669   # Kuma inflacionada
670   log.vero_IK= fitik$loglik
671   # Gamma Unitaria inflacionada
672   log.vero_IUG = fitigu$loglik
673
674   m.log.vero_IB = -fitib$loglik
675   # Kuma inflacionada
676   m.log.vero_IK= -fitik$loglik
677   # Gamma Unitaria inflacionada
678   m.log.vero_IUG = -fitigu$loglik
679
680   #Menor -log verossimilhanca
681
682   min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
683
684   Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
685   Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
686   Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)
687
688

```

```

689 # Calculando os criterios/quantidades para comparacao
690
691 #criterio_AIC#
692 # Beta inflacionada
693 AIC_IB = -2*log.vero_IB+2*k
694 # Kuma inflacionada
695 AIC_IK= -2*log.vero_IK+2*k
696 # Gamma Unitaria inflacionada
697 AIC_IUG = -2*log.vero_IUG+2*k
698
699 # Seleccionando o menor AIC
700 min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
701
702 Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0)
703 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
704 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
705
706 #criterio_AICC#
707 # Beta inflacionada
708 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1)
709 # Kuma inflacionada
710 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1)
711 # Gamma Unitaria inflacionada
712 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1)
713
714 # Seleccionando o menor AICC
715 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
716
717 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0)
718 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
719 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)
720
721 #criterio_BIC#
722 # Beta inflacionada
723 BIC_IB=-2*log.vero_IB+k*log(n)
724 #Kuma inflacionada
725 BIC_IK=-2*log.vero_IK+k*log(n)
726 # Gamma Unitaria inflacionada
727 BIC_IUG=-2*fitigu$loglik+k*log(n)
728
729 # Seleccionando o menor BIC
730 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
731
732 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
733 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
734 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)
735

```



```

736 #criterio_BICC#
737 # Beta inflacionada
738 BICC_IB=-2*log.vero_IB+(k*log(n))/(n-k-1)
739 #Kuma inflacionada
740 BICC_IK=-2*log.vero_IK+(k*log(n))/(n-k-1)
741 # Gamma Unitaria inflacionada
742 BICC_IUG=-2*fitigu$loglik+(k*log(n))/(n-k-1)
743
744 # Seleccionando o menor BICC
745 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
746
747 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
748 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)
749 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
750
751 #criterio_HQ#
752 # Beta inflacionada
753 HQ_IB=-2*log.vero_IB+2*log(log(n))
754 #Kuma inflacionada
755 HQ_IK=-2*log.vero_IK+2*log(log(n))
756 # Gamma Unitaria inflacionada
757 HQ_IUG=-2*fitigu$loglik+2*log(log(n))
758
759 # Seleccionando o menor HQ
760 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
761
762 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
763 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
764 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)
765
766 #criterio_HQC#
767 # Beta inflacionada
768 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1)
769 #Kuma inflacionada
770 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1)
771 # Gamma Unitaria inflacionada
772 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1)
773
774 # Seleccionando o menor HQC
775 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
776
777
778 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
779 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)
780 Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
781 # FIM DO LACO DE MONTE CARLO
782

```

```

783 }
784
785 # Proporcao media de zeros
786 #mean(prop.z)
787 # Proporcao media de uns
788 #mean(prop.u)
789
790
791 #Calculando percentuais escolha distribuicao(AIC)
792 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
793 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
794 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
795 p_AICIB
796 p_AICIK
797 p_AICIUG
798
799 #Calculando percentuais escolha distribuicao(AICC)
800 p_AICCIB<-((sum(Cont_AICC_IB))/NR)*100
801 p_AICCIK<-((sum(Cont_AICC_IK))/NR)*100
802 p_AICCIUG<-((sum(Cont_AICC_IUG))/NR)*100
803 p_AICCIB
804 p_AICCIK
805 p_AICCIUG
806
807 #Calculando percentuais escolha distribuicao(BIC)
808 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
809 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
810 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
811 p_BICIB
812 p_BICIK
813 p_BICIUG
814
815 #Calculando percentuais escolha distribuicao(BICC)
816 p_BICCIB<-((sum(Cont_BICC_IB))/NR)*100
817 p_BICCIK<-((sum(Cont_BICC_IK))/NR)*100
818 p_BICCIUG<-((sum(Cont_BICC_IUG))/NR)*100
819 p_BICCIB
820 p_BICCIK
821 p_BICCIUG
822
823 #Calculando percentuais escolha distribuicao(HQ)
824 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
825 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
826 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
827 p_HQIB
828 p_HQIK
829 p_HQIUG

```

```

830
831 #Calculando percentuais escolha distribuicao(HQC)
832 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
833 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
834 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
835 p_HQCIB
836 p_HQCIK
837 p_HQCIUG
838
839
840 #Calculando percentuais escolha distribuicao(-LL)
841 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
842 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
843 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100
844 p_LLIB
845 p_LLIK
846 p_LLIUG
847
848 #resultados -log.vero
849 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)
850 #Recebendo Resultados(AIC)
851 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
852 result_AIC
853 #Recebendo Resultados(AICC)
854 result_AICC=cbind(p_AICCIB,p_AICCIK,p_AICCIUG)
855 result_AICC
856 #Recebendo Resultados(BIC)
857 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
858 result_BIC
859 #Recebendo Resultados(BICC)
860 result_BICC=cbind(p_BICCIB,p_BICCIK,p_BICCIUG)
861 result_BICC
862 #Recebendo Resultados(HQ)
863 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
864 result_HQ
865 #Recebendo Resultados(HQC)
866 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
867 result_HQC
868
869 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100
870
871 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
872
873 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
874
875 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
876

```

```

877 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100
878
879 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
880
881 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
882
883 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
884
885 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
886
887 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
    rej.iuGA)
888
889 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.
    rej.iuGA)
890
891 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
    Nao.rej.iuGA)
892
893
894 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
    result_HQC,result.taxa.rej.ks,
895 result.taxa.rej.ad,result.taxa.rej.cvm)
896 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
897 rownames(M) <- c("-LogVero","AIC","AICC","BIC", "BICC","HQ","HQC", "Taxa.Nao.Rej.
    ks",
898 "Taxa.Nao.Rej.ad","Taxa.Nao.Rej.cvm")
899
900 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
    .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
901 "\n", "alpha.0: {alpha0}", "\n", "alpha.1: {alpha1}", "\n", "gama: {gama}", "\n", "
    phi: {phi}", "\n", "media: {media.v}",
902 "\n", "var: {round(var.v,4)}")
903 print("Resultados")
904 print(M)
905
906
907 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
    )
908 colnames(M.res) <- c("BIm.I","Kuma.I","GU.I")
909 rownames(M.res) <- c("criterios", "Taxa.Nao.Rej.ks","Taxa.Nao.Rej.ad","Taxa.Nao.
    Rej.cvm")
910 xtable(M.res)
911
912 #Salvando em um arquivo
913 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")

```

```

1  ##Simulacao gerando amostras a partir da kumaraswamy inflacionada em zero##
2  library(gamlss)
3  library(gamlss.dist)
4  library(gamlss.data)
5  library(betareg)
6  library(MASS)
7  library(goftest)
8
9  source("ikumafit.R")
10 source("iuga_fitv4.R")
11 source("ibetafit.R")
12 source("iuga_v2.R")
13
14
15 set.seed(33) #Fixando a semente
16
17
18 source("ikum-omega-phi.R")
19 # library(optimx)
20 library(rootSolve)
21 library(VGAM)
22 library(xtable)
23 # library(fitdistrplus)
24
25 "ikumafit" <- function(y){
26
27   y <- as.vector(y)
28
29   n <- length(y)
30   n0<- sum(y==0) # number of zeros
31   n1<- sum(y==1) # number of ones
32
33   lambda <- (n0+n1)/n # lambda estimator
34   p <- n1/(n0+n1)# p estimator
35
36   u<-1
37   if(n0 == 0)
38   {
39     p=1
40     u=0
41   }
42
43   if(n1 == 0)
44   {
45     p=0
46     u=0
47   }

```

```

48
49 i01 <- (y==0)+(y==1)
50
51 loglik <- function(theta)
52 {
53   omega <- theta[1]
54   phi <- theta[2]
55
56   #####
57   l2 = 0
58   if(u!=0)
59   {
60     l2a = ifelse((y == 1), log(p), 0)
61     l2b = ifelse((y == 0), log(1-p), 0)
62     l2 = l2a + l2b
63   }
64
65   l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
66
67   l3 = ifelse((i01 == 1), 0,
68   log(phi)+
69   log(log(0.5)/log(1-omega^phi))+
70   (phi-1)*log(y)+
71   ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
72   )
73
74   sum(l1 + l2 + l3)
75 }
76
77 escore <- function(theta)
78 {
79   omega <- theta[1]
80   phi <- theta[2]
81
82   delta = log(0.5)/log(1-omega^phi)
83   ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
84   +1)
85
86   c = ifelse((y == 0), 0, ci)
87   c = ifelse((y == 1), 0, c)
88
89   Uomega <- phi*sum(c)
90
91   v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
92   (delta-1)*((y^phi)*log(y)/(1-y^phi)))
93   v = ifelse((y == 1), 0, v)

```

```

94     Uphi <- sum(v)
95
96     derivada=c(Uomega,Uphi)
97     derivada
98 }
99
100 ### initial values
101 ys01<- y
102 if(any(y==0)) ys01<- ys01[-which(y==0)]
103 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
104
105 # fit <- vglm(ys01 ~ 1, kumar)
106 # par<-Coef(fit)
107
108 phi <- 5 #par[1]
109 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
110
111 #print(c(lambda,p,omega,phi))
112 ini <- c(omega,phi)
113
114 #####
115
116 opt <- optim(ini, loglik, escore, # hessian = T,
117 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
118
119 # opt <- optim(ini, loglik, escore,
120 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
121 # -9),
122 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
123 # .eps),
124 # # upper = rep(.Machine$double.xmax,(r+2))
125 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
126 # upper = rep(.Machine$double.xmax,(r+2))
127 # )
128
129 # opt <- optim(ini, loglik, escore)
130
131 # print(opt$par)
132
133 # print(names(opt))
134 # print(summary(opt) )
135 # print(summary(opt)[1:6] )
136 # print(opt$kkt1)
137
138 if (opt$conv != 0)
warning("FUNCTION DID NOT CONVERGE!")

```

```

139
140 k <- c()
141
142 # print("AQUI1")
143 # print(gradient(escore, opt$par))
144
145 coef <- c(lambda,p,opt$par)
146 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
147 # print(coef)
148 k$coef <- coef
149 k$conv <- opt$conv
150 k$loglik <- opt$value
151 k$counts <- as.numeric(opt$counts[1])
152
153 # library(rootSolve)
154 # library(numDeriv)
155 # escores<-rbind(
156 #   escore(coef),
157 #   gradient(loglik, coef),
158 #   grad(loglik, coef))
159 # print(round(escores,5))
160
161 # k$Knum<-gradient(escore, coef)
162
163 # print(k$Knum)
164 # k$Knum<-hessian(escore, coef, method="complex")
165 # print(k$Knum)
166
167
168 # # Expected information matrix
169 #
170 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
171 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
172 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
173 #
174 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
175 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
176 # delta <- log(0.5)/log(1-k$omega^k$phi)
177 #
178 # kapa<- 0.5772156649
179 # k0<- (pi^2)/6+kapa^2-2*kapa
180 #
181 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
182 #   log(1-y^k$phi)+1)
183 #
184 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
185 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))

```



```

185 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
186 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
187 #
188 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
189 #
190 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
191 #
192 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
193 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
194 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
195 # # k$phi^3))
196 # # si <- (1-k$lambda)*(b2) # ifelse(y==c,0,b2) #
197 #
198 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
199 # +1)-kapa)/((delta-1)*k$phi)) )
200 #
201 # L = diag(-1/(k$lambda*(1-k$lambda)))
202 # V = diag((k$lambda-1)*k$phi^2*h2)
203 # M = diag(mi)
204 # S = diag(si)
205 #
206 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
207 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
208 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
209 # Isb = t(Ibs)
210 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
211 #
212 # if(u!=0)
213 # {
214 #   k$pi <- as.vector(coef[(m+1):(m+u)])
215 #   eta_hat2 <- as.vector(w1%*%k$pi)
216 #   k$p <- as.vector(linkinv2(eta_hat2))
217 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
218 #   P = diag(-k$lambda/(k$p*(1-k$p)))
219 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
220 #
221 #   I <- rbind(
222 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
223 #       ncol=s)),
224 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
225 #       ncol=s)),
226 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
227 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
228 #   )

```

```

227 #
228 # }else{
229 # I <- rbind(
230 # cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
231 # cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
232 # cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
233 # )
234 # }
235 #
236 # k$I <- I
237 #
238 #
239 # #####
240 #
241 # # print(-k$Knum)
242 # # print(k$I)
243 #
244 # # vcov <- try(solve(-k$Knum))
245 # vcov <- try(solve(k$I))
246 # # vcov <- chol2inv(chol(k$I))
247 # #vcov <- K #somente para nao trancar simulacao
248 #
249 # k$cov_ok = 0
250 # if (class(vcov) == "try-error")
251 # {
252 #   vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
253 #     with inversion
254 #   k$cov_ok = 1
255 #   #
256 #   # if (class(vcov) == "try-error") #
257 #   # {
258 #     # vcov <- k$Knum^2
259 #     # warning("Problem with the variance and covariance matrix. The p-values
260 #       are not correct.")
261 #     # k$cov_ok = 2
262 #     # }
263 #   # }
264 #
265 # k$vcov <- vcov
266 # stderr <- sqrt(diag(k$vcov))
267 # k$stderr <- stderr
268
269 return(k)
270 }
271 ibetafit<-function(x)

```

```

272 {
273
274   n<- length(x) # sample size
275   n0<- sum(x==0) # number of zeros
276   n1<- sum(x==1) # number of ones
277   m<- n0 + n1
278
279   xm0<-x[which(x>0)]
280   x01<-xm0[which(xm0<1)]
281
282   #MV
283   loglik<-function(par)
284   {
285     alpha0<-par[1]
286     alpha1<-par[2]
287     gama<-par[3]
288     phi<-par[4]
289
290     alpha0 = ifelse(n0==0,0,alpha0)
291     alpha1 = ifelse(n1==0,0,alpha1)
292
293     #print(c(alpha0,alpha1,gama,phi))
294
295     c<- 1- alpha0*(1-gama)-alpha1*gama
296     mu<- gama*(1-alpha1)/c
297
298
299     l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
300     l1 = ifelse( (x == 1), log(alpha1*gama), 0)
301     l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
302     l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
      - mu) * phi, log = TRUE)))
303
304
305     #print("soma")
306     #print(sum(l0 + l1 + l2+ l3))
307     sum(l0 + l1 + l2+ l3)
308   }
309
310   escore<-function(par)
311   {
312     alpha0<-par[1]
313     alpha1<-par[2]
314     gama<-par[3]
315     phi<-par[4]
316
317     c<- 1- alpha0*(1-gama)-alpha1*gama

```

```

318 mu<- (gama*(1-alpha1))/c
319
320 a= mu * phi
321 b = a * (1 - mu)/mu
322
323 ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
324 mustar <- digamma(a) - digamma(b)
325
326
327
328 Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
329 #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
330 Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
      mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
331 Ualpha0 = sum(Ualpha01 + Ualpha03)
332
333 Ualpha0 = ifelse(n0==0,0,Ualpha0)
334
335
336 Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
337 #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
338 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
      gama*(1-gama)*(1-alpha0))/ (c^2) ) )
339 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01))-
      digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
340 Ualpha1 = sum(Ualpha11 - Ualpha13)
341
342 Ualpha1 = ifelse(n1==0,0,Ualpha1)
343
344 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
345 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
346 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
      mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
347
348 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
349
350 Uphio = ifelse( ((x == 0) | (x == 1)),0,
351 # (mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
352 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
353 )
354 Uphi = sum(Uphio)
355
356
357 c(Ualpha0,Ualpha1,Ugama,Uphi)
358 }
359

```

```

360 # metodo dos momentos para iniciarlizacao
361 x_bar<-mean(x01)
362 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
363
364 p<-x_bar*(((x_bar*(1-x_bar))/sigma2_hat)-1)
365 q<-(1-x_bar)*(((x_bar*(1-x_bar))/sigma2_hat)-1)
366
367 #print(c(x_bar,sigma2_hat,p,q))
368
369 delta0<- n0/n
370 delta1<- n1/n
371
372 a0<- delta0/(1-x_bar)
373 a1<- delta1/(x_bar)
374
375 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
376 par_ini<-c(a0,a1,p/(p+q),p+q)
377
378 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
379
380 #print("par_ini")
381 #print(par_ini)
382
383 max<-optim(par_ini,loglik,
384     escore,
385     method="BFGS",
386     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
387         (0.99999,0.99999,0.99999,9999999999),
388     control=list(fnscale=-1))
389
390 if(max$convergence != 0) print("Non-convergence")
391 # return
392 z<-c()
393 z$mv<-max$par
394 #print(z$mv)
395 z$conv<-max$convergence
396 z$loglik <- max$value
397 return(z)
398 }
399
400 iuGAfit <- function(y)
401 {
402
403     n <- length(y) # sample size
404     n0 <- sum(y == 0) # number of zeros

```

```

406 n1 <- sum(y == 1) # number of ones
407 m <- n0 + n1
408
409 ys01 <- y
410 if(any(y==0)) ys01<- ys01[-which(y==0)]
411 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
412
413 i01 <- (y==0)+(y==1)
414
415 #Maxima verossimilhanca
416
417 loglik <- function (par){
418
419   alpha0 <- par[1]
420   alpha1 <- par[2]
421   gama <- par[3]
422   phi <- par[4]
423
424   alpha0 = ifelse(n0 == 0, 0, alpha0)
425   alpha1 = ifelse(n1 == 0, 0, alpha1)
426
427   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
428   mu <- gama * (1 - alpha1) / c
429   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
430
431   l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
432   l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
433   l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
434   l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
435
436   #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
437
438   sum(l0 + l1 + l2 + l3)
439
440 }
441 escore <- function (par) {
442
443   alpha0 <- par[1]
444   alpha1 <- par[2]
445   gama <- par[3]
446   phi <- par[4]
447
448   alpha0 <- ifelse(n0 == 0, 0, alpha0)
449   alpha1 <- ifelse(n1 == 0, 0, alpha1)
450
451   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
452   mu <- gama * (1 - alpha1) / c

```

```

453 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
454 ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
455 mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
456
457
458 Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
459 Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
      / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
      ^ 2))
460 Ualpha0 <- sum(Ualpha01 + Ualpha03)
461
462 Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
463
464 Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
465 Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
      (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
      2))
466 Ualpha1 <- sum(Ualpha11 + Ualpha13)
467
468 Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
469
470
471 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
472 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
473 Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
      + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
      ^ 2))
474
475 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
476
477 Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
      / phi - ((d^2) * log(mu) * log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
      phi) - log(mu^(1/phi)))
478
479 Uphi = sum(Uphi0)
480
481
482 c(Ualpha0, Ualpha1, Ugama, Uphi)
483 }
484
485 #Inicializacao
486 y_bar <- mean(y)
487 y_bar0 <- mean(ys01)
488
489 delta0 <- n0/n
490 delta1 <- n1/n
491

```

```

492 a0 <- delta0/(1-y_bar)
493 a1 <- delta1/(y_bar)
494
495
496 #fit <- vglm(ys01 ~ 1, gamma2)
497 #par<-Coef(fit)
498
499 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
500 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
501 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
502 #phi_til = 5
503 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
504
505 par_ini <- c(a0, a1, y_bar, phi_til)
506
507
508 max<-optim(par_ini, loglik, escore,method = "BFGS",
509 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
510 (0.99999,0.99999,0.99999,9999999999),
511 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
512 (0.99999,0.99999,0.99999,9999999999),
513 control=list(fnscale=-1))
514
515 if(max$convergence != 0) print("Non-convergence")
516 # return
517 z <- c()
518 z$ini <- par_ini
519 z$mv <- max$par
520 z$conv <- max$convergence
521 z$loglik <- max$value
522 return(z)
523 }
524
525 n=200
526 #n=60
527 #n=100
528 #n=200
529 NR=10000
530 k=3 # numero de parametros
531
532 Cont_AIC_IB=rep(0,NR)
533 Cont_AIC_IK=rep(0,NR)
534 Cont_AIC_IUG=rep(0,NR)
535
536 Cont_AICC_IB=rep(0,NR)

```



```

537 Cont_AICC_IK=rep(0,NR)
538 Cont_AICC_IUG=rep(0,NR)
539
540 Cont_BIC_IB=rep(0,NR)
541 Cont_BIC_IK=rep(0,NR)
542 Cont_BIC_IUG=rep(0,NR)
543
544 Cont_BICC_IB=rep(0,NR)
545 Cont_BICC_IK=rep(0,NR)
546 Cont_BICC_IUG=rep(0,NR)
547
548 Cont_HQ_IB=rep(0,NR)
549 Cont_HQ_IK=rep(0,NR)
550 Cont_HQ_IUG=rep(0,NR)
551
552 Cont_HQC_IB=rep(0,NR)
553 Cont_HQC_IK=rep(0,NR)
554 Cont_HQC_IUG=rep(0,NR)
555
556 Cont_LL_IB =rep(0,NR)
557 Cont_LL_IK=rep(0,NR)
558 Cont_LL_IUG=rep(0,NR)
559
560 contC=0
561 contC1=0
562
563 prop.z = rep(0,NR)
564 prop.u = rep(0,NR)
565 var.am=rep(0,NR) #isaac
566
567 cvm.iBE = rep(0,NR)
568 ks.iBE = rep(0,NR)
569 ad.iBE = rep(0,NR)
570
571 cvm.iuGA = rep(0,NR)
572 ks.iuGA = rep(0,NR)
573 ad.iuGA = rep(0,NR)
574
575 cvm.ikum = rep(0,NR)
576 ks.ikum = rep(0,NR)
577 ad.ikum = rep(0,NR)
578
579 alpha0 = 0.05
580 alpha1 = 0
581 gama = 0.3
582 phi = 30
583

```

```

584 prob.0=alpha0*(1-gama) #(prob de zero)
585 prob.1=alpha1*gama #(prob de um)
586 prob.0
587 prob.1
588
589
590 lambda = prob.0+prob.1 #(prop.infl ou seja pro.0+prop.1)
591 lambda
592 p=(prob.1)/(lambda)
593 p
594
595 #lambda = alpha0
596 #(p=1 infl1 p=0 infla 0)
597 omega = gama
598 phi = phi
599
600 omega
601
602 valores.parametros = c(alpha0, alpha1, gama, phi)
603
604 prob.z = lambda*(1-p)
605 prob.o = lambda*p
606
607 prob.z # probabilidade de zero
608 prob.o #probabilidade de um
609
610 media.v = gama
611
612 bet=(log(0.5))/(log(1-omega^phi))
613 bet #expressao do paramentro beta
614
615 #var.v =lambda*p*(1-lambda*p)*bet*((beta(1+2/phi,bet))-(beta(1+1/phi,bet))*(2*
        lambda*p+bet*(1-lambda)*(beta(1+1/phi,bet))))
616
617
618 var.v =lambda*p*(1-lambda*p)+(1-lambda*p)*bet*((beta(1+2/phi,bet))-(beta(1+1/phi,
        bet))*(2*lambda*p+bet*(1-lambda)*(beta(1+1/phi,bet))))
619 #media.v
620 var.v
621
622 #Bayes - BEINF
623
624 c= 1- alpha0*(1-gama)-alpha1*gama
625 mu = gama*(1-alpha1)/c
626 delta0 = alpha0 * (1-gama)
627 delta1 = alpha1 * (gama)
628 p2= 1- delta0-delta1

```

```

629
630 mu
631 delta0
632 delta1
633 p2
634 dp = sqrt(1/(phi+1))
635
636
637 cont.ib = 0
638 cont.ik = 0
639 cont.igu = 0
640
641 for(i in 1:NR) {
642
643
644   y = rikum(n,lambda = lambda, p=p, omega = omega, phi = phi)
645   len = length(y)
646   prop.z[i] = sum(ifelse(y==0,1,0))/len
647   prop.u[i] = sum(ifelse(y==1,1,0))/len
648   var.am[i]=var(y) #isaac
649
650   fitib = ibetafit(y)
651   if (fitib$conv != 0)
652   {
653     cont.ib = cont.ib+1
654   }
655
656
657   fitik = ikumafit(y)
658   if (fitik$conv != 0)
659   {
660     cont.ik = cont.ik+1
661   }
662
663
664   fitigu = iuGAfit(y)
665
666
667   if ((fitigu$conv != 0) ){
668     cont.igu=cont.igu+1
669   }
670
671
672   ks.iBE[i] = ifelse(ks.test(y, "pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$p.value
673                     >0.05,1,0)
674
675   ad.iBE[i] = ifelse(ad.test(y, null="pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$p.

```

```

        value>0.05,1,0)
675
676 cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$
        p.value >0.05,1,0)
677
678
679 ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
        phi=phi)$p.value>0.05,1,0)
680
681 ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
682
683 cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
684
685
686 ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=lambda, p=0,omega=gama, phi=phi)$
        p.value>0.05,1,0)
687
688 ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=lambda, p=0,omega=gama, phi=
        phi)$p.value>0.05,1,0)
689
690 cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=lambda, p=0,omega=gama,
        phi=phi)$p.value>0.05,1,0)
691
692
693 #Log verossimilhanca
694 # Beta inflacionada
695 log.vero_IB = fitib$loglik
696 # Kuma inflacionada
697 log.vero_IK= fitik$loglik
698 # Gamma Unitaria inflacionada
699 log.vero_IUG = fitigu$loglik
700
701 m.log.vero_IB = -fitib$loglik
702 # Kuma inflacionada
703 m.log.vero_IK= -fitik$loglik
704 # Gamma Unitaria inflacionada
705 m.log.vero_IUG = -fitigu$loglik
706
707 #Menor -log verossimilhanca
708
709 min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
710
711 Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
712 Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
713 Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)

```

```

714
715 # Calculando os criterios/quantidades para comparacao
716
717 #criterio_AIC#
718 # Beta inflacionada
719 AIC_IB = -2*log.vero_IB+2*k
720 # Kuma inflacionada
721 AIC_IK= -2*log.vero_IK+2*k
722 # Gamma Unitaria inflacionada
723 AIC_IUG = -2*log.vero_IUG+2*k
724
725 # Seleccionando o menor AIC
726 min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
727
728 Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0)
729 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
730 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
731
732
733 # Beta inflacionada
734 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1)
735 # Kuma inflacionada
736 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1)
737 # Gamma Unitaria inflacionada
738 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1)
739
740 # Seleccionando o menor AICC
741 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
742
743 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0)
744 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
745 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)
746
747 #criterio_BIC#
748 # Beta inflacionada
749 BIC_IB=-2*log.vero_IB+k*log(n)
750 #Kuma inflacionada
751 BIC_IK=-2*log.vero_IK+k*log(n)
752 # Gamma Unitaria inflacionada
753 BIC_IUG=-2*fitigu$loglik+k*log(n)
754
755 # Seleccionando o menor BIC
756 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
757
758 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
759 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
760 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)

```

```

761
762 #criterio_BICC#
763 # Beta inflacionada
764 BICC_IB=-2*log.vero_IB+(k*log(n))/(n-k-1)
765 #Kuma inflacionada
766 BICC_IK=-2*log.vero_IK+(k*log(n))/(n-k-1)
767 # Gamma Unitaria inflacionada
768 BICC_IUG=-2*fitigu$loglik+(k*log(n))/(n-k-1)
769
770 # Seleccionando o menor BICC
771 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
772
773 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
774 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)
775 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
776
777 #criterio_HQ#
778 # Beta inflacionada
779 HQ_IB=-2*log.vero_IB+2*log(log(n))
780 #Kuma inflacionada
781 HQ_IK=-2*log.vero_IK+2*log(log(n))
782 # Gamma Unitaria inflacionada
783 HQ_IUG=-2*fitigu$loglik+2*log(log(n))
784
785 # Seleccionando o menor HQ
786 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
787
788 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
789 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
790 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)
791
792 #criterio_HQC#
793 # Beta inflacionada
794 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1)
795 #Kuma inflacionada
796 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1)
797 # Gamma Unitaria inflacionada
798 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1)
799
800 # Seleccionando o menor HQC
801 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
802
803 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
804 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)
805 Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
806 # FIM DO LACO DE MONTE CARLO
807 }

```

```

808
809 # Proporcao media de zeros
810 #mean(prop.z)
811 # Proporcao media de uns
812 #mean(prop.u)
813 var.amostrat=mean(var.am) #isaac
814
815 #Calculando percentuais escolha distribuicao(AIC)
816 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
817 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
818 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
819 p_AICIB
820 p_AICIK
821 p_AICIUG
822
823 #Calculando percentuais escolha distribuicao(AICC)
824 p_AICCIB<-((sum(Cont_AICC_IB))/NR)*100
825 p_AICCIK<-((sum(Cont_AICC_IK))/NR)*100
826 p_AICCIUG<-((sum(Cont_AICC_IUG))/NR)*100
827 p_AICCIB
828 p_AICCIK
829 p_AICCIUG
830
831 #Calculando percentuais escolha distribuicao(BIC)
832 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
833 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
834 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
835 p_BICIB
836 p_BICIK
837 p_BICIUG
838
839 #Calculando percentuais escolha distribuicao(BICC)
840 p_BICCIB<-((sum(Cont_BICC_IB))/NR)*100
841 p_BICCIK<-((sum(Cont_BICC_IK))/NR)*100
842 p_BICCIUG<-((sum(Cont_BICC_IUG))/NR)*100
843 p_BICCIB
844 p_BICCIK
845 p_BICCIUG
846
847 #Calculando percentuais escolha distribuicao(HQ)
848 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
849 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
850 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
851 p_HQIB
852 p_HQIK
853 p_HQIUG
854

```

```

855 #Calculando percentuais escolha distribuicao(HQC)
856 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
857 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
858 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
859 p_HQCIB
860 p_HQCIK
861 p_HQCIUG
862
863 #Calculando percentuais escolha distribuicao(-LL)
864 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
865 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
866 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100
867 p_LLIB
868 p_LLIK
869 p_LLIUG
870
871 #resultados -log.vero
872 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)
873 #Recebendo Resultados(AIC)
874 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
875 result_AIC
876 #Recebendo Resultados(AICC)
877 result_AICC=cbind(p_AICCIB,p_AICCIK,p_AICCIUG)
878 result_AICC
879 #Recebendo Resultados(BIC)
880 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
881 result_BIC
882 #Recebendo Resultados(BICC)
883 result_BICC=cbind(p_BICCIB,p_BICCIK,p_BICCIUG)
884 result_BICC
885 #Recebendo Resultados(HQ)
886 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
887 result_HQ
888 #Recebendo Resultados(HQC)
889 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
890 result_HQC
891
892 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100
893
894 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
895
896 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
897
898 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
899
900 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100
901

```



```

902 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
903
904 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
905
906 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
907
908 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
909
910 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
    rej.iuGA)
911
912 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.
    rej.iuGA)
913
914 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
    Nao.rej.iuGA)
915
916
917 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
    result_HQC,result.taxa.rej.ks,
918 result.taxa.rej.ad,result.taxa.rej.cvm)
919 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
920 rownames(M) <- c("-LogVero","AIC","AICC","BIC", "BICC","HQ","HQC", "Taxa.Nao.Rej.
    ks",
921 "Taxa.Nao.Rej.ad","Taxa.Nao.Rej.cvm")
922
923 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
    .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
924 "\n", "alpha.0: {alpha0}", "\n", "alpha.1: {alpha1}", "\n", "gama: {gama}", "\n", "
    phi: {phi}", "\n", "media: {media.v}",
925 "\n", "var: {round(var.v,4)}")
926 print("Resultados")
927 print(M)
928
929 var.amostral
930
931 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
    )
932 colnames(M.res) <- c("BIm.I","Kuma.I","GU.I")
933 rownames(M.res) <- c("criterios", "Taxa.Nao.Rej.ks","Taxa.Nao.Rej.ad","Taxa.Nao.
    Rej.cvm")
934 xtable(M.res)
935
936 #Salvando em um arquivo
937 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")

```

```

1 ##Simulacao gerando amostras a partir da kumaraswamy inflacionada em zero e um

```

```

      ##
2 library(gamlss)
3 library(gamlss.dist)
4 library(gamlss.data)
5 library(betareg)
6 library(MASS)
7 library(goftest)
8
9 source("ikumafit.R")
10 source("iuga_fitv4.R")
11 source("ibetafit.R")
12 source("iuga_v2.R")
13
14
15 set.seed(33) #Fixando a semente
16
17
18 source("ikum-omega-phi.R")
19 # library(optimx)
20 library(rootSolve)
21 library(VGAM)
22 library(xtable)
23 # library(fitdistrplus)
24
25 "ikumafit" <- function(y){
26
27   y <- as.vector(y)
28
29   n <- length(y)
30   n0<- sum(y==0) # number of zeros
31   n1<- sum(y==1) # number of ones
32
33   lambda <- (n0+n1)/n # lambda estimator
34   p <- n1/(n0+n1)# p estimator
35
36   u<-1
37   if(n0 == 0)
38   {
39     p=1
40     u=0
41   }
42
43   if(n1 == 0)
44   {
45     p=0
46     u=0
47   }

```

```

48
49 i01 <- (y==0)+(y==1)
50
51 loglik <- function(theta)
52 {
53   omega <- theta[1]
54   phi <- theta[2]
55
56   #####
57   l2 = 0
58   if(u!=0)
59   {
60     l2a = ifelse((y == 1), log(p), 0)
61     l2b = ifelse((y == 0), log(1-p), 0)
62     l2 = l2a + l2b
63   }
64
65   l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
66
67   l3 = ifelse((i01 == 1), 0,
68   log(phi)+
69   log(log(0.5)/log(1-omega^phi))+
70   (phi-1)*log(y)+
71   ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
72   )
73
74   sum(l1 + l2 + l3)
75 }
76
77 escore <- function(theta)
78 {
79   omega <- theta[1]
80   phi <- theta[2]
81
82   delta = log(0.5)/log(1-omega^phi)
83   ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
84   +1)
85
86   c = ifelse((y == 0), 0, ci)
87   c = ifelse((y == 1), 0, c)
88
89   Uomega <- phi*sum(c)
90
91   v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
92   (delta-1)*((y^phi)*log(y)/(1-y^phi)))
93   v = ifelse((y == 1), 0, v)

```

```

94     Uphi <- sum(v)
95
96     derivada=c(Uomega,Uphi)
97     derivada
98 }
99
100 ### initial values
101 ys01<- y
102 if(any(y==0)) ys01<- ys01[-which(y==0)]
103 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
104
105 # fit <- vglm(ys01 ~ 1, kumar)
106 # par<-Coef(fit)
107
108 phi <- 5 #par[1]
109 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
110
111 #print(c(lambda,p,omega,phi))
112 ini <- c(omega,phi)
113
114 #####
115
116 opt <- optim(ini, loglik, escore, # hessian = T,
117 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
118
119 # opt <- optim(ini, loglik, escore,
120 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
121 # -9),
122 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
123 # .eps),
124 # # upper = rep(.Machine$double.xmax,(r+2))
125 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
126 # upper = rep(.Machine$double.xmax,(r+2))
127 # )
128
129 # opt <- optim(ini, loglik, escore)
130
131 # print(opt$par)
132
133 # print(names(opt))
134 # print(summary(opt) )
135 # print(summary(opt)[1:6] )
136 # print(opt$kkt1)
137
138 if (opt$conv != 0)
warning("FUNCTION DID NOT CONVERGE!")

```

```

139
140 k <- c()
141
142 # print("AQUI1")
143 # print(gradient(escore, opt$par))
144
145 coef <- c(lambda,p,opt$par)
146 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
147 # print(coef)
148 k$coef <- coef
149 k$conv <- opt$conv
150 k$loglik <- opt$value
151 k$counts <- as.numeric(opt$counts[1])
152
153 # library(rootSolve)
154 # library(numDeriv)
155 # escores<-rbind(
156 #   escore(coef),
157 #   gradient(loglik, coef),
158 #   grad(loglik, coef))
159 # print(round(escores,5))
160
161 # k$Knum<-gradient(escore, coef)
162
163 # print(k$Knum)
164 # k$Knum<-hessian(escore, coef, method="complex")
165 # print(k$Knum)
166
167
168 # # Expected information matrix
169 #
170 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
171 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
172 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
173 #
174 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
175 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
176 # delta <- log(0.5)/log(1-k$omega^k$phi)
177 #
178 # kapa<- 0.5772156649
179 # k0<- (pi^2)/6+kapa^2-2*kapa
180 #
181 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
182 #   log(1-y^k$phi)+1)
183 #
184 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
185 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))

```

```

185 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
186 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
187 #
188 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
189 #
190 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
191 #
192 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
193 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
194 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
195 # # k$phi^3))
196 # # si <- (1-k$lambda)*(b2) # ifelse(y==c,0,b2) #
197 #
198 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
199 # # +1)-kapa)/((delta-1)*k$phi)) )
200 #
201 # L = diag(-1/(k$lambda*(1-k$lambda)))
202 # V = diag((k$lambda-1)*k$phi^2*h2)
203 # M = diag(mi)
204 # S = diag(si)
205 #
206 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
207 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
208 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
209 # Isb = t(Ibs)
210 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
211 #
212 # if(u!=0)
213 # {
214 #   k$pi <- as.vector(coef[(m+1):(m+u)])
215 #   eta_hat2 <- as.vector(w1%*%k$pi)
216 #   k$p <- as.vector(linkinv2(eta_hat2))
217 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
218 #   P = diag(-k$lambda/(k$p*(1-k$p)))
219 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
220 #
221 #   I <- rbind(
222 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
223 #       ncol=s)),
224 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
225 #       ncol=s)),
226 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
227 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
228 #   )

```

```

227 #
228 # }else{
229 # I <- rbind(
230 # cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
231 # cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
232 # cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
233 # )
234 # }
235 #
236 # k$I <- I
237 #
238 #
239 # #####
240 #
241 # # print(-k$Knum)
242 # # print(k$I)
243 #
244 # # vcov <- try(solve(-k$Knum))
245 # vcov <- try(solve(k$I))
246 # # vcov <- chol2inv(chol(k$I))
247 # #vcov <- K #somente para nao trancar simulacao
248 #
249 # k$cov_ok = 0
250 # if (class(vcov) == "try-error")
251 # {
252 #   vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
253 #   with inversion
254 #   k$cov_ok = 1
255 #   # if (class(vcov) == "try-error") #
256 #   # {
257 #   #   vcov <- k$Knum^2
258 #   #   warning("Problem with the variance and covariance matrix. The p-values
259 #   #   are not correct.")
260 #   #   k$cov_ok = 2
261 #   # }
262 #   # }
263 #
264 # k$vcov <- vcov
265 # stderr <- sqrt(diag(k$vcov))
266 # k$stderr <- stderr
267
268 return(k)
269 }
270
271 ibetafit<-function(x)

```

```

272 {
273
274   n<- length(x) # sample size
275   n0<- sum(x==0) # number of zeros
276   n1<- sum(x==1) # number of ones
277   m<- n0 + n1
278
279   xm0<-x[which(x>0)]
280   x01<-xm0[which(xm0<1)]
281
282   #MV
283   loglik<-function(par)
284   {
285     alpha0<-par[1]
286     alpha1<-par[2]
287     gama<-par[3]
288     phi<-par[4]
289
290     alpha0 = ifelse(n0==0,0,alpha0)
291     alpha1 = ifelse(n1==0,0,alpha1)
292
293     #print(c(alpha0,alpha1,gama,phi))
294
295     c<- 1- alpha0*(1-gama)-alpha1*gama
296     mu<- gama*(1-alpha1)/c
297
298
299     l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
300     l1 = ifelse( (x == 1), log(alpha1*gama), 0)
301     l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
302     l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
      - mu) * phi, log = TRUE)))
303
304
305     #print("soma")
306     #print(sum(l0 + l1 + l2+ l3))
307     sum(l0 + l1 + l2+ l3)
308   }
309
310   escore<-function(par)
311   {
312     alpha0<-par[1]
313     alpha1<-par[2]
314     gama<-par[3]
315     phi<-par[4]
316
317     c<- 1- alpha0*(1-gama)-alpha1*gama

```



```

318 mu<- (gama*(1-alpha1))/c
319
320 a= mu * phi
321 b = a * (1 - mu)/mu
322
323 ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
324 mustar <- digamma(a) - digamma(b)
325
326
327 Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
328 #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
329 Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
      mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
330 Ualpha0 = sum(Ualpha01 + Ualpha03)
331
332 Ualpha0 = ifelse(n0==0,0,Ualpha0)
333
334
335 Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
336 #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
337 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
      gama*(1-gama)*(1-alpha0))/ (c^2) ) )
338 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
      digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
339 Ualpha1 = sum(Ualpha11 - Ualpha13)
340
341 Ualpha1 = ifelse(n1==0,0,Ualpha1)
342
343 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
344 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
345 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
      mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
346
347 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
348
349 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
350 # (mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
351 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
352 )
353 Uphi = sum(Uphi0)
354
355
356 c(Ualpha0,Ualpha1,Ugama,Uphi)
357 }
358
359 # metodo dos momentos para iniciarlizacao

```

```

360 x_bar<-mean(x01)
361 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
362
363 p<-x_bar*(((x_bar*(1-x_bar))/sigma2_hat)-1)
364 q<-(1-x_bar)*(((x_bar*(1-x_bar))/sigma2_hat)-1)
365
366 #print(c(x_bar,sigma2_hat,p,q))
367
368 delta0<- n0/n
369 delta1<- n1/n
370
371 a0<- delta0/(1-x_bar)
372 a1<- delta1/(x_bar)
373
374 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
375 par_ini<-c(a0,a1,p/(p+q),p+q)
376
377 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
378
379 #print("par_ini")
380 #print(par_ini)
381
382 max<-optim(par_ini,loglik,
383           escore,
384           method="BFGS",
385           #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
386           (0.99999,0.99999,0.99999,9999999999),
387           control=list(fnscale=-1))
388
389 if(max$convergence != 0) print("Non-convergence")
390 # return
391 z<-c()
392 z$mv<-max$par
393 #print(z$mv)
394 z$conv<-max$convergence
395 z$loglik <- max$value
396 return(z)
397 }
398
399 iuGAfit <- function(y)
400 {
401   n <- length(y) # sample size
402   n0 <- sum(y == 0) # number of zeros
403   n1 <- sum(y == 1) # number of ones

```

```

406 m <- n0 + n1
407
408 ys01 <- y
409 if(any(y==0)) ys01<- ys01[-which(y==0)]
410 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
411
412 i01 <- (y==0)+(y==1)
413
414 #Maxima verossimilhanca
415
416 loglik <- function (par){
417
418   alpha0 <- par[1]
419   alpha1 <- par[2]
420   gama <- par[3]
421   phi <- par[4]
422
423   alpha0 = ifelse(n0 == 0, 0, alpha0)
424   alpha1 = ifelse(n1 == 0, 0, alpha1)
425
426   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
427   mu <- gama * (1 - alpha1) / c
428   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
429
430   l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
431   l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
432   l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
433   l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
434
435   #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
436
437   sum(l0 + l1 + l2 + l3)
438
439 }
440 escore <- function (par) {
441
442   alpha0 <- par[1]
443   alpha1 <- par[2]
444   gama <- par[3]
445   phi <- par[4]
446
447   alpha0 <- ifelse(n0 == 0, 0, alpha0)
448   alpha1 <- ifelse(n1 == 0, 0, alpha1)
449
450   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
451   mu <- gama * (1 - alpha1) / c
452   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))

```

```

453 ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
454 mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
455
456
457 Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
458 Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
      / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
      ^ 2))
459 Ualpha0 <- sum(Ualpha01 + Ualpha03)
460
461 Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
462
463 Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
464 Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
      (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
      2))
465 Ualpha1 <- sum(Ualpha11 + Ualpha13)
466
467 Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
468
469
470 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
471 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
472 Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
      + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
      ^ 2))
473
474 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
475
476 Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
      / phi - ((d^2) * log(mu) * log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
      phi) - log(mu^(1/phi)))
477
478 Uphi = sum(Uphi0)
479
480
481 c(Ualpha0, Ualpha1, Ugama, Uphi)
482 }
483
484
485 #Inicializacao
486
487 y_bar <- mean(y)
488 y_bar0 <- mean(ys01)
489
490 delta0 <- n0/n
491 delta1 <- n1/n

```

```

492
493 a0 <- delta0/(1-y_bar)
494 a1 <- delta1/(y_bar)
495
496
497 #fit <- vglm(ys01 ~ 1, gamma2)
498 #par<-Coef(fit)
499
500 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
501 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
502 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
503 #phi_til = 5
504 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
505
506 par_ini <- c(a0, a1, y_bar, phi_til)
507
508
509 max<-optim(par_ini, loglik, escore,method = "BFGS",
510 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
511         (0.99999,0.99999,0.99999,9999999999),
512 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
513         (0.99999,0.99999,0.99999,9999999999),
514 control=list(fnscale=-1))
515
516 if(max$convergence != 0) print("Non-convergence")
517 # return
518 z <- c()
519 z$ini <- par_ini
520 z$mv <- max$par
521 z$conv <- max$convergence
522 z$loglik <- max$value
523 return(z)
524 }
525
526 n=200
527 #n=60
528 #n=100
529 #n=200
530 NR=10000
531 k=4 # numero de parametros
532
533 Cont_AIC_IB=rep(0,NR)
534 Cont_AIC_IK=rep(0,NR)
535 Cont_AIC_IUG=rep(0,NR)
536
537 Cont_AICC_IB=rep(0,NR)

```

```

537 Cont_AICC_IK=rep(0,NR)
538 Cont_AICC_IUG=rep(0,NR)
539
540 Cont_BIC_IB=rep(0,NR)
541 Cont_BIC_IK=rep(0,NR)
542 Cont_BIC_IUG=rep(0,NR)
543
544 Cont_BICC_IB=rep(0,NR)
545 Cont_BICC_IK=rep(0,NR)
546 Cont_BICC_IUG=rep(0,NR)
547
548 Cont_HQ_IB=rep(0,NR)
549 Cont_HQ_IK=rep(0,NR)
550 Cont_HQ_IUG=rep(0,NR)
551
552 Cont_HQC_IB=rep(0,NR)
553 Cont_HQC_IK=rep(0,NR)
554 Cont_HQC_IUG=rep(0,NR)
555
556 Cont_LL_IB =rep(0,NR)
557 Cont_LL_IK=rep(0,NR)
558 Cont_LL_IUG=rep(0,NR)
559
560 contC=0
561 contC1=0
562
563 prop.z = rep(0,NR)
564 prop.u = rep(0,NR)
565 var.am=rep(0,NR) #isaac
566
567 cvm.iBE = rep(0,NR)
568 ks.iBE = rep(0,NR)
569 ad.iBE = rep(0,NR)
570
571 cvm.iuGA = rep(0,NR)
572 ks.iuGA = rep(0,NR)
573 ad.iuGA = rep(0,NR)
574
575 cvm.ikum = rep(0,NR)
576 ks.ikum = rep(0,NR)
577 ad.ikum = rep(0,NR)
578
579 #alpha0=P0/(1-gama) -> P0=P(y=0)
580 #alpha1=P1/(gama) -> P1=P(y=1)
581 #teste
582
583

```

```

584 alpha0 = 0.05
585 alpha1 = 0.05
586 gama = 0.7
587 phi = 50
588 alpha0
589 alpha1
590
591 prob.0=alpha0*(1-gama) #(prob de zero)
592 prob.1=alpha1*gama #(prob de um)
593 prob.0
594 prob.1
595
596
597 lambda = prob.0+prob.1 #(prop.infl ou seja pro.0+prop.1)
598 lambda
599 p=(prob.1)/(lambda)
600 p
601 #p = (alpha0*(1-gama))/gama #(p=1 infl1 p=0 infla 0)
602 omega = gama
603 phi = phi
604
605 lambda
606 p
607 omega
608 phi
609
610 omega
611
612 valores.parametros = c(alpha0, alpha1, gama, phi)
613
614 prob.z = lambda*(1-p)
615 prob.o = lambda*p
616
617 prob.z # probabilidade de zero
618 prob.o #probabilidade de um
619
620 media.v = gama
621
622 bet=(log(0.5))/(log(1-omega^phi))
623 bet #expressao do parametro beta
624
625 var.v =lambda*p*(1-lambda*p)+(1-lambda*p)*bet*((beta(1+2/phi,bet))-(beta(1+1/phi,
    bet))*(2*lambda*p+bet*(1-lambda)*beta(1+1/phi,bet))))
626 #media.v
627 var.v
628
629

```

```

630 c= 1- alpha0*(1-gama)-alpha1*gama
631 mu = gama*(1-alpha1)/c
632 delta0 = alpha0 * (1-gama)
633 delta1 = alpha1 * (gama)
634 p2= 1- delta0-delta1
635
636 mu
637 delta0
638 delta1
639 p2
640 dp = sqrt(1/(phi+1))
641
642 cont.ib = 0
643 cont.ik = 0
644 cont.igu = 0
645
646 for(i in 1:NR) {
647
648   y = rikum(n,lambda = lambda, p=p, omega = omega, phi = phi)
649   len = length(y)
650   prop.z[i] = sum(ifelse(y==0,1,0))/len
651   prop.u[i] = sum(ifelse(y==1,1,0))/len
652   var.am[i]=var(y) #isaac
653
654   fitib = ibetafit(y)
655   if (fitib$conv != 0)
656   {
657     cont.ib = cont.ib+1
658   }
659
660
661   fitik = ikumafit(y)
662   if (fitik$conv != 0)
663   {
664     cont.ik = cont.ik+1
665   }
666
667
668   fitigu = iuGAfit(y)
669
670
671   if ((fitigu$conv != 0) ){
672     cont.igu=cont.igu+1
673   }
674
675
676   ks.iBE[i] = ifelse(ks.test(y, "pBEINF",mu=mu , sigma=dp, nu=delta0/p2, tau=

```



```

        delta1/p2)$p.value>0.05,1,0)
677
678 ad.iBE[i] = ifelse(ad.test(y, null="pBEINF",mu=mu , sigma=dp, nu=delta0/p2, tau
        =delta1/p2)$p.value>0.05,1,0)
679
680 cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINF",mu=mu , sigma=dp, nu=delta0/p2,
        tau=delta1/p2)$p.value >0.05,1,0)
681
682
683 ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
        phi=phi)$p.value>0.05,1,0)
684
685 ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
686
687 cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
688
689
690 ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=lambda, p=p,omega=gama, phi=phi)$
        p.value>0.05,1,0)
691
692 ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=lambda, p=p,omega=gama, phi=
        phi)$p.value>0.05,1,0)
693
694 cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=lambda, p=p,omega=gama,
        phi=phi)$p.value>0.05,1,0)
695
696 #cvm.iuGA[i] = ifelse(cvm.test(y, "pgui",alpha0=fitigu$mv[1],alpha1=fitigu$mv
        [2],gama=fitigu$mv[3], phi=fitigu$mv[4])$p.value<0.05,1,0)
697 #cvm.ikum[i] = ifelse(cvm.test(y, "pikum",lambda=fitik$coef[1], p=fitik$coef
        [2],omega=fitik$coef[3], phi=fitik$coef[4])$p.value<0.05,1,0)
698
699 #Log verossimilhanca
700 # Beta inflacionada
701 log.vero_IB = fitib$loglik
702 # Kuma inflacionada
703 log.vero_IK= fitik$loglik
704 # Gamma Unitaria inflacionada
705 log.vero_IUG = fitigu$loglik
706
707 m.log.vero_IB = -fitib$loglik
708 # Kuma inflacionada
709 m.log.vero_IK= -fitik$loglik
710 # Gamma Unitaria inflacionada
711 m.log.vero_IUG = -fitigu$loglik
712

```

```

713 #Menor -log verossimilhanca
714
715 min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
716
717 Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
718 Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
719 Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)
720
721
722
723
724 # Calculando os criterios/quantidades para comparacao
725
726 #criteiro_AIC#
727 # Beta inflacionada
728 AIC_IB = -2*log.vero_IB+2*k
729 # Kuma inflacionada
730 AIC_IK= -2*log.vero_IK+2*k
731 # Gamma Unitaria inflacionada
732 AIC_IUG = -2*log.vero_IUG+2*k
733
734 # Selecionando o menor AIC
735 min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
736
737 Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0)
738 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
739 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
740
741
742 # Beta inflacionada
743 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1)
744 # Kuma inflacionada
745 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1)
746 # Gamma Unitaria inflacionada
747 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1)
748
749 # Selecionando o menor AICC
750 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
751
752 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0)
753 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
754 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)
755
756 #criterio_BIC#
757 # Beta inflacionada
758 BIC_IB=-2*log.vero_IB+k*log(n)
759 #Kuma inflacionada

```

```

760 BIC_IK=-2*log.vero_IK+k*log(n)
761 # Gamma Unitaria inflacionada
762 BIC_IUG=-2*fitigu$loglik+k*log(n)
763
764 # Seleccionando o menor BIC
765 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
766
767 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
768 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
769 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)
770
771 #criterio_BICC#
772 # Beta inflacionada
773 BICC_IB=-2*log.vero_IB+(k*log(n))/(n-k-1)
774 #Kuma inflacionada
775 BICC_IK=-2*log.vero_IK+(k*log(n))/(n-k-1)
776 # Gamma Unitaria inflacionada
777 BICC_IUG=-2*fitigu$loglik+(k*log(n))/(n-k-1)
778
779 # Seleccionando o menor BICC
780 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
781
782 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
783 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)
784 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
785
786 #criterio_HQ#
787 # Beta inflacionada
788 HQ_IB=-2*log.vero_IB+2*log(log(n))
789 #Kuma inflacionada
790 HQ_IK=-2*log.vero_IK+2*log(log(n))
791 # Gamma Unitaria inflacionada
792 HQ_IUG=-2*fitigu$loglik+2*log(log(n))
793
794 # Seleccionando o menor HQ
795 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
796
797 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
798 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
799 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)
800
801 #criterio_HQC#
802 # Beta inflacionada
803 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1)
804 #Kuma inflacionada
805 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1)
806 # Gamma Unitaria inflacionada

```

```

807 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1)
808
809 # Selecionando o menor HQC
810 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
811
812
813 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
814 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)
815 Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
816 # FIM DO LACO DE MONTE CARLO
817 }
818
819 # Proporcao media de zeros
820 #mean(prop.z)
821 # Proporcao media de uns
822 #mean(prop.u)
823 var.amostrat=mean(var.am) #isaac
824
825 #Calculando percentuais escolha distribuicao(AIC)
826 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
827 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
828 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
829 p_AICIB
830 p_AICIK
831 p_AICIUG
832
833 #Calculando percentuais escolha distribuicao(AICC)
834 p_AICCIB<-((sum(Cont_AICC_IB))/NR)*100
835 p_AICCIK<-((sum(Cont_AICC_IK))/NR)*100
836 p_AICCIUG<-((sum(Cont_AICC_IUG))/NR)*100
837 p_AICCIB
838 p_AICCIK
839 p_AICCIUG
840
841 #Calculando percentuais escolha distribuicao(BIC)
842 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
843 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
844 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
845 p_BICIB
846 p_BICIK
847 p_BICIUG
848
849 #Calculando percentuais escolha distribuicao(BICC)
850 p_BICCIB<-((sum(Cont_BICC_IB))/NR)*100
851 p_BICCIK<-((sum(Cont_BICC_IK))/NR)*100
852 p_BICCIUG<-((sum(Cont_BICC_IUG))/NR)*100
853 p_BICCIB

```

```

854 p_BICCIK
855 p_BICCIUG
856
857 #Calculando percentuais escolha distribuicao(HQ)
858 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
859 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
860 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
861 p_HQIB
862 p_HQIK
863 p_HQIUG
864
865 #Calculando percentuais escolha distribuicao(HQC)
866 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
867 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
868 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
869 p_HQCIB
870 p_HQCIK
871 p_HQCIUG
872
873 #Calculando percentuais escolha distribuicao(-LL)
874 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
875 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
876 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100
877 p_LLIB
878 p_LLIK
879 p_LLIUG
880
881 #resultados -log.vero
882 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)
883 #Recebendo Resultados(AIC)
884 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
885 result_AIC
886 #Recebendo Resultados(AICC)
887 result_AICC=cbind(p_AICIB,p_AICIK,p_AICIUG)
888 result_AICC
889 #Recebendo Resultados(BIC)
890 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
891 result_BIC
892 #Recebendo Resultados(BICC)
893 result_BICC=cbind(p_BICIB,p_BICIK,p_BICCIUG)
894 result_BICC
895 #Recebendo Resultados(HQ)
896 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
897 result_HQ
898 #Recebendo Resultados(HQC)
899 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
900 result_HQC

```

```

901
902 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100
903 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
904 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
905 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
906 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100
907 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
908 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
909 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
910 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
911 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
    rej.iuGA)
912 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.
    rej.iuGA)
913 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
    Nao.rej.iuGA)
914
915 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
    result_HQC,result.taxa.rej.ks,
916 result.taxa.rej.ad,result.taxa.rej.cvm)
917 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
918 rownames(M) <- c("-LogVero","AIC","AICC","BIC", "BICC","HQ","HQC", "Taxa.Nao.Rej.
    ks",
919 "Taxa.Nao.Rej.ad","Taxa.Nao.Rej.cvm")
920
921 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
    .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
922 "\n", "alpha.0: {alpha0}", "\n", "alpha.1: {alpha1}", "\n", "gama: {gama}", "\n", "
    phi: {phi}", "\n", "media: {media.v}",
923 "\n", "var: {round(var.v,4)}")
924 print("Resultados")
925 print(M)
926
927 var.amostral
928
929 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
    )
930 colnames(M.res) <- c("BIm.I","Kuma.I","GU.I")
931 rownames(M.res) <- c("criterios", "Taxa.Nao.Rej.ks","Taxa.Nao.Rej.ad","Taxa.Nao.
    Rej.cvm")
932 xtable(M.res)
933
934 #Salvando em um arquivo
935 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")

```

```

1  ##Simulacao gerando amostras a partir da kumaraswamy inflacionada em um##
2  library(gamlss)

```

```

3 library(gamlss.dist)
4 library(gamlss.data)
5 library(betareg)
6 library(MASS)
7 library(goftest)
8 source("ikumafit.R")
9 source("iuga_fitv4.R")
10 source("ibetafit.R")
11 source("iuga_v2.R")
12 set.seed(33) #Fixando a semente
13 source("ikum-omega-phi.R")
14 # library(optimx)
15 library(rootSolve)
16 library(VGAM)
17 library(xtable)
18 # library(fitdistrplus)
19
20 "ikumafit" <- function(y){
21
22   y <- as.vector(y)
23
24   n <- length(y)
25   n0<- sum(y==0) # number of zeros
26   n1<- sum(y==1) # number of ones
27
28   lambda <- (n0+n1)/n # lambda estimator
29   p <- n1/(n0+n1)# p estimator
30
31   u<-1
32   if(n0 == 0)
33   {
34     p=1
35     u=0
36   }
37
38   if(n1 == 0)
39   {
40     p=0
41     u=0
42   }
43
44   i01 <- (y==0)+(y==1)
45
46   loglik <- function(theta)
47   {
48     omega <- theta[1]
49     phi <- theta[2]

```

```

50
51 #####
52 l2 = 0
53 if(u!=0)
54 {
55     l2a = ifelse((y == 1), log(p), 0)
56     l2b = ifelse((y == 0), log(1-p), 0)
57     l2 = l2a + l2b
58 }
59
60 l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
61
62 l3 = ifelse((i01 == 1), 0,
63 log(phi)+
64 log(log(0.5)/log(1-omega^phi))+
65 (phi-1)*log(y)+
66 ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
67 )
68
69 sum(l1 + l2 + l3)
70 }
71
72 escore <- function(theta)
73 {
74     omega <- theta[1]
75     phi <- theta[2]
76
77     delta = log(0.5)/log(1-omega^phi)
78     ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
79         +1)
80
81     c = ifelse((y == 0), 0, ci)
82     c = ifelse((y == 1), 0, c)
83
84     Uomega <- phi*sum(c)
85
86     v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
87     (delta-1)*((y^phi)*log(y)/(1-y^phi)))
88     v = ifelse((y == 1), 0, v)
89
90     Uphi <- sum(v)
91
92     derivada=c(Uomega,Uphi)
93     derivada
94 }
95
96 ### initial values

```



```

96  ys01<- y
97  if(any(y==0)) ys01<- ys01[-which(y==0)]
98  if(any(y==1)) ys01<- ys01[-which(ys01==1)]
99
100 # fit <- vglm(ys01 ~ 1, kumar)
101 # par<-Coef(fit)
102
103 phi <- 5 #par[1]
104 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
105
106 #print(c(lambda,p,omega,phi))
107 ini <- c(omega,phi)
108
109 #####
110
111 opt <- optim(ini, loglik, escore, # hessian = T,
112 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
113
114 # opt <- optim(ini, loglik, escore,
115 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
116 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
117 # # upper = rep(.Machine$double.xmax,(r+2))
118 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
119 # upper = rep(.Machine$double.xmax,(r+2))
120 # )
121
122 # opt <- optim(ini, loglik, escore)
123
124 # print(opt$par)
125
126 # print(names(opt))
127 # print(summary(opt) )
128 # print(summary(opt)[1:6] )
129 # print(opt$kkt1)
130
131
132 if (opt$conv != 0)
133 warning("FUNCTION DID NOT CONVERGE!")
134
135 k <- c()
136
137 # print("AQUI1")
138 # print(gradient(escore, opt$par))
139
140 coef <- c(lambda,p,opt$par)

```

```

141 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
142 # print(coef)
143 k$coef <- coef
144 k$conv <- opt$conv
145 k$loglik <- opt$value
146 k$counts <- as.numeric(opt$counts[1])
147
148 # library(rootSolve)
149 # library(numDeriv)
150 # escores<-rbind(
151 #   escore(coef),
152 #   gradient(loglik, coef),
153 #   grad(loglik, coef))
154 # print(round(escores,5))
155
156 # k$Knum<-gradient(escore, coef)
157
158 # print(k$Knum)
159 # k$Knum<-hessian(escore, coef, method="complex")
160 # print(k$Knum)
161
162
163 # # Expected information matrix
164 #
165 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
166 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
167 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
168 #
169 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
170 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
171 # delta <- log(0.5)/log(1-k$omega^k$phi)
172 #
173 # kapa<- 0.5772156649
174 # k0<- (pi^2)/6+kapa^2-2*kapa
175 #
176 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
177 #   log(1-y^k$phi)+1)
178 #
179 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
180 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
181 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
182 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
183 #
184 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
185 #
186 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)

```

```

187 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
188 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
189 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
190 # # k$phi^3))
191 # # si <- (1-k$lambda)*(b2) # ifelse(y==c,0,b2) #
192 #
193 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
194 # +1)-kapa)/((delta-1)*k$phi)) )
195 #
196 # L = diag(-1/(k$lambda*(1-k$lambda)))
197 # V = diag((k$lambda-1)*k$phi^2*h2)
198 # M = diag(mi)
199 # S = diag(si)
200 #
201 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
202 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
203 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
204 # Isb = t(Ibs)
205 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
206 #
207 # if(u!=0)
208 # {
209 #   k$pi <- as.vector(coef[(m+1):(m+u)])
210 #   eta_hat2 <- as.vector(w1%*%k$pi)
211 #   k$p <- as.vector(linkinv2(eta_hat2))
212 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
213 #   P = diag(-k$lambda/(k$p*(1-k$p)))
214 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
215 #
216 #   I <- rbind(
217 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
218 #       ncol=s)),
219 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
220 #       ncol=s)),
221 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
222 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
223 #   )
224 # }else{
225 #   I <- rbind(
226 #     cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
227 #     cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
228 #     cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
229 #   )

```

```

229     # }
230     #
231     # k$I <- I
232     #
233     #
234     # #####
235     #
236     # # print(-k$Knum)
237     # # print(k$I)
238     #
239     # # vcov <- try(solve(-k$Knum))
240     # vcov <- try(solve(k$I))
241     # # vcov <- chol2inv(chol(k$I))
242     # #vcov <- K #somente para nao trancar simulacao
243     #
244     # k$cov_ok = 0
245     # if (class(vcov) == "try-error")
246     # {
247     #   # vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
248     #   #   with inversion
249     #   # k$cov_ok = 1
250     #   #
251     #   # if (class(vcov) == "try-error") #
252     #   # {
253     #   #   # vcov <- k$Knum^2
254     #   #   # warning("Problem with the variance and covariance matrix. The p-values
255     #   #   #     are not correct.")
256     #   #   # k$cov_ok = 2
257     #   #   # }
258     #   # }
259     #
260     # k$vcov <- vcov
261     # stderr <- sqrt(diag(k$vcov))
262     # k$stderr <- stderr
263
264     return(k)
265   }
266
267   ibetafit<-function(x)
268   {
269     n<- length(x) # sample size
270     n0<- sum(x==0) # number of zeros
271     n1<- sum(x==1) # number of ones
272     m<- n0 + n1
273

```

```

274 xm0<-x[which(x>0)]
275 x01<-xm0[which(xm0<1)]
276
277 #MV
278 loglik<-function(par)
279 {
280   alpha0<-par[1]
281   alpha1<-par[2]
282   gama<-par[3]
283   phi<-par[4]
284
285   alpha0 = ifelse(n0==0,0,alpha0)
286   alpha1 = ifelse(n1==0,0,alpha1)
287
288   #print(c(alpha0,alpha1,gama,phi))
289
290   c<- 1- alpha0*(1-gama)-alpha1*gama
291   mu<- gama*(1-alpha1)/c
292
293
294   l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
295   l1 = ifelse( (x == 1), log(alpha1*gama), 0)
296   l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
297   l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
      - mu) * phi, log = TRUE)))
298
299
300   #print("soma")
301   #print(sum(l0 + l1 + l2+ l3))
302   sum(l0 + l1 + l2+ l3)
303 }
304
305 escore<-function(par)
306 {
307   alpha0<-par[1]
308   alpha1<-par[2]
309   gama<-par[3]
310   phi<-par[4]
311
312   c<- 1- alpha0*(1-gama)-alpha1*gama
313   mu<- (gama*(1-alpha1))/c
314
315   a= mu * phi
316   b = a * (1 - mu)/mu
317
318   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
319   mustar <- digamma(a) - digamma(b)

```

```

320
321
322 Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
323 #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
324 Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
      mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
325 Ualpha0 = sum(Ualpha01 + Ualpha03)
326
327 Ualpha0 = ifelse(n0==0,0,Ualpha0)
328
329
330 Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
331 #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
332 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
      gama*(1-gama)*(1-alpha0))/ (c^2) ) )
333 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
      digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
334 Ualpha1 = sum(Ualpha11 - Ualpha13)
335
336 Ualpha1 = ifelse(n1==0,0,Ualpha1)
337
338 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
339 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
340 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
      mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
341
342 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
343
344 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
345 #((mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
346 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
347 )
348 Uphi = sum(Uphi0)
349
350
351 c(Ualpha0,Ualpha1,Ugama,Uphi)
352 }
353
354 # metodo dos momentos para iniciarlizacao
355 x_bar<-mean(x01)
356 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
357
358 p<-x_bar*(((x_bar*(1-x_bar))/sigma2_hat)-1)
359 q<-(1-x_bar)*(((x_bar*(1-x_bar))/sigma2_hat)-1)
360
361 #print(c(x_bar,sigma2_hat,p,q))

```

```

362
363 delta0<- n0/n
364 delta1<- n1/n
365
366 a0<- delta0/(1-x_bar)
367 a1<- delta1/(x_bar)
368
369 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
370 par_ini<-c(a0,a1,p/(p+q),p+q)
371
372 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
373
374 #print("par_ini")
375 #print(par_ini)
376
377 max<-optim(par_ini,loglik,
378     escore,
379     method="BFGS",
380     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
381         (0.99999,0.99999,0.99999,9999999999),
382     control=list(fnscale=-1))
383
384 if(max$convergence != 0) print("Non-convergence")
385 # return
386 z<-c()
387 z$mv<-max$par
388 #print(z$mv)
389 z$conv<-max$convergence
390 z$loglik <- max$value
391 return(z)
392 }
393
394 iuGAfit <- function(y)
395 {
396
397     n <- length(y) # sample size
398     n0 <- sum(y == 0) # number of zeros
399     n1 <- sum(y == 1) # number of ones
400     m <- n0 + n1
401
402     ys01 <- y
403     if(any(y==0)) ys01<- ys01[-which(y==0)]
404     if(any(y==1)) ys01<- ys01[-which(ys01==1)]
405
406     i01 <- (y==0)+(y==1)

```

```

408
409 #Maxima verossimilhanca
410
411 loglik <- function (par){
412
413   alpha0 <- par[1]
414   alpha1 <- par[2]
415   gama <- par[3]
416   phi <- par[4]
417
418   alpha0 = ifelse(n0 == 0, 0, alpha0)
419   alpha1 = ifelse(n1 == 0, 0, alpha1)
420
421   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
422   mu <- gama * (1 - alpha1) / c
423   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
424
425   l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
426   l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
427   l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
428   l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
429
430   #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
431
432   sum(l0 + l1 + l2 + l3)
433
434 }
435 escore <- function (par) {
436
437   alpha0 <- par[1]
438   alpha1 <- par[2]
439   gama <- par[3]
440   phi <- par[4]
441
442   alpha0 <- ifelse(n0 == 0, 0, alpha0)
443   alpha1 <- ifelse(n1 == 0, 0, alpha1)
444
445   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
446   mu <- gama * (1 - alpha1) / c
447   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
448   ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
449   mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
450
451
452   Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
453   Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
      / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / c

```



```

      ^ 2))
454 Ualpha0 <- sum(Ualpha01 + Ualpha03)
455
456 Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
457
458 Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
459 Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
      (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
      2))
460 Ualpha1 <- sum(Ualpha11 + Ualpha13)
461
462 Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
463
464
465 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
466 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
467 Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
      + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
      ^ 2))
468
469 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
470
471 Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
      /phi - ((d^2) *log(mu)* log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
      phi) - log(mu^(1/phi)))
472
473 Uphi = sum(Uphi0)
474
475
476 c(Ualpha0, Ualpha1, Ugama, Uphi)
477 }
478
479 #Inicializacao
480
481 y_bar <- mean(y)
482 y_bar0 <- mean(ys01)
483
484 delta0 <- n0/n
485 delta1 <- n1/n
486
487 a0 <- delta0/(1-y_bar)
488 a1 <- delta1/(y_bar)
489
490 #fit <- vglm(ys01 ~ 1, gamma2)
491 #par<-Coef(fit)
492
493 #mu <-(y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)

```

```

494 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
495 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
496 #phi_til = 5
497 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
498
499 par_ini <- c(a0, a1, y_bar, phi_til)
500
501 max<-optim(par_ini, loglik, escore,method = "BFGS",
502 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
503 (0.99999,0.99999,0.99999,9999999999),
504 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
505 (0.99999,0.99999,0.99999,9999999999),
506 control=list(fnscale=-1))
507
508 if(max$convergence != 0) print("Non-convergence")
509 # return
510 z <- c()
511 z$ini <- par_ini
512 z$mv <- max$par
513 z$conv <- max$convergence
514 z$loglik <- max$value
515 return(z)
516 }
517
518 n=30
519 #n=60
520 #n=100
521 #n=200
522 NR=10000
523 k=3 # numero de parametros
524
525 Cont_AIC_IB=rep(0,NR)
526 Cont_AIC_IK=rep(0,NR)
527 Cont_AIC_IUG=rep(0,NR)
528
529 Cont_AICC_IB=rep(0,NR)
530 Cont_AICC_IK=rep(0,NR)
531 Cont_AICC_IUG=rep(0,NR)
532
533 Cont_BIC_IB=rep(0,NR)
534 Cont_BIC_IK=rep(0,NR)
535 Cont_BIC_IUG=rep(0,NR)
536
537 Cont_BICC_IB=rep(0,NR)
538 Cont_BICC_IK=rep(0,NR)
539 Cont_BICC_IUG=rep(0,NR)

```

```

539
540 Cont_HQ_IB=rep(0,NR)
541 Cont_HQ_IK=rep(0,NR)
542 Cont_HQ_IUG=rep(0,NR)
543
544 Cont_HQC_IB=rep(0,NR)
545 Cont_HQC_IK=rep(0,NR)
546 Cont_HQC_IUG=rep(0,NR)
547
548 Cont_LL_IB =rep(0,NR)
549 Cont_LL_IK=rep(0,NR)
550 Cont_LL_IUG=rep(0,NR)
551
552 contC=0
553 contC1=0
554
555 prop.z = rep(0,NR)
556 prop.u = rep(0,NR)
557 var.am=rep(0,NR) #isaac
558
559 cvm.iBE = rep(0,NR)
560 ks.iBE = rep(0,NR)
561 ad.iBE = rep(0,NR)
562
563 cvm.iuGA = rep(0,NR)
564 ks.iuGA = rep(0,NR)
565 ad.iuGA = rep(0,NR)
566
567 cvm.ikum = rep(0,NR)
568 ks.ikum = rep(0,NR)
569 ad.ikum = rep(0,NR)
570
571 alpha0 = 0
572 alpha1 = 0.07
573 gama = 0.7
574 phi = 10
575
576 lambda = alpha1
577 p = 1 #(p=1 infl1 p=0 infla 0)
578 omega = gama
579 phi = phi
580
581 omega
582
583 valores.parametros = c(alpha0, alpha1, gama, phi)
584
585 prob.z = lambda*(1-p)

```

```

586 prob.o = lambda*p
587
588 prob.z # probabilidade de zero
589 prob.o #probabilidade de um
590
591 media.v = gama
592
593 bet=(log(0.5))/(log(1-omega^phi))
594 bet #expressao do paramentro beta
595
596 #var.v =lambda*p*(1-lambda*p)*bet*((beta(1+2/phi,bet))-(beta(1+1/phi,bet))*(2*
    lambda*p+bet*(1-lambda)*(beta(1+1/phi,bet))))
597
598 var.v =lambda*p*(1-lambda*p)+(1-lambda*p)*bet*((beta(1+2/phi,bet))-(beta(1+1/phi,
    bet))*(2*lambda*p+bet*(1-lambda)*(beta(1+1/phi,bet))))
599 #media.v
600 var.v
601
602 #Bayes - BEINF
603
604 c= 1- alpha0*(1-gama)-alpha1*gama
605 mu = gama*(1-alpha1)/c
606 delta0 = alpha0 * (1-gama)
607 delta1 = alpha1 * (gama)
608 p2= 1- delta0-delta1
609
610 mu
611 delta0
612 delta1
613 p2
614 dp = sqrt(1/(phi+1))
615
616
617 cont.ib = 0
618 cont.ik = 0
619 cont.igu = 0
620
621 for(i in 1:NR) {
622
623
624 y = rikum(n,lambda = lambda, p=p, omega = omega, phi = phi)
625 len = length(y)
626 prop.z[i] = sum(ifelse(y==0,1,0))/len
627 prop.u[i] = sum(ifelse(y==1,1,0))/len
628 var.am[i]=var(y) #isaac
629
630 fitib = ibetafit(y)

```

```

631 if (fitib$conv != 0)
632 {
633     cont.ib = cont.ib+1
634 }
635
636
637 fitik = ikumafit(y)
638 if (fitik$conv != 0)
639 {
640     cont.ik = cont.ik+1
641 }
642
643 fitigu = iuGAfit(y)
644
645
646 if ((fitigu$conv != 0) ){
647     cont.igu=cont.igu+1
648 }
649
650 ks.iBE[i] = ifelse(ks.test(y, "pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$p.value
651                    >0.05,1,0)
652
653 ad.iBE[i] = ifelse(ad.test(y, null="pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$p.
654                    value>0.05,1,0)
655
656 cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$
657                    p.value >0.05,1,0)
658
659 ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
660                             phi=phi)$p.value>0.05,1,0)
661
662 ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
663                             gama, phi=phi)$p.value>0.05,1,0)
664
665 cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
666                             gama, phi=phi)$p.value>0.05,1,0)
667
668 ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=alpha1, p=1,omega=gama, phi=phi)$
669                    p.value>0.05,1,0)
670
671 ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=alpha1, p=1,omega=gama, phi=
672                    phi)$p.value>0.05,1,0)
673
674 cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=alpha1, p=1,omega=gama,
675                    phi=phi)$p.value>0.05,1,0)

```

```

669
670 #Log verossimilhanca
671 # Beta inflacionada
672 log.vero_IB = fitib$loglik
673 # Kuma inflacionada
674 log.vero_IK= fitik$loglik
675 # Gamma Unitaria inflacionada
676 log.vero_IUG = fitigu$loglik
677
678 m.log.vero_IB = -fitib$loglik
679 # Kuma inflacionada
680 m.log.vero_IK= -fitik$loglik
681 # Gamma Unitaria inflacionada
682 m.log.vero_IUG = -fitigu$loglik
683
684 #Menor -log verossimilhanca
685
686 min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
687
688 Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
689 Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
690 Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)
691
692 # Calculando os criterios/quantidades para comparacao
693
694 #criteiro_AIC#
695 AIC_IB = -2*log.vero_IB+2*k #BI(Beta inflacionada)
696 AIC_IK= -2*log.vero_IK+2*k #KI(Kuma inflacionada)
697 AIC_IUG = -2*log.vero_IUG+2*k #GUI(Gamma Unitaria inflacionada)
698
699 # Selecionando o menor AIC
700 min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
701
702 Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0)
703 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
704 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
705
706 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1) #BI
707 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1) #KI
708 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1) #GUI
709
710 # Selecionando o menor AICC
711 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
712
713 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0)
714 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
715 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)

```

```

716
717 #criterio_BIC#
718 BIC_IB=-2*log.vero_IB+k*log(n) #BI
719 BIC_IK=-2*log.vero_IK+k*log(n) #KI
720 BIC_IUG=-2*fitigu$loglik+k*log(n) #GUI
721
722 # Seleccionando o menor BIC
723 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
724
725 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
726 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
727 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)
728
729 #criterio_BICC#
730 BICC_IB=-2*log.vero_IB+(k*log(n))/(n-k-1) #BI
731 BICC_IK=-2*log.vero_IK+(k*log(n))/(n-k-1) #KI
732 BICC_IUG=-2*fitigu$loglik+(k*log(n))/(n-k-1) #GUI
733
734 # Seleccionando o menor BICC
735 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
736
737 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
738 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)
739 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
740
741 #criterio_HQ#
742 HQ_IB=-2*log.vero_IB+2*log(log(n)) #BI
743 HQ_IK=-2*log.vero_IK+2*log(log(n)) #KI
744 HQ_IUG=-2*fitigu$loglik+2*log(log(n)) #GUI
745
746 # Seleccionando o menor HQ
747 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
748
749 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
750 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
751 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)
752
753 #criterio_HQC#
754 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1) #BI
755 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1) #KI
756 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1) #GUI
757
758 # Seleccionando o menor HQC
759 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
760
761 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
762 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)

```

```

763   Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
764   # FIM DO LACO DE MONTE CARLO
765 }
766
767 # Proporcao media de zeros
768 #mean(prop.z)
769 # Proporcao media de uns
770 #mean(prop.u)
771 var.amostrat=mean(var.am) #isaac
772
773 #Calculando percentuais escolha distribuicao(AIC)
774 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
775 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
776 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
777 p_AICIB
778 p_AICIK
779 p_AICIUG
780
781 #Calculando percentuais escolha distribuicao(AICC)
782 p_AICCIB<-((sum(Cont_AICC_IB))/NR)*100
783 p_AICCIK<-((sum(Cont_AICC_IK))/NR)*100
784 p_AICCIUG<-((sum(Cont_AICC_IUG))/NR)*100
785 p_AICCIB
786 p_AICCIK
787 p_AICCIUG
788
789 #Calculando percentuais escolha distribuicao(BIC)
790 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
791 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
792 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
793 p_BICIB
794 p_BICIK
795 p_BICIUG
796
797 #Calculando percentuais escolha distribuicao(BICC)
798 p_BICCIB<-((sum(Cont_BICC_IB))/NR)*100
799 p_BICCIK<-((sum(Cont_BICC_IK))/NR)*100
800 p_BICCIUG<-((sum(Cont_BICC_IUG))/NR)*100
801 p_BICCIB
802 p_BICCIK
803 p_BICCIUG
804
805 #Calculando percentuais escolha distribuicao(HQ)
806 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
807 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
808 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
809 p_HQIB

```



```

810 p_HQIK
811 p_HQIUG
812
813 #Calculando percentuais escolha distribuicao(HQC)
814 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
815 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
816 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
817 p_HQCIB
818 p_HQCIK
819 p_HQCIUG
820
821 #Calculando percentuais escolha distribuicao(-LL)
822 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
823 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
824 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100
825 p_LLIB
826 p_LLIK
827 p_LLIUG
828
829 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)
830 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
831 result_AIC
832 result_AICC=cbind(p_AICCIB,p_AICCIK,p_AICCIUG)
833 result_AICC
834 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
835 result_BIC
836 result_BICC=cbind(p_BICCIB,p_BICCIK,p_BICCIUG)
837 result_BICC
838 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
839 result_HQ
840 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
841 result_HQC
842
843 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100
844 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
845 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
846 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
847 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100
848 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
849 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
850 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
851 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
852
853 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
      rej.iuGA)
854
855 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.

```

```

      rej.iuGA)
856
857 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
      Nao.rej.iuGA)
858
859 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
      result_HQC,result.taxa.rej.ks,
860 result.taxa.rej.ad,result.taxa.rej.cvm)
861 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
862 rownames(M) <- c("-LogVero","AIC","AICC","BIC", "BICC","HQ","HQC", "Taxa.Nao.Rej.
      ks",
863 "Taxa.Nao.Rej.ad","Taxa.Nao.Rej.cvm")
864
865 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
      .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
866 "\n", "alpha.0: {alpha0}", "\n", "alpha.1: {alpha1}", "\n", "gama: {gama}", "\n", "
      phi: {phi}", "\n", "media: {media.v}",
867 "\n", "var: {round(var.v,4)}")
868 print("Resultados")
869 print(M)
870
871 var.amostral
872
873 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
      )
874 colnames(M.res) <- c("BIm.I","Kuma.I","GU.I")
875 rownames(M.res) <- c("criterios", "Taxa.Nao.Rej.ks","Taxa.Nao.Rej.ad","Taxa.Nao.
      Rej.cvm")
876 xtable(M.res)
877
878 #Salvando em um arquivo
879 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")

```

```

1  ##Simulacao gerando amostras a partir da gama unitaria inflacionada em zero##
2  library(gamlss)
3  library(gamlss.dist)
4  library(gamlss.data)
5  library(betareg)
6  library(MASS)
7  library(goftest)
8  source("ikumafit.R")
9  source("iuga_fitv4.R")
10 source("ibetafit.R")
11 source("iuga_v2.R")
12 set.seed(33) #Fixando a semente
13 source("ikum-omega-phi.R")
14 # library(optimx)

```

```

15 library(rootSolve)
16 library(VGAM)
17 library(xtable)
18 # library(fitdistrplus)
19
20 "ikumafit" <- function(y){
21
22   y <- as.vector(y)
23
24   n <- length(y)
25   n0<- sum(y==0) # number of zeros
26   n1<- sum(y==1) # number of ones
27
28   lambda <- (n0+n1)/n # lambda estimator
29   p <- n1/(n0+n1)# p estimator
30
31   u<-1
32   if(n0 == 0)
33   {
34     p=1
35     u=0
36   }
37
38   if(n1 == 0)
39   {
40     p=0
41     u=0
42   }
43
44   i01 <- (y==0)+(y==1)
45
46   loglik <- function(theta)
47   {
48     omega <- theta[1]
49     phi <- theta[2]
50
51     #####
52     l2 = 0
53     if(u!=0)
54     {
55       l2a = ifelse((y == 1), log(p), 0)
56       l2b = ifelse((y == 0), log(1-p), 0)
57       l2 = l2a + l2b
58     }
59
60     l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
61

```

```

62   l3 = ifelse((i01 == 1), 0,
63   log(phi)+
64   log(log(0.5)/log(1-omega^phi))+
65   (phi-1)*log(y)+
66   ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
67   )
68
69   sum(l1 + l2 + l3)
70 }
71
72 escore <- function(theta)
73 {
74   omega <- theta[1]
75   phi <- theta[2]
76
77   delta = log(0.5)/log(1-omega^phi)
78   ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
79         +1)
80
81   c = ifelse((y == 0), 0, ci)
82   c = ifelse((y == 1), 0, c)
83
84   Uomega <- phi*sum(c)
85
86   v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
87   (delta-1)*((y^phi)*log(y)/(1-y^phi)))
88   v = ifelse((y == 1), 0, v)
89
90   Uphi <- sum(v)
91
92   derivada=c(Uomega,Uphi)
93   derivada
94 }
95
96 ### initial values
97 ys01<- y
98 if(any(y==0)) ys01<- ys01[-which(y==0)]
99 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
100
101 # fit <- vglm(ys01 ~ 1, kumar)
102 # par<-Coef(fit)
103
104 phi <- 5 #par[1]
105 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
106
107 #print(c(lambda,p,omega,phi))
108 ini <- c(omega,phi)

```

```

108
109 #####
110
111 opt <- optim(ini, loglik, escore, # hessian = T,
112 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
113
114 # opt <- optim(ini, loglik, escore,
115 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
116 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
117 # # upper = rep(.Machine$double.xmax,(r+2))
118 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
119 # upper = rep(.Machine$double.xmax,(r+2))
120 # )
121
122 # opt <- optim(ini, loglik, escore)
123
124 # print(opt$par)
125
126 # print(names(opt))
127 # print(summary(opt) )
128 # print(summary(opt)[1:6] )
129 # print(opt$kkt1)
130
131
132 if (opt$conv != 0)
133 warning("FUNCTION DID NOT CONVERGE!")
134
135 k <- c()
136
137 # print("AQUI1")
138 # print(gradient(escore, opt$par))
139
140 coef <- c(lambda,p,opt$par)
141 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
142 # print(coef)
143 k$coef <- coef
144 k$conv <- opt$conv
145 k$loglik <- opt$value
146 k$counts <- as.numeric(opt$counts[1])
147
148 # library(rootSolve)
149 # library(numDeriv)
150 # escores<-rbind(
151 # escore(coef),
152 # gradient(loglik, coef),

```

```

153 # grad(loglik, coef))
154 # print(round(escores,5))
155
156 # k$Knum<-gradient(escore, coef)
157
158 # print(k$Knum)
159 # k$Knum<-hessian(escore, coef, method="complex")
160 # print(k$Knum)
161
162
163 # # Expected information matrix
164 #
165 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
166 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
167 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
168 #
169 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
170 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
171 # delta <- log(0.5)/log(1-k$omega^k$phi)
172 #
173 # kapa<- 0.5772156649
174 # k0<- (pi^2)/6+kapa^2-2*kapa
175 #
176 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
      log(1-y^k$phi)+1)
177 #
178 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
179 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
180 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
181 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
182 #
183 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
184 #
185 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
186 #
187 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
188 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
      phi)) -
189 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
      k$phi^3))
190 # #
191 # # si <- (1-k$lambda)*(b2) # ifelse(y=c,0,b2) #
192 #
193 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
      +1)-kapa)/((delta-1)*k$phi)) )
194 #
195 # L = diag(-1/(k$lambda*(1-k$lambda)))

```

```

196 # V = diag((k$lambda-1)*k$phi^2*h2)
197 # M = diag(mi)
198 # S = diag(si)
199 #
200 #
201 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
202 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
203 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
204 # Isb = t(Ibs)
205 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
206 #
207 # if(u!=0)
208 # {
209 #   k$pi <- as.vector(coef[(m+1):(m+u)])
210 #   eta_hat2 <- as.vector(w1%*%k$pi)
211 #   k$p <- as.vector(linkinv2(eta_hat2))
212 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
213 #   P = diag(-k$lambda/(k$p*(1-k$p)))
214 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
215 #
216 #   I <- rbind(
217 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
218 #       ncol=s)),
219 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
220 #       ncol=s)),
221 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
222 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
223 #   )
224 # }else{
225 #   I <- rbind(
226 #     cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
227 #     cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
228 #     cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
229 #   )
230 # }
231 # k$I <- I
232 #
233 #
234 # #####
235 #
236 # # print(-k$Knum)
237 # # print(k$I)
238 #
239 # # vcov <- try(solve(-k$Knum))
240 # vcov <- try(solve(k$I))

```

```

241 # # vcov <- chol2inv(chol(k$I))
242 # #vcov <- K #somente para nao trancar simulacao
243 #
244 # k$cov_ok = 0
245 # if (class(vcov) == "try-error")
246 # {
247   # vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
   # with inversion
248   # k$cov_ok = 1
249   #
250   # if (class(vcov) == "try-error") #
251   # {
252     # vcov <- k$Knum^2
253     # warning("Problem with the variance and covariance matrix. The p-values
   # are not correct.")
254     # k$cov_ok = 2
255     # }
256   # }
257
258
259 # k$vcov <- vcov
260 # stderr <- sqrt(diag(k$vcov))
261 # k$stderr <- stderr
262
263 return(k)
264 }
265
266 ibetafit<-function(x)
267 {
268
269   n<- length(x) # sample size
270   n0<- sum(x==0) # number of zeros
271   n1<- sum(x==1) # number of ones
272   m<- n0 + n1
273
274   xm0<-x[which(x>0)]
275   x01<-xm0[which(xm0<1)]
276
277   #MV
278   loglik<-function(par)
279   {
280     alpha0<-par[1]
281     alpha1<-par[2]
282     gama<-par[3]
283     phi<-par[4]
284
285     alpha0 = ifelse(n0==0,0,alpha0)

```



```

286 alpha1 = ifelse(n1==0,0,alpha1)
287
288 #print(c(alpha0,alpha1,gama,phi))
289
290 c<- 1- alpha0*(1-gama)-alpha1*gama
291 mu<- gama*(1-alpha1)/c
292
293
294 l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
295 l1 = ifelse( (x == 1), log(alpha1*gama), 0)
296 l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
297 l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
    - mu) * phi, log = TRUE)))
298
299
300 #print("soma")
301 #print(sum(l0 + l1 + l2+ l3))
302 sum(l0 + l1 + l2+ l3)
303 }
304
305 escore<-function(par)
306 {
307   alpha0<-par[1]
308   alpha1<-par[2]
309   gama<-par[3]
310   phi<-par[4]
311
312   c<- 1- alpha0*(1-gama)-alpha1*gama
313   mu<- (gama*(1-alpha1))/c
314
315   a= mu * phi
316   b = a * (1 - mu)/mu
317
318   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
319   mustar <- digamma(a) - digamma(b)
320
321   Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
322   #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
323   Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
    mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
324   Ualpha0 = sum(Ualpha01 + Ualpha03)
325
326   Ualpha0 = ifelse(n0==0,0,Ualpha0)
327
328
329   Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
330   #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)

```

```

331 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
      gama*(1-gama)*(1-alpha0))/ (c^2) ) )
332 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01))-
      digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
333 Ualpha1 = sum(Ualpha11 - Ualpha13)
334
335 Ualpha1 = ifelse(n1==0,0,Ualpha1)
336
337 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
338 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
339 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
      mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
340
341 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
342
343 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
344 #((mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
345 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
346 )
347 Uphi = sum(Uphi0)
348
349
350 c(Ualpha0,Ualpha1,Ugama,Uphi)
351 }
352
353 # metodo dos momentos para iniciarlizacao
354 x_bar<-mean(x01)
355 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
356
357 p<-x_bar*(((x_bar*(1-x_bar))/sigma2_hat)-1)
358 q<-(1-x_bar)*(((x_bar*(1-x_bar))/sigma2_hat)-1)
359
360 #print(c(x_bar,sigma2_hat,p,q))
361
362 delta0<- n0/n
363 delta1<- n1/n
364
365 a0<- delta0/(1-x_bar)
366 a1<- delta1/(x_bar)
367
368 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
369 par_ini<-c(a0,a1,p/(p+q),p+q)
370
371 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
372
373 #print("par_ini")

```

```

374 #print(par_ini)
375
376 max<-optim(par_ini,loglik,
377     escore,
378     method="BFGS",
379     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
        (0.99999,0.99999,0.99999,9999999999),
380     control=list(fnscale=-1))
381
382 if(max$convergence != 0) print("Non-convergence")
383 # return
384 z<-c()
385 z$mv<-max$par
386 #print(z$mv)
387 z$conv<-max$convergence
388 z$loglik <- max$value
389 return(z)
390 }
391
392 iuGAfit <- function(y)
393
394 {
395     n <- length(y) # sample size
396     n0 <- sum(y == 0) # number of zeros
397     n1 <- sum(y == 1) # number of ones
398     m <- n0 + n1
399
400     ys01 <- y
401     if(any(y==0)) ys01<- ys01[-which(y==0)]
402     if(any(y==1)) ys01<- ys01[-which(ys01==1)]
403
404     i01 <- (y==0)+(y==1)
405
406     #Maxima verossimilhanca
407
408     loglik <- function (par){
409
410         alpha0 <- par[1]
411         alpha1 <- par[2]
412         gama <- par[3]
413         phi <- par[4]
414
415         alpha0 = ifelse(n0 == 0, 0, alpha0)
416         alpha1 = ifelse(n1 == 0, 0, alpha1)
417
418         c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
419         mu <- gama * (1 - alpha1) / c

```

```

420 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
421
422 l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
423 l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
424 l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
425 l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
426
427 #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
428
429 sum(l0 + l1 + l2 + l3)
430
431 }
432 escore <- function (par) {
433
434   alpha0 <- par[1]
435   alpha1 <- par[2]
436   gama <- par[3]
437   phi <- par[4]
438
439   alpha0 <- ifelse(n0 == 0, 0, alpha0)
440   alpha1 <- ifelse(n1 == 0, 0, alpha1)
441
442   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
443   mu <- gama * (1 - alpha1) / c
444   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
445   ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
446   mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
447
448
449   Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
450   Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
      / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
      ^ 2))
451   Ualpha0 <- sum(Ualpha01 + Ualpha03)
452
453   Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
454
455   Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
456   Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
      (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
      2))
457   Ualpha1 <- sum(Ualpha11 + Ualpha13)
458
459   Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
460
461
462   Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)

```

```

463   Ugama02 <- ifelse((y == 1), 1 / gama, 0)
464   Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
      + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
      ^ 2))
465
466   Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
467
468   Uphio <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
      /phi - ((d^2) *log(mu)* log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
      phi) - log(mu^(1/phi)))
469
470   Uphi = sum(Uphio)
471
472
473   c(Ualpha0, Ualpha1, Ugama, Uphi)
474 }
475
476 #Inicializacao
477
478 y_bar <- mean(y)
479 y_bar0 <- mean(ys01)
480
481 delta0 <- n0/n
482 delta1 <- n1/n
483
484 a0 <- delta0/(1-y_bar)
485 a1 <- delta1/(y_bar)
486
487
488 #fit <- vglm(ys01 ~ 1, gamma2)
489 #par<-Coef(fit)
490
491 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
492 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
493 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
494 #phi_til = 5
495 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
496
497 par_ini <- c(a0, a1, y_bar, phi_til)
498
499
500 max<-optim(par_ini, loglik, escore,method = "BFGS",
501 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
502 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
503 control=list(fnscale=-1))

```

```

504
505   if(max$convergence != 0) print("Non-convergence")
506   # return
507   z <- c()
508   z$ini <- par_ini
509   z$mv <- max$par
510   z$conv <- max$convergence
511   z$loglik <- max$value
512   return(z)
513 }
514
515 n=30
516 #n=60
517 #n=100
518 #n=200
519 NR=10000
520 k=3 # numero de parametros
521
522 Cont_AIC_IB=rep(0,NR)
523 Cont_AIC_IK=rep(0,NR)
524 Cont_AIC_IUG=rep(0,NR)
525
526 Cont_AICC_IB=rep(0,NR)
527 Cont_AICC_IK=rep(0,NR)
528 Cont_AICC_IUG=rep(0,NR)
529
530 Cont_BIC_IB=rep(0,NR)
531 Cont_BIC_IK=rep(0,NR)
532 Cont_BIC_IUG=rep(0,NR)
533
534 Cont_BICC_IB=rep(0,NR)
535 Cont_BICC_IK=rep(0,NR)
536 Cont_BICC_IUG=rep(0,NR)
537
538 Cont_HQ_IB=rep(0,NR)
539 Cont_HQ_IK=rep(0,NR)
540 Cont_HQ_IUG=rep(0,NR)
541
542 Cont_HQC_IB=rep(0,NR)
543 Cont_HQC_IK=rep(0,NR)
544 Cont_HQC_IUG=rep(0,NR)
545
546 Cont_LL_IB =rep(0,NR)
547 Cont_LL_IK=rep(0,NR)
548 Cont_LL_IUG=rep(0,NR)
549
550 contC=0

```

```

551 contC1=0
552
553 prop.z = rep(0,NR)
554 prop.u = rep(0,NR)
555
556 cvm.iBE = rep(0,NR)
557 ks.iBE = rep(0,NR)
558 ad.iBE = rep(0,NR)
559
560 cvm.iuGA = rep(0,NR)
561 ks.iuGA = rep(0,NR)
562 ad.iuGA = rep(0,NR)
563
564 cvm.ikum = rep(0,NR)
565 ks.ikum = rep(0,NR)
566 ad.ikum = rep(0,NR)
567
568 alpha0 = 0.14
569 alpha1 = 0
570 gama = 0.5
571 phi = 50
572
573 prob.0=alpha0*(1-gama) #(prob de zero)
574 prob.1=alpha1*gama #(prob de um)
575 prob.0
576 prob.1
577
578 lambda = prob.0+prob.1 #(prop.infl ou seja pro.0+prop.1)
579 lambda
580 p=(prob.1)/(lambda)
581 p
582
583 valores.parametros = c(alpha0, alpha1, gama, phi)
584
585 prob.z = alpha0*(1-gama)
586 prob.o = alpha1*gama
587
588 prob.z # probabilidade de zero
589 prob.o #probabilidade de um
590
591 media.v = gama
592 var.v = alpha1*gama*(1-alpha1*gama)+gama*(1-alpha1)*((2-((gama*(1-alpha1))/(1-
    alpha0*(1-gama)-alpha1*gama))^(1/phi))^(-phi)-gama*(1+alpha1))
593
594 media.v
595 var.v
596

```

```

597 #Bayes - BEINF
598
599 c= 1- alpha0*(1-gama)-alpha1*gama
600 mu = gama*(1-alpha1)/c
601 delta0 = alpha0 * (1-gama)
602 delta1 = alpha1 * (gama)
603 p2= 1- delta0-delta1
604
605 mu
606 delta0
607 delta1
608 p2
609 dp = sqrt(1/(phi+1))
610
611
612 cont.ib = 0
613 cont.ik = 0
614 cont.igu = 0
615
616 for(i in 1:NR) {
617
618
619   y = riGU(n,alpha0 = alpha0, alpha1=alpha1, gama = gama, phi = phi)
620   len = length(y)
621   prop.z[i] = sum(ifelse(y==0,1,0))/len
622   prop.u[i] = sum(ifelse(y==1,1,0))/len
623
624
625   fitib = ibetafit(y)
626   if (fitib$conv != 0)
627   {
628     cont.ib = cont.ib+1
629   }
630
631
632   fitik = ikumafit(y)
633   if (fitik$conv != 0)
634   {
635     cont.ik = cont.ik+1
636   }
637
638   fitigu = iuGAfit(y)
639
640
641   if ((fitigu$conv != 0) ){
642     cont.igu=cont.igu+1
643   }

```



```

644
645
646 ks.iBE[i] = ifelse(ks.test(y, "pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$p.value
        >0.05,1,0)
647
648 ad.iBE[i] = ifelse(ad.test(y, null="pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$p.
        value>0.05,1,0)
649
650 cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINFO",mu=mu , sigma=dp, nu=delta0/p2)$
        p.value >0.05,1,0)
651
652 ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
        phi=phi)$p.value>0.05,1,0)
653
654 ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
655
656 cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
657
658 ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=lambda, p=p,omega=gama, phi=phi)$
        p.value>0.05,1,0)
659
660 ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=lambda, p=p,omega=gama, phi=
        phi)$p.value>0.05,1,0)
661
662 cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=lambda, p=p,omega=gama,
        phi=phi)$p.value>0.05,1,0)
663
664 #Log verossimilhanca
665 # Beta inflacionada
666 log.vero_IB = fitib$loglik
667 # Kuma inflacionada
668 log.vero_IK= fitik$loglik
669 # Gamma Unitaria inflacionada
670 log.vero_IUG = fitigu$loglik
671
672 m.log.vero_IB = -fitib$loglik
673 # Kuma inflacionada
674 m.log.vero_IK= -fitik$loglik
675 # Gamma Unitaria inflacionada
676 m.log.vero_IUG = -fitigu$loglik
677
678 #Menor -log verossimilhanca
679
680 min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
681

```

```

682 Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
683 Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
684 Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)
685
686 # Calculando os criterios/quantidades para comparacao
687
688 #criteiro_AIC#
689 AIC_IB = -2*log.vero_IB+2*k #BI(Beta inflacionada)
690 AIC_IK= -2*log.vero_IK+2*k #KI(Kuma inflacionada)
691 AIC_IUG = -2*log.vero_IUG+2*k #GUI(Gama Unitaria Inflacionada)
692
693 # Seleccionando o menor AIC
694 min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
695
696 Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0)
697 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
698 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
699
700 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1) #BI
701 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1) #KI
702 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1) #GUI
703
704 # Seleccionando o menor AICC
705 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
706
707 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0)
708 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
709 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)
710
711 #criterio_BIC#
712 BIC_IB=-2*log.vero_IB+k*log(n) #BI
713 BIC_IK=-2*log.vero_IK+k*log(n) #KI
714 BIC_IUG=-2*fitigu$loglik+k*log(n) #GUI
715
716 # Seleccionando o menor BIC
717 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
718
719 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
720 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
721 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)
722
723 #criterio_BICC#
724 BICC_IB=-2*log.vero_IB+(k*log(n))/(n-k-1) #BI
725 BICC_IK=-2*log.vero_IK+(k*log(n))/(n-k-1) #KI
726 BICC_IUG=-2*fitigu$loglik+(k*log(n))/(n-k-1) #GUI
727
728 # Seleccionando o menor BICC

```

```

729 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
730
731 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
732 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)
733 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
734
735 #criterio_HQ#
736 HQ_IB=-2*log.vero_IB+2*log(log(n)) #BI
737 HQ_IK=-2*log.vero_IK+2*log(log(n)) #KI
738 HQ_IUG=-2*fitigu$loglik+2*log(log(n)) #GUI
739
740 # Selecionando o menor HQ
741 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
742
743 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
744 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
745 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)
746
747 #criterio_HQC#
748 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1) #BI
749 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1) #KI
750 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1) #GUI
751
752 # Selecionando o menor HQC
753 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
754
755 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
756 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)
757 Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
758 # FIM DO LACO DE MONTE CARLO
759 }
760
761 # Proporcao media de zeros
762 #mean(prop.z)
763 # Proporcao media de uns
764 #mean(prop.u)
765
766 #Calculando percentuais escolha distribuicao(AIC)
767 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
768 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
769 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
770 p_AICIB
771 p_AICIK
772 p_AICIUG
773
774 #Calculando percentuais escolha distribuicao(AICC)
775 p_AICCIB<-((sum(Cont_AICC_IB))/NR)*100

```

```

776 p_AICCIK<-((sum(Cont_AICC_IK))/NR)*100
777 p_AICCIUG<-((sum(Cont_AICC_IUG))/NR)*100
778 p_AICCIB
779 p_AICCIK
780 p_AICCIUG
781
782 #Calculando percentuais escolha distribuicao(BIC)
783 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
784 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
785 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
786 p_BICIB
787 p_BICIK
788 p_BICIUG
789
790 #Calculando percentuais escolha distribuicao(BICC)
791 p_BICCIB<-((sum(Cont_BICC_IB))/NR)*100
792 p_BICCIK<-((sum(Cont_BICC_IK))/NR)*100
793 p_BICCIUG<-((sum(Cont_BICC_IUG))/NR)*100
794 p_BICCIB
795 p_BICCIK
796 p_BICCIUG
797
798 #Calculando percentuais escolha distribuicao(HQ)
799 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
800 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
801 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
802 p_HQIB
803 p_HQIK
804 p_HQIUG
805
806 #Calculando percentuais escolha distribuicao(HQC)
807 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
808 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
809 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
810 p_HQCIB
811 p_HQCIK
812 p_HQCIUG
813
814 #Calculando percentuais escolha distribuicao(-LL)
815 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
816 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
817 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100
818 p_LLIB
819 p_LLIK
820 p_LLIUG
821
822 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)

```

```

823 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
824 result_AIC
825 result_AICC=cbind(p_AICCIB,p_AICCIK,p_AICCIUG)
826 result_AICC
827 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
828 result_BIC
829 result_BICC=cbind(p_BICCIB,p_BICCIK,p_BICCIUG)
830 result_BICC
831 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
832 result_HQ
833 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
834 result_HQC
835
836 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100
837
838 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
839
840 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
841
842 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
843
844 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100
845
846 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
847
848 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
849
850 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
851
852 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
853
854 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
    rej.iuGA)
855
856 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.
    rej.iuGA)
857
858 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
    Nao.rej.iuGA)
859
860 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
    result_HQC,result.taxa.rej.ks,
861 result.taxa.rej.ad,result.taxa.rej.cvm)
862 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
863 rownames(M) <- c("-LogVero","AIC","AICC","BIC", "BICC","HQ","HQC", "Taxa.Nao.Rej.
    ks",
864 "Taxa.Nao.Rej.ad","Taxa.Nao.Rej.cvm")

```

```

865
866 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
      .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
867 "\n", "alpha.0: {alpha0}", "\n", "alpha.1: {alpha1}", "\n", "gama: {gama}", "\n", "
      phi: {phi}", "\n", "media: {media.v}",
868 "\n", "var: {round(var.v,4)}")
869 print("Resultados")
870 print(M)
871
872 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
      )
873 colnames(M.res) <- c("BIm.I","Kuma.I","GU.I")
874 rownames(M.res) <- c("criterios", "Taxa.Nao.Rej.ks","Taxa.Nao.Rej.ad","Taxa.Nao.
      Rej.cvm")
875 xtable(M.res)
876
877 #Salvando em um arquivo
878 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")

```

```

1  ##Simulacao gerando amostras a partir da gama unitaria inflacionada em zero e
      um##
2  library(gamlss)
3  library(gamlss.dist)
4  library(gamlss.data)
5  library(betareg)
6  library(MASS)
7  library(goftest)
8  source("ikumafit.R")
9  source("iuga_fitv4.R")
10 source("ibetafit.R")
11 source("iuga_v2.R")
12 set.seed(33) #Fixando a semente
13 source("ikum-omega-phi.R")
14 # library(optimx)
15 library(rootSolve)
16 library(VGAM)
17 library(xtable)
18 # library(fitdistrplus)
19
20 "ikumafit" <- function(y){
21
22   y <- as.vector(y)
23
24   n <- length(y)
25   n0<- sum(y==0) # number of zeros
26   n1<- sum(y==1) # number of ones
27

```

```

28 lambda <- (n0+n1)/n # lambda estimator
29 p <- n1/(n0+n1) # p estimator
30
31 u<-1
32 if(n0 == 0)
33 {
34   p=1
35   u=0
36 }
37
38 if(n1 == 0)
39 {
40   p=0
41   u=0
42 }
43
44 i01 <- (y==0)+(y==1)
45
46 loglik <- function(theta)
47 {
48   omega <- theta[1]
49   phi <- theta[2]
50
51   #####
52   l2 = 0
53   if(u!=0)
54   {
55     l2a = ifelse((y == 1), log(p), 0)
56     l2b = ifelse((y == 0), log(1-p), 0)
57     l2 = l2a + l2b
58   }
59
60   l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
61
62   l3 = ifelse((i01 == 1), 0,
63   log(phi)+
64   log(log(0.5)/log(1-omega^phi))+
65   (phi-1)*log(y)+
66   ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
67   )
68
69   sum(l1 + l2 + l3)
70 }
71
72 escore <- function(theta)
73 {
74   omega <- theta[1]

```

```

75 phi <- theta[2]
76
77 delta = log(0.5)/log(1-omega^phi)
78 ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
79      +1)
80
81 c = ifelse((y == 0), 0, ci)
82 c = ifelse((y == 1), 0, c)
83
84 Uomega <- phi*sum(c)
85
86 v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
87      (delta-1)*((y^phi)*log(y)/(1-y^phi)))
88 v = ifelse((y == 1), 0, v)
89
90 Uphi <- sum(v)
91
92 derivada=c(Uomega,Uphi)
93 }
94
95 ### initial values
96 ys01<- y
97 if(any(y==0)) ys01<- ys01[-which(y==0)]
98 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
99
100 # fit <- vglm(ys01 ~ 1, kumar)
101 # par<-Coef(fit)
102
103 phi <- 5 #par[1]
104 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
105
106 #print(c(lambda,p,omega,phi))
107 ini <- c(omega,phi)
108
109 #####
110
111 opt <- optim(ini, loglik, escore, # hessian = T,
112 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
113
114 # opt <- optim(ini, loglik, escore,
115 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
116 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
117 # # upper = rep(.Machine$double.xmax,(r+2))
118 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),

```



```

119 # upper = rep(.Machine$double.xmax,(r+2))
120 # )
121
122 # opt <- optim(ini, loglik, escore)
123
124 # print(opt$par)
125
126 # print(names(opt))
127 # print(summary(opt) )
128 # print(summary(opt)[1:6] )
129 # print(opt$kkt1)
130
131
132 if (opt$conv != 0)
133 warning("FUNCTION DID NOT CONVERGE!")
134
135 k <- c()
136
137 # print("AQUI1")
138 # print(gradient(escore, opt$par))
139
140 coef <- c(lambda,p,opt$par)
141 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
142 # print(coef)
143 k$coef <- coef
144 k$conv <- opt$conv
145 k$loglik <- opt$value
146 k$counts <- as.numeric(opt$counts[1])
147
148 # library(rootSolve)
149 # library(numDeriv)
150 # escores<-rbind(
151 #   escore(coef),
152 #   gradient(loglik, coef),
153 #   grad(loglik, coef))
154 # print(round(escores,5))
155
156 # k$Knum<-gradient(escore, coef)
157
158 # print(k$Knum)
159 # k$Knum<-hessian(escore, coef, method="complex")
160 # print(k$Knum)
161
162
163 # # Expected information matrix
164 #
165 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))

```

```

166 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
167 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
168 #
169 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
170 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
171 # delta <- log(0.5)/log(1-k$omega^k$phi)
172 #
173 # kapa<- 0.5772156649
174 # k0<- (pi^2)/6+kapa^2-2*kapa
175 #
176 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
      log(1-y^k$phi)+1)
177 #
178 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
179 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
180 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
181 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
182 #
183 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
184 #
185 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
186 #
187 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
188 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
      phi)) -
189 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
      k$phi^3))
190 # #
191 # # si <- (1-k$lambda)*(b2) # ifelse(y=c,0,b2) #
192 #
193 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
      +1)-kapa)/((delta-1)*k$phi)) )
194 #
195 # L = diag(-1/(k$lambda*(1-k$lambda)))
196 # V = diag((k$lambda-1)*k$phi^2*h2)
197 # M = diag(mi)
198 # S = diag(si)
199 #
200 #
201 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
202 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
203 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
204 # Isb = t(Ibs)
205 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
206 #
207 # if(u!=0)
208 # {

```

```

209 # k$pi <- as.vector(coef[(m+1):(m+u)])
210 # eta_hat2 <- as.vector(w1**k$pi)
211 # k$p <- as.vector(linkinv2(eta_hat2))
212 # T2 = diag(as.vector( 1/diflink2(k$p) ))
213 # P = diag(-k$lambda/(k$p*(1-k$p)))
214 # Ipp = -t(w1) **% P **% (T2^2) **% w1
215 #
216 # I <- rbind(
217 # cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
218 # ncol=s)),
219 # cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
220 # ncol=s)),
221 # cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
222 # cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
223 # )
224 # }else{
225 # I <- rbind(
226 # cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
227 # cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
228 # cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
229 # )
230 # }
231 # k$I <- I
232 #
233 #
234 # #####
235 #
236 # # print(-k$Knum)
237 # # print(k$I)
238 #
239 # # vcov <- try(solve(-k$Knum))
240 # vcov <- try(solve(k$I))
241 # # vcov <- chol2inv(chol(k$I))
242 # #vcov <- K #somente para nao trancar simulacao
243 #
244 # k$cov_ok = 0
245 # if (class(vcov) == "try-error")
246 # {
247 #   vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
248 #   with inversion
249 #   k$cov_ok = 1
250 #   #
251 #   if (class(vcov) == "try-error") #
252 #   {
253     # vcov <- k$Knum^2

```

```

253     # warning("Problem with the variance and covariance matrix. The p-values
      # are not correct.")
254     # k$cov_ok = 2
255     # }
256     # }
257
258
259     # k$vcov <- vcov
260     # stderror <- sqrt(diag(k$vcov))
261     # k$stderror <- stderror
262
263     return(k)
264 }
265
266 ibetafit<-function(x)
267 {
268
269     n<- length(x) # sample size
270     n0<- sum(x==0) # number of zeros
271     n1<- sum(x==1) # number of ones
272     m<- n0 + n1
273
274     xm0<-x[which(x>0)]
275     x01<-xm0[which(xm0<1)]
276
277     #MV
278     loglik<-function(par)
279     {
280         alpha0<-par[1]
281         alpha1<-par[2]
282         gama<-par[3]
283         phi<-par[4]
284
285         alpha0 = ifelse(n0==0,0,alpha0)
286         alpha1 = ifelse(n1==0,0,alpha1)
287
288         #print(c(alpha0,alpha1,gama,phi))
289
290         c<- 1- alpha0*(1-gama)-alpha1*gama
291         mu<- gama*(1-alpha1)/c
292
293
294         l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
295         l1 = ifelse( (x == 1), log(alpha1*gama), 0)
296         l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
297         l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
      - mu) * phi, log = TRUE)))

```

```

298
299
300 #print("soma")
301 #print(sum(l0 + l1 + l2+ l3))
302 sum(l0 + l1 + l2+ l3)
303 }
304
305 escore<-function(par)
306 {
307   alpha0<-par[1]
308   alpha1<-par[2]
309   gama<-par[3]
310   phi<-par[4]
311
312   c<- 1- alpha0*(1-gama)-alpha1*gama
313   mu<- (gama*(1-alpha1))/c
314
315   a= mu * phi
316   b = a * (1 - mu)/mu
317
318   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
319   mustar <- digamma(a) - digamma(b)
320
321   Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
322   #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
323   Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
324     mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
325   Ualpha0 = sum(Ualpha01 + Ualpha03)
326
327   Ualpha0 = ifelse(n0==0,0,Ualpha0)
328
329   Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
330   #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
331   Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
332     gama*(1-gama)*(1-alpha0))/ (c^2) ) )
333   #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
334     digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
335   Ualpha1 = sum(Ualpha11 - Ualpha13)
336
337   Ualpha1 = ifelse(n1==0,0,Ualpha1)
338
339   Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
340   Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
341   Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
342     mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
343
344   Ugama = sum(-Ugama01 + Ugama02 + Ugama04)

```

```

341
342 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
343 # (mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
344 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
345 )
346 Uphi = sum(Uphi0)
347
348
349 c(Ualpha0,Ualpha1,Ugama,Uphi)
350 }
351
352 # metodo dos momentos para iniciarlizacao
353 x_bar<-mean(x01)
354 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
355
356 p<-x_bar*((x_bar*(1-x_bar))/sigma2_hat)-1)
357 q<-(1-x_bar)*((x_bar*(1-x_bar))/sigma2_hat)-1)
358
359 #print(c(x_bar,sigma2_hat,p,q))
360
361 delta0<- n0/n
362 delta1<- n1/n
363
364 a0<- delta0/(1-x_bar)
365 a1<- delta1/(x_bar)
366
367 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
368 par_ini<-c(a0,a1,p/(p+q),p+q)
369
370 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
371
372 #print("par_ini")
373 #print(par_ini)
374
375 max<-optim(par_ini,loglik,
376     escore,
377     method="BFGS",
378     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
379     control=list(fnscale=-1))
380
381 if(max$convergence != 0) print("Non-convergence")
382 # return
383 z<-c()
384 z$mv<-max$par
385 #print(z$mv)

```

```

386   z$conv<-max$convergence
387   z$loglik <- max$value
388   return(z)
389 }
390
391 iuGAfit <- function(y)
392 {
393   {
394
395     n <- length(y) # sample size
396     n0 <- sum(y == 0) # number of zeros
397     n1 <- sum(y == 1) # number of ones
398     m <- n0 + n1
399
400     ys01 <- y
401     if(any(y==0)) ys01<- ys01[-which(y==0)]
402     if(any(y==1)) ys01<- ys01[-which(ys01==1)]
403
404     i01 <- (y==0)+(y==1)
405
406     #Maxima verossimilhanca
407
408     loglik <- function (par){
409
410       alpha0 <- par[1]
411       alpha1 <- par[2]
412       gama <- par[3]
413       phi <- par[4]
414
415       alpha0 = ifelse(n0 == 0, 0, alpha0)
416       alpha1 = ifelse(n1 == 0, 0, alpha1)
417
418       c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
419       mu <- gama * (1 - alpha1) / c
420       d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
421
422       l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
423       l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
424       l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
425       l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
426
427       #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
428
429       sum(l0 + l1 + l2 + l3)
430
431     }
432     escore <- function (par) {

```

```

433
434 alpha0 <- par[1]
435 alpha1 <- par[2]
436 gama <- par[3]
437 phi <- par[4]
438
439 alpha0 <- ifelse(n0 == 0, 0, alpha0)
440 alpha1 <- ifelse(n1 == 0, 0, alpha1)
441
442 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
443 mu <- gama * (1 - alpha1) / c
444 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
445 ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
446 mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
447
448 Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
449 Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d) /
  / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
    ^ 2))
450 Ualpha0 <- sum(Ualpha01 + Ualpha03)
451
452 Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
453
454 Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
455 Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
  (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
    2))
456 Ualpha1 <- sum(Ualpha11 + Ualpha13)
457
458 Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
459
460 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
461 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
462 Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
  + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
    ^ 2))
463
464 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
465
466 Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
  / phi - ((d^2) * log(mu) * log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
    phi) - log(mu^(1/phi)))
467
468 Uphi = sum(Uphi0)
469
470
471 c(Ualpha0, Ualpha1, Ugama, Uphi)

```



```

472 }
473
474 #Inicializacao
475
476 y_bar <- mean(y)
477 y_bar0 <- mean(ys01)
478
479 delta0 <- n0/n
480 delta1 <- n1/n
481
482 a0 <- delta0/(1-y_bar)
483 a1 <- delta1/(y_bar)
484
485 #fit <- vglm(ys01 ~ 1, gamma2)
486 #par<-Coef(fit)
487
488 #mu <-(y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
489 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
490 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
491 #phi_til = 5
492 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
493
494 par_ini <- c(a0, a1, y_bar, phi_til)
495
496 max<-optim(par_ini, loglik, escore,method = "BFGS",
497 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
498 (0.99999,0.99999,0.99999,9999999999),
499 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
500 (0.99999,0.99999,0.99999,9999999999),
501 control=list(fnscale=-1))
502
503 if(max$convergence != 0) print("Non-convergence")
504 # return
505 z <- c()
506 z$ini <- par_ini
507 z$mv <- max$par
508 z$conv <- max$convergence
509 z$loglik <- max$value
510 return(z)
511 }
512
513 n=100
514 #n=60
515 #n=100
516 #n=200
517 NR=10000
518 k=4 # numero de parametros

```

```

517
518 Cont_AIC_IB=rep(0,NR)
519 Cont_AIC_IK=rep(0,NR)
520 Cont_AIC_IUG=rep(0,NR)
521
522 Cont_AICC_IB=rep(0,NR)
523 Cont_AICC_IK=rep(0,NR)
524 Cont_AICC_IUG=rep(0,NR)
525
526 Cont_BIC_IB=rep(0,NR)
527 Cont_BIC_IK=rep(0,NR)
528 Cont_BIC_IUG=rep(0,NR)
529
530 Cont_BICC_IB=rep(0,NR)
531 Cont_BICC_IK=rep(0,NR)
532 Cont_BICC_IUG=rep(0,NR)
533
534 Cont_HQ_IB=rep(0,NR)
535 Cont_HQ_IK=rep(0,NR)
536 Cont_HQ_IUG=rep(0,NR)
537
538 Cont_HQC_IB=rep(0,NR)
539 Cont_HQC_IK=rep(0,NR)
540 Cont_HQC_IUG=rep(0,NR)
541
542 Cont_LL_IB =rep(0,NR)
543 Cont_LL_IK=rep(0,NR)
544 Cont_LL_IUG=rep(0,NR)
545
546 contC=0
547 contC1=0
548
549 prop.z = rep(0,NR)
550 prop.u = rep(0,NR)
551
552 cvm.iBE = rep(0,NR)
553 ks.iBE = rep(0,NR)
554 ad.iBE = rep(0,NR)
555
556 cvm.iuGA = rep(0,NR)
557 ks.iuGA = rep(0,NR)
558 ad.iuGA = rep(0,NR)
559
560 cvm.ikum = rep(0,NR)
561 ks.ikum = rep(0,NR)
562 ad.ikum = rep(0,NR)
563

```

```

564 alpha0 = 0.1
565 alpha1 = 0.1
566 gama = 0.8
567 phi = 50
568
569 prob.0=alpha0*(1-gama) #(prob de zero)
570 prob.1=alpha1*gama #(prob de um)
571 prob.0
572 prob.1
573
574 lambda = prob.0+prob.1 #(prop.infl ou seja pro.0+prop.1)
575 lambda
576 p=(prob.1)/(lambda)
577 p
578 #p = (alpha0*(1-gama))/gama #(p=1 infl1 p=0 infla 0)
579 omega = gama
580 phi = phi
581
582 valores.parametros = c(alpha0, alpha1, gama, phi)
583
584 prob.z = alpha0*(1-gama)
585 prob.o = alpha1*gama
586
587 prob.z # probabilidade de zero
588 prob.o #probabilidade de um
589
590 media.v = gama
591 var.v = alpha1*gama*(1-alpha1*gama)+gama*(1-alpha1)*((2-((gama*(1-alpha1))/(1-
    alpha0*(1-gama)-alpha1*gama))^(1/phi)))^(-phi)-gama*(1+alpha1))
592
593 media.v
594 var.v
595
596 #Bayes - BEINF
597
598 c= 1- alpha0*(1-gama)-alpha1*gama
599 mu = gama*(1-alpha1)/c
600 delta0 = alpha0 * (1-gama)
601 delta1 = alpha1 * (gama)
602 p2= 1- delta0-delta1
603
604 mu
605 delta0
606 delta1
607 p2
608 dp = sqrt(1/(phi+1))
609

```

```

610 cont.ib = 0
611 cont.ik = 0
612 cont.igu = 0
613
614 for(i in 1:NR) {
615
616   y = riGU(n,alpha0 = alpha0, alpha1=alpha1, gama = gama, phi = phi)
617   len = length(y)
618   prop.z[i] = sum(ifelse(y==0,1,0))/len
619   prop.u[i] = sum(ifelse(y==1,1,0))/len
620
621   fitib = ibetafit(y)
622   if (fitib$conv != 0)
623   {
624     cont.ib = cont.ib+1
625   }
626
627   fitik = ikumafit(y)
628   if (fitik$conv != 0)
629   {
630     cont.ik = cont.ik+1
631   }
632
633   fitigu = iuGAfit(y)
634
635   if ((fitigu$conv != 0) ){
636     cont.igu=cont.igu+1
637   }
638
639   ks.iBE[i] = ifelse(ks.test(y, "pBEINF",mu=mu , sigma=dp, nu=delta0/p2, tau=
        delta1/p2)$p.value>0.05,1,0)
640
641   ad.iBE[i] = ifelse(ad.test(y, null="pBEINF",mu=mu , sigma=dp, nu=delta0/p2, tau
        =delta1/p2)$p.value>0.05,1,0)
642
643   cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINF",mu=mu , sigma=dp, nu=delta0/p2,
        tau=delta1/p2)$p.value >0.05,1,0)
644
645
646   ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
        phi=phi)$p.value>0.05,1,0)
647
648   ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)
649
650   cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
        gama, phi=phi)$p.value>0.05,1,0)

```

```

651
652
653 ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=lambda, p=p,omega=gama, phi=phi)$
    p.value>0.05,1,0)
654
655 ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=lambda, p=p,omega=gama, phi=
    phi)$p.value>0.05,1,0)
656
657 cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=lambda, p=p,omega=gama,
    phi=phi)$p.value>0.05,1,0)
658
659 #Log verossimilhanca
660 # Beta inflacionada
661 log.vero_IB = fitib$loglik
662 # Kuma inflacionada
663 log.vero_IK= fitik$loglik
664 # Gamma Unitaria inflacionada
665 log.vero_IUG = fitigu$loglik
666
667 m.log.vero_IB = -fitib$loglik
668 # Kuma inflacionada
669 m.log.vero_IK= -fitik$loglik
670 # Gamma Unitaria inflacionada
671 m.log.vero_IUG = -fitigu$loglik
672
673 #Menor -log verossimilhanca
674
675 min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
676
677 Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
678 Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
679 Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)
680
681 # Calculando os criterios/quantidades para comparacao
682
683 #criteiro_AIC#
684 AIC_IB = -2*log.vero_IB+2*k #BI(Beta inflacionada)
685 AIC_IK= -2*log.vero_IK+2*k #KI(Kuma inflacionada)
686 AIC_IUG = -2*log.vero_IUG+2*k #GUI(Gamma Unitaria inflacionada)
687
688 # Seleccionando o menor AIC
689 min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
690
691 Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0)
692 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
693 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
694

```

```

695 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1) #BI
696 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1) #KI
697 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1) #GUI
698
699 # Seleccionando o menor AICC
700 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
701
702 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0)
703 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
704 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)
705
706 #criterio_BIC#
707 BIC_IB=-2*log.vero_IB+k*log(n) #BI
708 BIC_IK=-2*log.vero_IK+k*log(n) #KI
709 BIC_IUG=-2*fitigu$loglik+k*log(n) #GUI
710
711 # Seleccionando o menor BIC
712 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
713
714 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
715 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
716 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)
717
718 #criterio_BICC#
719 BICC_IB=-2*log.vero_IB+(k*log(n))/(n-k-1) #BI
720 BICC_IK=-2*log.vero_IK+(k*log(n))/(n-k-1) #KI
721 BICC_IUG=-2*fitigu$loglik+(k*log(n))/(n-k-1) #GUI
722
723 # Seleccionando o menor BICC
724 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
725
726 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
727 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)
728 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
729
730 #criterio_HQ#
731 HQ_IB=-2*log.vero_IB+2*log(log(n)) #BI
732 HQ_IK=-2*log.vero_IK+2*log(log(n)) #KI
733 HQ_IUG=-2*fitigu$loglik+2*log(log(n)) #GUI
734
735 # Seleccionando o menor HQ
736 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
737
738 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
739 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
740 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)
741

```

```

742 #criterio_HQC#
743 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1) #BI
744 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1) #KI
745 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1) #GUI
746
747 # Selecionando o menor HQC
748 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
749
750 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
751 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)
752 Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
753 # FIM DO LACO DE MONTE CARLO
754 }
755
756 # Proporcao media de zeros
757 #mean(prop.z)
758 # Proporcao media de uns
759 #mean(prop.u)
760
761 #Calculando percentuais escolha distribuicao(AIC)
762 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
763 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
764 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
765 p_AICIB
766 p_AICIK
767 p_AICIUG
768
769 #Calculando percentuais escolha distribuicao(AICC)
770 p_AICCBIB<-((sum(Cont_AICC_IB))/NR)*100
771 p_AICCBIK<-((sum(Cont_AICC_IK))/NR)*100
772 p_AICCCIUG<-((sum(Cont_AICC_IUG))/NR)*100
773 p_AICCBIB
774 p_AICCBIK
775 p_AICCCIUG
776
777 #Calculando percentuais escolha distribuicao(BIC)
778 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
779 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
780 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
781 p_BICIB
782 p_BICIK
783 p_BICIUG
784
785 #Calculando percentuais escolha distribuicao(BICC)
786 p_BICCBIB<-((sum(Cont_BICC_IB))/NR)*100
787 p_BICCBIK<-((sum(Cont_BICC_IK))/NR)*100
788 p_BICCCIUG<-((sum(Cont_BICC_IUG))/NR)*100

```

```

789 p_BICCIB
790 p_BICCIK
791 p_BICCIUG
792
793 #Calculando percentuais escolha distribuicao(HQ)
794 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
795 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
796 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
797 p_HQIB
798 p_HQIK
799 p_HQIUG
800
801 #Calculando percentuais escolha distribuicao(HQC)
802 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
803 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
804 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
805 p_HQCIB
806 p_HQCIK
807 p_HQCIUG
808
809 #Calculando percentuais escolha distribuicao(-LL)
810 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
811 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
812 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100
813 p_LLIB
814 p_LLIK
815 p_LLIUG
816
817 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)
818 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
819 result_AIC
820 result_AICC=cbind(p_AICCIB,p_AICCIK,p_AICCIUG)
821 result_AICC
822 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
823 result_BIC
824 result_BICC=cbind(p_BICCIB,p_BICCIK,p_BICCIUG)
825 result_BICC
826 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
827 result_HQ
828 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
829 result_HQC
830
831 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100
832 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
833 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
834 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
835 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100

```



```

836 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
837 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
838 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
839 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
840
841 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
    rej.iuGA)
842
843 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.
    rej.iuGA)
844
845 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
    Nao.rej.iuGA)
846
847
848 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
    result_HQC,result.taxa.rej.ks,
849 result.taxa.rej.ad,result.taxa.rej.cvm)
850 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
851 rownames(M) <- c("-LogVero","AIC","AICC","BIC","BICC","HQ","HQC","Taxa.Nao.Rej.
    ks",
852 "Taxa.Nao.Rej.ad","Taxa.Nao.Rej.cvm")
853
854 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
    .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
855 "\n", "alpha.0: {alpha0}", "\n", "alpha.1: {alpha1}", "\n", "gama: {gama}", "\n", "
    phi: {phi}", "\n", "media: {media.v}",
856 "\n", "var: {round(var.v,4)}")
857 print("Resultados")
858 print(M)
859
860 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
    )
861 colnames(M.res) <- c("BIm.I","Kuma.I","GU.I")
862 rownames(M.res) <- c("criterios", "Taxa.Nao.Rej.ks","Taxa.Nao.Rej.ad","Taxa.Nao.
    Rej.cvm")
863 xtable(M.res)
864
865 #Salvando em um arquivo
866 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")

```

```

1  ##Simulacao gerando amostras a partir da gama unitaria inflacionada em um##
2  library(gamlss)
3  library(gamlss.dist)
4  library(gamlss.data)
5  library(betareg)
6  library(MASS)

```

```

7 library(goftest)
8 source("ikumafit.R")
9 source("iuga_fitv4.R")
10 source("ibetafit.R")
11 source("iuga_v2.R")
12 set.seed(33) #Fixando a semente
13 source("ikum-omega-phi.R")
14 # library(optimx)
15 library(rootSolve)
16 library(VGAM)
17 library(xtable)
18 # library(fitdistrplus)
19
20 "ikumafit" <- function(y){
21
22   y <- as.vector(y)
23
24   n <- length(y)
25   n0<- sum(y==0) # number of zeros
26   n1<- sum(y==1) # number of ones
27
28   lambda <- (n0+n1)/n # lambda estimator
29   p <- n1/(n0+n1)# p estimator
30
31   u<-1
32   if(n0 == 0)
33   {
34     p=1
35     u=0
36   }
37
38   if(n1 == 0)
39   {
40     p=0
41     u=0
42   }
43
44   i01 <- (y==0)+(y==1)
45
46   loglik <- function(theta)
47   {
48     omega <- theta[1]
49     phi <- theta[2]
50
51     #####
52     l2 = 0
53     if(u!=0)

```

```

54 {
55   l2a = ifelse((y == 1), log(p), 0)
56   l2b = ifelse((y == 0), log(1-p), 0)
57   l2 = l2a + l2b
58 }
59
60 l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
61
62 l3 = ifelse((i01 == 1), 0,
63   log(phi)+
64   log(log(0.5)/log(1-omega^phi))+
65   (phi-1)*log(y)+
66   ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
67 )
68
69 sum(l1 + l2 + l3)
70 }
71
72 escore <- function(theta)
73 {
74   omega <- theta[1]
75   phi <- theta[2]
76
77   delta = log(0.5)/log(1-omega^phi)
78   ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
79     +1)
80
81   c = ifelse((y == 0), 0, ci)
82   c = ifelse((y == 1), 0, c)
83
84   Uomega <- phi*sum(c)
85
86   v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
87     (delta-1)*((y^phi)*log(y)/(1-y^phi)))
88   v = ifelse((y == 1), 0, v)
89
90   Uphi <- sum(v)
91
92   derivada=c(Uomega,Uphi)
93   derivada
94 }
95
96 ### initial values
97 ys01<- y
98 if(any(y==0)) ys01<- ys01[-which(y==0)]
99 if(any(y==1)) ys01<- ys01[-which(ys01==1)]

```

```

100 # fit <- vglm(ys01 ~ 1, kumar)
101 # par<-Coef(fit)
102
103 phi <- 5 #par[1]
104 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
105
106 #print(c(lambda,p,omega,phi))
107 ini <- c(omega,phi)
108
109 #####
110
111 opt <- optim(ini, loglik, escore, # hessian = T,
112 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
113
114 # opt <- optim(ini, loglik, escore,
115 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
116 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
117 # # upper = rep(.Machine$double.xmax,(r+2))
118 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
119 # upper = rep(.Machine$double.xmax,(r+2))
120 # )
121
122 # opt <- optim(ini, loglik, escore)
123
124 # print(opt$par)
125
126 # print(names(opt))
127 # print(summary(opt) )
128 # print(summary(opt)[1:6] )
129 # print(opt$kkt1)
130
131
132 if (opt$conv != 0)
133 warning("FUNCTION DID NOT CONVERGE!")
134
135 k <- c()
136
137 # print("AQUI1")
138 # print(gradient(escore, opt$par))
139
140 coef <- c(lambda,p,opt$par)
141 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
142 # print(coef)
143 k$coef <- coef
144 k$conv <- opt$conv

```

```

145 k$loglik <- opt$value
146 k$counts <- as.numeric(opt$counts[1])
147
148 # library(rootSolve)
149 # library(numDeriv)
150 # escores<-rbind(
151 #   escore(coef),
152 #   gradient(loglik, coef),
153 #   grad(loglik, coef))
154 # print(round(escores,5))
155
156 # k$Knum<-gradient(escore, coef)
157
158 # print(k$Knum)
159 # k$Knum<-hessian(escore, coef, method="complex")
160 # print(k$Knum)
161
162
163 # # Expected information matrix
164 #
165 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
166 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
167 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
168 #
169 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
170 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
171 # delta <- log(0.5)/log(1-k$omega^k$phi)
172 #
173 # kapa<- 0.5772156649
174 # k0<- (pi^2)/6+kapa^2-2*kapa
175 #
176 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
177 #   log(1-y^k$phi)+1)
178 #
179 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
180 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
181 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
182 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
183 #
184 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
185 #
186 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
187 #
188 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
189 #   2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
190 #     phi)) -
191 #   (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*

```

```

    k$phi^3))
190 # #
191 # # si <- (1-k$lambda)*(b2) # ifelse(y=c,0,b2) #
192 #
193 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
    +1)-kapa)/((delta-1)*k$phi)) )
194 #
195 # L = diag(-1/(k$lambda*(1-k$lambda)))
196 # V = diag((k$lambda-1)*k$phi^2*h2)
197 # M = diag(mi)
198 # S = diag(si)
199 #
200 #
201 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
202 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
203 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
204 # Isb = t(Ibs)
205 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
206 #
207 # if(u!=0)
208 # {
209 #   k$pi <- as.vector(coef[(m+1):(m+u)])
210 #   eta_hat2 <- as.vector(w1*%k$pi)
211 #   k$p <- as.vector(linkinv2(eta_hat2))
212 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
213 #   P = diag(-k$lambda/(k$p*(1-k$p)))
214 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
215 #
216 #   I <- rbind(
217 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
        ncol=s)),
218 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
        ncol=s)),
219 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
220 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
221 #   )
222 #
223 # }else{
224 #   I <- rbind(
225 #     cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
226 #     cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
227 #     cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
228 #   )
229 # }
230 #
231 # k$I <- I
232 #

```

```

233 #
234 # #####
235 #
236 # # print(-k$Knum)
237 # # print(k$I)
238 #
239 # # vcov <- try(solve(-k$Knum))
240 # vcov <- try(solve(k$I))
241 # # vcov <- chol2inv(chol(k$I))
242 # #vcov <- K #somente para nao trancar simulacao
243 #
244 # k$cov_ok = 0
245 # if (class(vcov) == "try-error")
246 # {
247 #   vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
248 #   with inversion
249 #   k$cov_ok = 1
250 #   #
251 #   # if (class(vcov) == "try-error") #
252 #   # {
253 #   #   vcov <- k$Knum^2
254 #   #   warning("Problem with the variance and covariance matrix. The p-values
255 #   #   are not correct.")
256 #   #   k$cov_ok = 2
257 #   # }
258 # }
259
260 # k$vcov <- vcov
261 # stderr <- sqrt(diag(k$vcov))
262 # k$stderr <- stderr
263
264 return(k)
265 }
266
267 ibetafit<-function(x)
268 {
269
270   n<- length(x) # sample size
271   n0<- sum(x==0) # number of zeros
272   n1<- sum(x==1) # number of ones
273   m<- n0 + n1
274
275   xm0<-x[which(x>0)]
276   x01<-xm0[which(xm0<1)]
277
278   #MV

```

```

278 loglik<-function(par)
279 {
280   alpha0<-par[1]
281   alpha1<-par[2]
282   gama<-par[3]
283   phi<-par[4]
284
285   alpha0 = ifelse(n0==0,0,alpha0)
286   alpha1 = ifelse(n1==0,0,alpha1)
287
288   #print(c(alpha0,alpha1,gama,phi))
289
290   c<- 1- alpha0*(1-gama)-alpha1*gama
291   mu<- gama*(1-alpha1)/c
292
293
294   l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
295   l1 = ifelse( (x == 1), log(alpha1*gama), 0)
296   l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
297   l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
      - mu) * phi, log = TRUE)))
298
299
300   #print("soma")
301   #print(sum(l0 + l1 + l2+ l3))
302   sum(l0 + l1 + l2+ l3)
303 }
304
305 escore<-function(par)
306 {
307   alpha0<-par[1]
308   alpha1<-par[2]
309   gama<-par[3]
310   phi<-par[4]
311
312   c<- 1- alpha0*(1-gama)-alpha1*gama
313   mu<- (gama*(1-alpha1))/c
314
315   a= mu * phi
316   b = a * (1 - mu)/mu
317
318   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
319   mustar <- digamma(a) - digamma(b)
320
321
322
323   Ualpha01 = ifelse((x == 0), (1/alpha0), 0)

```



```

324 #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
325 Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
      mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
326 Ualpha0 = sum(Ualpha01 + Ualpha03)
327
328 Ualpha0 = ifelse(n0==0,0,Ualpha0)
329
330
331 Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
332 #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
333 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
      gama*(1-gama)*(1-alpha0))/ (c^2) ) )
334 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
      digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
335 Ualpha1 = sum(Ualpha11 - Ualpha13)
336
337 Ualpha1 = ifelse(n1==0,0,Ualpha1)
338
339 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
340 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
341 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
      mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
342
343 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
344
345 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
346 #((mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
347 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
348 )
349 Uphi = sum(Uphi0)
350
351
352 c(Ualpha0,Ualpha1,Ugama,Uphi)
353 }
354
355 # metodo dos momentos para iniciarlizacao
356 x_bar<-mean(x01)
357 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
358
359 p<-x_bar*((x_bar*(1-x_bar))/sigma2_hat)-1)
360 q<-(1-x_bar)*((x_bar*(1-x_bar))/sigma2_hat)-1)
361
362 #print(c(x_bar,sigma2_hat,p,q))
363
364 delta0<- n0/n
365 delta1<- n1/n

```

```

366
367 a0<- delta0/(1-x_bar)
368 a1<- delta1/(x_bar)
369
370 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
371 par_ini<-c(a0,a1,p/(p+q),p+q)
372
373 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
374
375 #print("par_ini")
376 #print(par_ini)
377
378 max<-optim(par_ini,loglik,
379     escore,
380     method="BFGS",
381     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
382         (0.99999,0.99999,0.99999,9999999999),
383     control=list(fnscale=-1))
384
385 if(max$convergence != 0) print("Non-convergence")
386 # return
387 z<-c()
388 z$mv<-max$par
389 #print(z$mv)
390 z$conv<-max$convergence
391 z$loglik <- max$value
392 return(z)
393 }
394
395 iuGAfit <- function(y)
396 {
397
398     n <- length(y) # sample size
399     n0 <- sum(y == 0) # number of zeros
400     n1 <- sum(y == 1) # number of ones
401     m <- n0 + n1
402
403     ys01 <- y
404     if(any(y==0)) ys01<- ys01[-which(y==0)]
405     if(any(y==1)) ys01<- ys01[-which(ys01==1)]
406
407     i01 <- (y==0)+(y==1)
408
409     #Maxima verossimilhanca
410     loglik <- function (par){

```

```

412
413 alpha0 <- par[1]
414 alpha1 <- par[2]
415 gama <- par[3]
416 phi <- par[4]
417
418 alpha0 = ifelse(n0 == 0, 0, alpha0)
419 alpha1 = ifelse(n1 == 0, 0, alpha1)
420
421 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
422 mu <- gama * (1 - alpha1) / c
423 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
424
425 l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
426 l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
427 l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
428 l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
429
430 #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
431
432 sum(l0 + l1 + l2 + l3)
433
434 }
435 escore <- function (par) {
436
437   alpha0 <- par[1]
438   alpha1 <- par[2]
439   gama <- par[3]
440   phi <- par[4]
441
442   alpha0 <- ifelse(n0 == 0, 0, alpha0)
443   alpha1 <- ifelse(n1 == 0, 0, alpha1)
444
445   c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
446   mu <- gama * (1 - alpha1) / c
447   d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
448   ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
449   mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
450
451
452   Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
453   Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
     / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
     ^ 2))
454   Ualpha0 <- sum(Ualpha01 + Ualpha03)
455
456   Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)

```

```

457
458 Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
459 Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
      (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
      2))
460 Ualpha1 <- sum(Ualpha11 + Ualpha13)
461
462 Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
463
464 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
465 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
466 Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
      + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
      ^ 2))
467
468 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
469
470 Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
      / phi - ((d^2) * log(mu) * log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
      phi) - log(mu^(1/phi)))
471
472 Uphi = sum(Uphi0)
473
474 c(Ualpha0, Ualpha1, Ugama, Uphi)
475 }
476
477 #Inicializacao
478
479 y_bar <- mean(y)
480 y_bar0 <- mean(ys01)
481
482 delta0 <- n0/n
483 delta1 <- n1/n
484
485 a0 <- delta0/(1-y_bar)
486 a1 <- delta1/(y_bar)
487
488 #fit <- vglm(ys01 ~ 1, gamma2)
489 #par<-Coef(fit)
490
491 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
492 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
493 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
494 #phi_til = 5
495 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
496
497 par_ini <- c(a0, a1, y_bar, phi_til)

```

```

498
499 max<-optim(par_ini, loglik, escore,method = "BFGS",
500 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
501 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
502 control=list(fnscale=-1))
503
504 if(max$convergence != 0) print("Non-convergence")
505 # return
506 z <- c()
507 z$ini <- par_ini
508 z$mv <- max$par
509 z$conv <- max$convergence
510 z$loglik <- max$value
511 return(z)
512 }
513
514 n=100
515 #n=60
516 #n=100
517 #n=200
518 NR=10000
519 k=3 # numero de parametros
520
521 Cont_AIC_IB=rep(0,NR)
522 Cont_AIC_IK=rep(0,NR)
523 Cont_AIC_IUG=rep(0,NR)
524
525 Cont_AICC_IB=rep(0,NR)
526 Cont_AICC_IK=rep(0,NR)
527 Cont_AICC_IUG=rep(0,NR)
528
529 Cont_BIC_IB=rep(0,NR)
530 Cont_BIC_IK=rep(0,NR)
531 Cont_BIC_IUG=rep(0,NR)
532
533 Cont_BICC_IB=rep(0,NR)
534 Cont_BICC_IK=rep(0,NR)
535 Cont_BICC_IUG=rep(0,NR)
536
537 Cont_HQ_IB=rep(0,NR)
538 Cont_HQ_IK=rep(0,NR)
539 Cont_HQ_IUG=rep(0,NR)
540
541 Cont_HQC_IB=rep(0,NR)
542 Cont_HQC_IK=rep(0,NR)

```

```

543 Cont_HQC_IUG=rep(0,NR)
544
545 Cont_LL_IB =rep(0,NR)
546 Cont_LL_IK=rep(0,NR)
547 Cont_LL_IUG=rep(0,NR)
548
549 contC=0
550 contC1=0
551
552 prop.z = rep(0,NR)
553 prop.u = rep(0,NR)
554
555 cvm.iBE = rep(0,NR)
556 ks.iBE = rep(0,NR)
557 ad.iBE = rep(0,NR)
558
559 cvm.iuGA = rep(0,NR)
560 ks.iuGA = rep(0,NR)
561 ad.iuGA = rep(0,NR)
562
563 cvm.ikum = rep(0,NR)
564 ks.ikum = rep(0,NR)
565 ad.ikum = rep(0,NR)
566
567 alpha0 = 0
568 alpha1 = 0.0875
569 gama = 0.8
570 phi = 50
571
572 valores.parametros = c(alpha0, alpha1, gama, phi)
573
574 prob.z = alpha0*(1-gama)
575 prob.o = alpha1*gama
576
577 prob.z # probabilidade de zero
578 prob.o #probabilidade de um
579
580 media.v = gama
581 var.v = alpha1*gama*(1-alpha1*gama)+gama*(1-alpha1)*((2-((gama*(1-alpha1))/(1-
      alpha0*(1-gama)-alpha1*gama))^(1/phi))^(-phi)-gama*(1+alpha1))
582
583 media.v
584 var.v
585
586 #Bayes - BEINF
587
588 c= 1- alpha0*(1-gama)-alpha1*gama

```

```

589 mu = gama*(1-alpha1)/c
590 delta0 = alpha0 * (1-gama)
591 delta1 = alpha1 * (gama)
592 p2= 1- delta0-delta1
593
594 mu
595 delta0
596 delta1
597 p2
598 dp = sqrt(1/(phi+1))
599
600 cont.ib = 0
601 cont.ik = 0
602 cont.igu = 0
603
604 for(i in 1:NR) {
605
606
607   y = riGU(n,alpha0 = alpha0, alpha1=alpha1, gama = gama, phi = phi)
608   len = length(y)
609   prop.z[i] = sum(ifelse(y==0,1,0))/len
610   prop.u[i] = sum(ifelse(y==1,1,0))/len
611
612
613   fitib = ibetafit(y)
614   if (fitib$conv != 0)
615   {
616     cont.ib = cont.ib+1
617   }
618
619   fitik = ikumafit(y)
620   if (fitik$conv != 0)
621   {
622     cont.ik = cont.ik+1
623   }
624
625   fitigu = iuGAfit(y)
626
627
628   if ((fitigu$conv != 0) ){
629     cont.igu=cont.igu+1
630   }
631
632   ks.iBE[i] = ifelse(ks.test(y, "pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$p.value
633                     >0.05,1,0)
634   ad.iBE[i] = ifelse(ad.test(y, null="pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$p.
635                     value>0.05,1,0)

```

```

634   cvm.iBE[i] = ifelse(cvm.test(y, null="pBEINF1",mu=mu , sigma=dp, nu=delta1/p2)$
      p.value >0.05,1,0)
635   ks.iuGA[i] = ifelse(ks.test(y, "pgui",alpha0=alpha0,alpha1=alpha1,gama=gama,
      phi=phi)$p.value>0.05,1,0)
636   ad.iuGA[i] = ifelse(ad.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
      gama, phi=phi)$p.value>0.05,1,0)
637   cvm.iuGA[i] = ifelse(cvm.test(y, null="pgui",alpha0=alpha0,alpha1=alpha1,gama=
      gama, phi=phi)$p.value>0.05,1,0)
638   ks.ikum[i] = ifelse(ks.test(y, "pikum",lambda=alpha1, p=1,omega=gama, phi=phi)$
      p.value>0.05,1,0)
639   ad.ikum[i] = ifelse(ad.test(y, null="pikum",lambda=alpha1, p=1,omega=gama, phi=
      phi)$p.value>0.05,1,0)
640   cvm.ikum[i] = ifelse(cvm.test(y, null="pikum",lambda=alpha1, p=1,omega=gama,
      phi=phi)$p.value>0.05,1,0)
641
642   #Log verossimilhanca
643   # Beta inflacionada
644   log.vero_IB = fitib$loglik
645   # Kuma inflacionada
646   log.vero_IK= fitik$loglik
647   # Gamma Unitaria inflacionada
648   log.vero_IUG = fitigu$loglik
649
650   m.log.vero_IB = -fitib$loglik
651   # Kuma inflacionada
652   m.log.vero_IK= -fitik$loglik
653   # Gamma Unitaria inflacionada
654   m.log.vero_IUG = -fitigu$loglik
655
656   #Menor -log verossimilhanca
657   min_LL = which.min(c(m.log.vero_IB,m.log.vero_IK,m.log.vero_IUG))
658
659   Cont_LL_IB[i] = ifelse(min_LL==1,1,0)
660   Cont_LL_IK[i] = ifelse(min_LL==2,1,0)
661   Cont_LL_IUG[i] = ifelse(min_LL==3,1,0)
662
663   # Calculando os criterios/quantidades para comparacao
664
665   #criteiro_AIC#
666   AIC_IB = -2*log.vero_IB+2*k #BI(Beta Inflacionada)
667   AIC_IK= -2*log.vero_IK+2*k #KI(Kuma inflacionada)
668   AIC_IUG = -2*log.vero_IUG+2*k #GUI(Gamma Unitaria inflacionada)
669
670   # Selecionando o menor AIC
671   min_AIC = which.min(c(AIC_IB,AIC_IK,AIC_IUG))
672
673   Cont_AIC_IB[i] = ifelse(min_AIC==1,1,0) #BI

```



```

674 Cont_AIC_IK[i] = ifelse(min_AIC==2,1,0)
675 Cont_AIC_IUG[i] = ifelse(min_AIC==3,1,0)
676
677 AICC_IB= -2*log.vero_IB+(2*n*k)/(n-k-1) #BI
678 AICC_IK= -2*log.vero_IK+(2*n*k)/(n-k-1) #KI
679 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1) #GUI
680
681 # Seleccionando o menor AICC
682 min_AICC= which.min(c(AICC_IB,AICC_IK,AICC_IUG))
683
684 Cont_AICC_IB[i]=ifelse(min_AICC==1,1,0) #BI
685 Cont_AICC_IK[i]=ifelse(min_AICC==2,1,0)
686 Cont_AICC_IUG[i]=ifelse(min_AICC==3,1,0)
687
688 #criterio_BIC#
689 BIC_IB=-2*log.vero_IB+k*log(n) #BI
690 BIC_IK=-2*log.vero_IK+k*log(n) #KI
691 BIC_IUG=-2*fitigu$loglik+k*log(n) #GUI
692
693 # Seleccionando o menor BIC
694 min_BIC = which.min(c(BIC_IB,BIC_IK,BIC_IUG))
695
696 Cont_BIC_IB[i]=ifelse(min_BIC==1,1,0)
697 Cont_BIC_IK[i]=ifelse(min_BIC==2,1,0)
698 Cont_BIC_IUG[i]=ifelse(min_BIC==3,1,0)
699
700 #criterio_BICC#
701 # Beta inflacionada
702 BICC_IB=-2*log.vero_IB+(k*log(n))/(n-k-1) #BI
703 BICC_IK=-2*log.vero_IK+(k*log(n))/(n-k-1) #KI
704 BICC_IUG=-2*fitigu$loglik+(k*log(n))/(n-k-1) #GUI
705
706 # Seleccionando o menor BICC
707 min_BICC = which.min(c(BICC_IB,BICC_IK,BICC_IUG))
708
709 Cont_BICC_IB[i] = ifelse(min_BICC==1,1,0)
710 Cont_BICC_IK[i] = ifelse(min_BICC==2,1,0)
711 Cont_BICC_IUG[i] = ifelse(min_BICC==3,1,0)
712
713 #criterio_HQ#
714 HQ_IB=-2*log.vero_IB+2*log(log(n)) #BI
715 HQ_IK=-2*log.vero_IK+2*log(log(n)) #KI
716 HQ_IUG=-2*fitigu$loglik+2*log(log(n)) #GUI
717
718 # Seleccionando o menor HQ
719 min_HQ = which.min(c(HQ_IB,HQ_IK,HQ_IUG))
720

```

```

721 Cont_HQ_IB[i] = ifelse(min_HQ==1,1,0)
722 Cont_HQ_IK[i] = ifelse(min_HQ==2,1,0)
723 Cont_HQ_IUG[i] = ifelse(min_HQ==3,1,0)
724
725 #criterio_HQC#
726 HQC_IB=-2*log.vero_IB+(2*n*k*log(log(n)))/(n-k-1) #BI
727 HQC_IK=-2*log.vero_IK+(2*n*k*log(log(n)))/(n-k-1) #KI
728 HQC_IUG=-2*fitigu$loglik+(2*n*k*log(log(n)))/(n-k-1) #GUI
729
730 # Selecionando o menor HQC
731 min_HQC = which.min(c(HQC_IB,HQC_IK,HQC_IUG))
732
733 Cont_HQC_IB[i] = ifelse(min_HQC==1,1,0)
734 Cont_HQC_IK[i] = ifelse(min_HQC==2,1,0)
735 Cont_HQC_IUG[i] = ifelse(min_HQC==3,1,0)
736 # FIM DO LACO DE MONTE CARLO
737 }
738
739 # Proporcão média de zeros
740 #mean(prop.z)
741 # Proporcão média de uns
742 #mean(prop.u)
743
744 #Calculando percentuais escolha distribuicao(AIC)
745 p_AICIB<-((sum(Cont_AIC_IB))/NR)*100
746 p_AICIK<-((sum(Cont_AIC_IK))/NR)*100
747 p_AICIUG<-((sum(Cont_AIC_IUG))/NR)*100
748 p_AICIB
749 p_AICIK
750 p_AICIUG
751
752 #Calculando percentuais escolha distribuicao(AICC)
753 p_AICCIB<-((sum(Cont_AICC_IB))/NR)*100
754 p_AICCIK<-((sum(Cont_AICC_IK))/NR)*100
755 p_AICCIUG<-((sum(Cont_AICC_IUG))/NR)*100
756 p_AICCIB
757 p_AICCIK
758 p_AICCIUG
759
760 #Calculando percentuais escolha distribuicao(BIC)
761 p_BICIB<-((sum(Cont_BIC_IB))/NR)*100
762 p_BICIK<-((sum(Cont_BIC_IK))/NR)*100
763 p_BICIUG<-((sum(Cont_BIC_IUG))/NR)*100
764 p_BICIB
765 p_BICIK
766 p_BICIUG
767

```

```

768 #Calculando percentuais escolha distribuicao(BICC)
769 p_BICCIB<-((sum(Cont_BICC_IB))/NR)*100
770 p_BICCIK<-((sum(Cont_BICC_IK))/NR)*100
771 p_BICCIUG<-((sum(Cont_BICC_IUG))/NR)*100
772 p_BICCIB
773 p_BICCIK
774 p_BICCIUG
775
776 #Calculando percentuais escolha distribuicao(HQ)
777 p_HQIB<-((sum(Cont_HQ_IB))/NR)*100
778 p_HQIK<-((sum(Cont_HQ_IK))/NR)*100
779 p_HQIUG<-((sum(Cont_HQ_IUG))/NR)*100
780 p_HQIB
781 p_HQIK
782 p_HQIUG
783
784 #Calculando percentuais escolha distribuicao(HQC)
785 p_HQCIB<-((sum(Cont_HQC_IB))/NR)*100
786 p_HQCIK<-((sum(Cont_HQC_IK))/NR)*100
787 p_HQCIUG<-((sum(Cont_HQC_IUG))/NR)*100
788 p_HQCIB
789 p_HQCIK
790 p_HQCIUG
791
792 #Calculando percentuais escolha distribuicao(-LL)
793 p_LLIB<-((sum(Cont_LL_IB))/NR)*100
794 p_LLIK<-((sum(Cont_LL_IK))/NR)*100
795 p_LLIUG<-((sum(Cont_LL_IUG))/NR)*100
796 p_LLIB
797 p_LLIK
798 p_LLIUG
799
800 #resultados -log.vero
801 result_LL = cbind(p_LLIB,p_LLIK,p_LLIUG)
802 result_AIC=cbind(p_AICIB,p_AICIK,p_AICIUG)
803 result_AIC
804 result_AICC=cbind(p_AICCIB,p_AICCIK,p_AICCIUG)
805 result_AICC
806 result_BIC=cbind(p_BICIB,p_BICIK,p_BICIUG)
807 result_BIC
808 result_BICC=cbind(p_BICCIB,p_BICCIK,p_BICCIUG)
809 result_BICC
810 result_HQ=cbind(p_HQIB,p_HQIK,p_HQIUG)
811 result_HQ
812 result_HQC=cbind(p_HQCIB,p_HQCIK,p_HQCIUG)
813 result_HQC
814 cvm.Taxa.Nao.rej.iBE = (sum(cvm.iBE)/NR)*100

```

```

815 ks.Taxa.Nao.rej.iBE = (sum(ks.iBE)/NR)*100
816 ad.Taxa.Nao.rej.iBE = (sum(ad.iBE)/NR)*100
817 cvm.Taxa.Nao.rej.iuGA = (sum(cvm.iuGA)/NR)*100
818 ks.Taxa.Nao.rej.iuGA = (sum(ks.iuGA)/NR)*100
819 ad.Taxa.Nao.rej.iuGA = (sum(ad.iuGA)/NR)*100
820 cvm.Taxa.Nao.rej.ikum = (sum(cvm.ikum)/NR)*100
821 ks.Taxa.Nao.rej.ikum = (sum(ks.ikum)/NR)*100
822 ad.Taxa.Nao.rej.ikum = (sum(ad.ikum)/NR)*100
823
824 result.taxa.rej.ks = cbind(ks.Taxa.Nao.rej.iBE,ks.Taxa.Nao.rej.ikum,ks.Taxa.Nao.
    rej.iuGA)
825
826 result.taxa.rej.ad = cbind(ad.Taxa.Nao.rej.iBE,ad.Taxa.Nao.rej.ikum,ad.Taxa.Nao.
    rej.iuGA)
827
828 result.taxa.rej.cvm = cbind(cvm.Taxa.Nao.rej.iBE,cvm.Taxa.Nao.rej.ikum,cvm.Taxa.
    Nao.rej.iuGA)
829
830 M=rbind(result_LL, result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,
    result_HQC,result.taxa.rej.ks,
831 result.taxa.rej.ad,result.taxa.rej.cvm)
832 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
833 rownames(M) <- c("-LogVero","AIC","AICC","BIC", "BICC","HQ","HQC", "Taxa.Nao.Rej.
    ks",
834 "Taxa.Nao.Rej.ad","Taxa.Nao.Rej.cvm")
835
836 glue::glue("Numero de replicas: {NR}", "\n", "Tamanho amostral: {n}", "\n", "Prob
    .Zero: {prob.z}", "\n", "Prob.Um: {prob.o}",
837 "\n", "alpha.0: {alpha0}","\n", "alpha.1: {alpha1}", "\n", "gama: {gama}","\n", "
    phi: {phi}","\n", "media: {media.v}",
838 "\n", "var: {round(var.v,4)}")
839 print("Resultados")
840 print(M)
841
842 M.res=rbind( result_AIC,result.taxa.rej.ks,result.taxa.rej.ad,result.taxa.rej.cvm
    )
843 colnames(M.res) <- c("BIm.I","Kuma.I","GU.I")
844 rownames(M.res) <- c("critérios", "Taxa.Nao.Rej.ks","Taxa.Nao.Rej.ad","Taxa.Nao.
    Rej.cvm")
845 xtable(M.res)
846
847 #Salvando em um arquivo
848 #write.table(result_AIC, file = "Resultados_Escolha_Dist.txt", sep = " ")

```

Apêndice C

```
1      ##APLICACAO COM INFLACIONAMENTO EM ZERO##
2
3  #Proporcao de pessoas que usa internet em 2000 nos paises do mundo
4  #Fonte dos dados: https://ourworldindata.org/
5  library(gamlss.dist)
6  library(goftest) #ad e cvm
7  source("ikumafit.R")
8  source("iuga_fitv4.R")
9  source("ibetafit.R")
10 source("iuga_v2.R")
11 source("ikum-omega-phi.R")
12 library(gamlss)
13 library(gamlss.dist)
14 library(gamlss.data)
15 library(betareg)
16 library(MASS)
17
18 "ikumafit" <- function(y){
19
20   y <- as.vector(y)
21
22   n <- length(y)
23   n0<- sum(y==0) # number of zeros
24   n1<- sum(y==1) # number of ones
25
26   lambda <- (n0+n1)/n # lambda estimator
27   p <- n1/(n0+n1) # p estimator
28
29   u<-1
30   if(n0 == 0)
31   {
32     p=1
33     u=0
34   }
35
36   if(n1 == 0)
```

```

37 {
38   p=0
39   u=0
40 }
41
42 i01 <- (y==0)+(y==1)
43
44 loglik <- function(theta)
45 {
46   omega <- theta[1]
47   phi <- theta[2]
48
49   #####
50   l2 = 0
51   if(u!=0)
52   {
53     l2a = ifelse((y == 1), log(p), 0)
54     l2b = ifelse((y == 0), log(1-p), 0)
55     l2 = l2a + l2b
56   }
57
58   l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
59
60   l3 = ifelse((i01 == 1), 0,
61   log(phi)+
62   log(log(0.5)/log(1-omega^phi))+
63   (phi-1)*log(y)+
64   ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
65   )
66
67   sum(l1 + l2 + l3)
68 }
69
70 escore <- function(theta)
71 {
72   omega <- theta[1]
73   phi <- theta[2]
74
75   delta = log(0.5)/log(1-omega^phi)
76   ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
77   +1)
78
79   c = ifelse((y == 0), 0, ci)
80   c = ifelse((y == 1), 0, c)
81
82   Uomega <- phi*sum(c)

```

```

83   v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
84   (delta-1)*((y^phi)*log(y)/(1-y^phi)))
85   v = ifelse((y == 1), 0, v)
86
87   Uphi <- sum(v)
88
89   derivada=c(Uomega,Uphi)
90   derivada
91 }
92
93 ### initial values
94 ys01<- y
95 if(any(y==0)) ys01<- ys01[-which(y==0)]
96 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
97
98 # fit <- vglm(ys01 ~ 1, kumar)
99 # par<-Coef(fit)
100
101 phi <- 5 #par[1]
102 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
103
104 #print(c(lambda,p,omega,phi))
105 ini <- c(omega,phi)
106
107 #####
108
109 opt <- optim(ini, loglik, escore, # hessian = T,
110 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9)
111
112 # opt <- optim(ini, loglik, escore,
113 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
114 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
115 # # upper = rep(.Machine$double.xmax,(r+2))
116 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
117 # upper = rep(.Machine$double.xmax,(r+2))
118 # )
119
120 # opt <- optim(ini, loglik, escore)
121
122 # print(opt$par)
123
124 # print(names(opt))
125 # print(summary(opt) )
126 # print(summary(opt)[1:6] )
127 # print(opt$kkt1)

```

```

128
129
130 if (opt$conv != 0)
131   warning("FUNCTION DID NOT CONVERGE!")
132
133 k <- c()
134
135 # print("AQUI1")
136 # print(gradient(escore, opt$par))
137
138 coef <- c(lambda,p,opt$par)
139 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
140 # print(coef)
141 k$coef <- coef
142 k$conv <- opt$conv
143 k$loglik <- opt$value
144 k$counts <- as.numeric(opt$counts[1])
145
146 # library(rootSolve)
147 # library(numDeriv)
148 # escores<-rbind(
149 #   escore(coef),
150 #   gradient(loglik, coef),
151 #   grad(loglik, coef))
152 # print(round(escores,5))
153
154 # k$Knum<-gradient(escore, coef)
155
156 # print(k$Knum)
157 # k$Knum<-hessian(escore, coef, method="complex")
158 # print(k$Knum)
159
160
161 # # Expected information matrix
162 #
163 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
164 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
165 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
166 #
167 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
168 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
169 # delta <- log(0.5)/log(1-k$omega^k$phi)
170 #
171 # kapa<- 0.5772156649
172 # k0<- (pi^2)/6+kapa^2-2*kapa
173 #

```



```

174 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
      log(1-y^k$phi)+1)
175 #
176 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
177 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
178 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
179 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
180 #
181 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
182 #
183 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
184 #
185 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
186 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
      phi)) -
187 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
      k$phi^3))
188 # #
189 # # si <- (1-k$lambda)*(b2) # ifelse(y==c,0,b2) #
190 #
191 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
      +1)-kapa)/((delta-1)*k$phi)) )
192 #
193 # L = diag(-1/(k$lambda*(1-k$lambda)))
194 # V = diag((k$lambda-1)*k$phi^2*h2)
195 # M = diag(mi)
196 # S = diag(si)
197 #
198 #
199 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
200 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
201 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
202 # Isb = t(Ibs)
203 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
204 #
205 # if(u!=0)
206 # {
207 #   k$pi <- as.vector(coef[(m+1):(m+u)])
208 #   eta_hat2 <- as.vector(w1*%k$pi)
209 #   k$p <- as.vector(linkinv2(eta_hat2))
210 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
211 #   P = diag(-k$lambda/(k$p*(1-k$p)))
212 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
213 #
214 #   I <- rbind(
215 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
      ncol=s)),

```

```

216 # cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
      ncol=s)),
217 # cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
218 # cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
219 # )
220 #
221 # }else{
222 # I <- rbind(
223 # cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
224 # cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
225 # cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
226 # )
227 # }
228 #
229 # k$I <- I
230 #
231 #
232 # #####
233 #
234 # # print(-k$Knum)
235 # # print(k$I)
236 #
237 # # vcov <- try(solve(-k$Knum))
238 # vcov <- try(solve(k$I))
239 # # vcov <- chol2inv(chol(k$I))
240 # #vcov <- K #somente para nao trancar simulacao
241 #
242 # k$cov_ok = 0
243 # if (class(vcov) == "try-error")
244 # {
245 #   vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
      with inversion
246 #   k$cov_ok = 1
247 #
248 #   if (class(vcov) == "try-error") #
249 #   {
250 #     vcov <- k$Knum^2
251 #     warning("Problem with the variance and covariance matrix. The p-values
      are not correct.")
252 #     k$cov_ok = 2
253 #   }
254 # }
255
256
257 # k$vcov <- vcov
258 # stderr <- sqrt(diag(k$vcov))
259 # k$stderr <- stderr

```

```

260
261   return(k)
262 }
263
264 ibetafit<-function(x)
265 {
266
267   n<- length(x) # sample size
268   n0<- sum(x==0) # number of zeros
269   n1<- sum(x==1) # number of ones
270   m<- n0 + n1
271
272   xm0<-x[which(x>0)]
273   x01<-xm0[which(xm0<1)]
274
275   #MV
276   loglik<-function(par)
277   {
278     alpha0<-par[1]
279     alpha1<-par[2]
280     gama<-par[3]
281     phi<-par[4]
282
283     alpha0 = ifelse(n0==0,0,alpha0)
284     alpha1 = ifelse(n1==0,0,alpha1)
285
286     #print(c(alpha0,alpha1,gama,phi))
287
288     c<- 1- alpha0*(1-gama)-alpha1*gama
289     mu<- gama*(1-alpha1)/c
290
291
292     l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
293     l1 = ifelse( (x == 1), log(alpha1*gama), 0)
294     l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
295     l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
      - mu) * phi, log = TRUE)))
296
297
298     #print("soma")
299     #print(sum(l0 + l1 + l2+ l3))
300     sum(l0 + l1 + l2+ l3)
301   }
302
303   escore<-function(par)
304   {
305     alpha0<-par[1]

```

```

306 alpha1<-par[2]
307 gama<-par[3]
308 phi<-par[4]
309
310 c<- 1- alpha0*(1-gama)-alpha1*gama
311 mu<- (gama*(1-alpha1))/c
312
313 a= mu * phi
314 b = a * (1 - mu)/mu
315
316 ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
317 mustar <- digamma(a) - digamma(b)
318
319
320
321 Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
322 #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
323 Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
      mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
324 Ualpha0 = sum(Ualpha01 + Ualpha03)
325
326 Ualpha0 = ifelse(n0==0,0,Ualpha0)
327
328
329 Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
330 #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
331 Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
      gama*(1-gama)*(1-alpha0))/ (c^2) ) )
332 #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
      digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
333 Ualpha1 = sum(Ualpha11 - Ualpha13)
334
335 Ualpha1 = ifelse(n1==0,0,Ualpha1)
336
337 Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
338 Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
339 Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
      mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
340
341 Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
342
343 Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
344 #((mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
      digamma(b))
345 mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
346 )
347 Uphi = sum(Uphi0)

```

```

348
349
350     c(Ualpha0,Ualpha1,Ugama,Uphi)
351 }
352
353 # metodo dos momentos para iniciarlizacao
354 x_bar<-mean(x01)
355 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
356
357 p<-x_bar*(((x_bar*(1-x_bar))/sigma2_hat)-1)
358 q<-(1-x_bar)*(((x_bar*(1-x_bar))/sigma2_hat)-1)
359
360 #print(c(x_bar,sigma2_hat,p,q))
361
362 delta0<- n0/n
363 delta1<- n1/n
364
365 a0<- delta0/(1-x_bar)
366 a1<- delta1/(x_bar)
367
368 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
369 par_ini<-c(a0,a1,p/(p+q),p+q)
370
371 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
372
373 #print("par_ini")
374 #print(par_ini)
375
376 max<-optim(par_ini,loglik,
377     escore,
378     method="BFGS",
379     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
380         (0.99999,0.99999,0.99999,9999999999),
381     control=list(fnscale=-1))
382
383 if(max$convergence != 0) print("Non-convergence")
384 # return
385 z<-c()
386 z$mv<-max$par
387 #print(z$mv)
388 z$conv<-max$convergence
389 z$loglik <- max$value
390 return(z)
391 }
392
393 iuGAfit <- function(y)

```

```

394 {
395 {
396
397   n <- length(y) # sample size
398   n0 <- sum(y == 0) # number of zeros
399   n1 <- sum(y == 1) # number of ones
400   m <- n0 + n1
401
402   ys01 <- y
403   if(any(y==0)) ys01<- ys01[-which(y==0)]
404   if(any(y==1)) ys01<- ys01[-which(ys01==1)]
405
406   i01 <- (y==0)+(y==1)
407
408   #Maxima verossimilhanca
409
410   loglik <- function (par){
411
412     alpha0 <- par[1]
413     alpha1 <- par[2]
414     gama <- par[3]
415     phi <- par[4]
416
417     alpha0 = ifelse(n0 == 0, 0, alpha0)
418     alpha1 = ifelse(n1 == 0, 0, alpha1)
419
420     c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
421     mu <- gama * (1 - alpha1) / c
422     d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
423
424     l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
425     l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
426     l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
427     l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
428
429     #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
430
431     sum(l0 + l1 + l2 + l3)
432
433   }
434   escore <- function (par) {
435
436     alpha0 <- par[1]
437     alpha1 <- par[2]
438     gama <- par[3]
439     phi <- par[4]
440

```

```

441 alpha0 <- ifelse(n0 == 0, 0, alpha0)
442 alpha1 <- ifelse(n1 == 0, 0, alpha1)
443
444 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
445 mu <- gama * (1 - alpha1) / c
446 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
447 ystar <- ifelse((y == 0) | (y == 1), 0, log(y))
448 mustar <- ifelse((y == 0) | (y == 1), 0, -phi / d)
449
450
451 Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
452 Ualpha03 <- ifelse((y == 0) | (y == 1), 0, - (1 - gama) / c + (d * (1 + d)
    / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
    ^ 2))
453 Ualpha0 <- sum(Ualpha01 + Ualpha03)
454
455 Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
456
457 Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
458 Ualpha13 <- ifelse((y == 0) | (y == 1), 0, - (gama / c) - ((d * (1 + d)) /
    (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
    2))
459 Ualpha1 <- sum(Ualpha11 + Ualpha13)
460
461 Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
462
463
464 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
465 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
466 Ugama04 <- ifelse((y == 0) | (y == 1), 0, (alpha0 - alpha1) / c + ((d * (1
    + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
    ^ 2))
467
468 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
469
470 Uphi0 <- ifelse((y == 0) | (y == 1), 0, log(-log(y)) + log(d) - (d*log(mu))
    / phi - ((d^2) * log(mu) * log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
    phi) - log(mu^(1/phi)))
471
472 Uphi = sum(Uphi0)
473
474
475 c(Ualpha0, Ualpha1, Ugama, Uphi)
476 }
477
478 #Inicializacao
479

```

```

480 y_bar <- mean(y)
481 y_bar0 <- mean(ys01)
482
483 delta0 <- n0/n
484 delta1 <- n1/n
485
486 a0 <- delta0/(1-y_bar)
487 a1 <- delta1/(y_bar)
488
489 #fit <- vglm(ys01 ~ 1, gamma2)
490 #par<-Coef(fit)
491
492 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
493 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
494 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
495 #phi_til = 5
496 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
497
498 par_ini <- c(a0, a1, y_bar, phi_til)
499
500 max<-optim(par_ini, loglik, escore,method = "BFGS",
501 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
502 (0.99999,0.99999,0.99999,9999999999),
503 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
504 (0.99999,0.99999,0.99999,9999999999),
505 control=list(fnscale=-1))
506
507 if(max$convergence != 0) print("Non-convergence")
508 # return
509 z <- c()
510 z$ini <- par_ini
511 z$mv <- max$par
512 z$conv <- max$convergence
513 z$loglik <- max$value
514 return(z)
515 }
516
517 #valores da aplicacao
518 y<-c( 0, 0.0010, 0.0050, 0, 0.1050, 0.0010, 0.0650, 0.0700, 0.0130, 0.1540,
519 0.4680, 0.3370, 0.0010, 0.0800, 0.0620, 0.0010, 0.0400, 0.0190, 0.2940, 0.0600,
520 0.0020, 0.4290, 0.0040, 0.0140, 0.0110, 0.0290, 0.0290, 0.1890, 0.0900, 0.0540,
521 0.0010, 0.0010, 0, 0.0030, 0.5130, 0.0180, 0.3800, 0.0010, 0, 0.1660,
522 0.0180, 0.0220, 0.0030, 0, 0.0580, 0.0020, 0.0660, 0.0050, 0.1530, 0.0980,
523 0, 0.3920, 0.0020, 0.0880, 0.0370, 0, 0.0150, 0.0060, 0.0120, 0.0010,
524 0.0010, 0.2860, 0.0090, 0, 0.0150, 0.3720, 0.1430, 0.0640, 0.0120, 0.0090,
525 0.0050, 0.3020, 0.0020, 0.1910, 0.0910, 0.3170, 0.0410, 0.1610, 0.0070, 0.0010,
526 0.0020, 0.0060, 0.0020, 0.0120, 0.2780, 0.0700, 0.4450, 0.0050, 0.0090, 0.0090,

```



```

525 0.0010, 0.1790, 0.2090, 0.2310, 0.0310, 0.3000, 0.0260, 0.0070, 0.0030, 0.0180,
526 0.0670, 0.0100, 0.0010, 0.0630, 0.0800, 0.0020, 0, 0.0020, 0.3650, 0.0640,
527 0.2290, 0.1360, 0.0010, 0.0010, 0.2140, 0.0220, 0.0010, 0.1310, 0.0150, 0.0020,
528 0.0730, 0.0510, 0.0370, 0.0130, 0.4220, 0.0130, 0.2540, 0.0070, 0.0010, 0,
529 0.0160, 0.0300, 0.0020, 0.0330, 0.1390, 0.0320, 0.0100, 0, 0.0010, 0,
530 0.0250, 0, 0.0420, 0.0350, 0.0130, 0.2020, 0.0110, 0.0660, 0.0080, 0.0070,
531 0.0310, 0.0200, 0.0040, 0.0070, 0.1050, 0.0490, 0.0360, 0.0010, 0.0010, 0.0590,
532 0.0510, 0.0320, 0.0060, 0.4880, 0.0460, 0.0220, 0.0040, 0.2350, 0.0740, 0.0010,
533 0.0120, 0.0030, 0.0110, 0.0050, 0, 0.0020, 0.0030, 0.0030, 0.0060, 0,
534 0.0250, 0.0340, 0.0270, 0.0020, 0, 0.0010, 0.0370, 0.0080, 0.0240, 0.0770,
535 0.0280, 0.0380, 0.0010, 0, 0.0520, 0.0020, 0.0070, 0.2360, 0.0100, 0.0490,
536 0.0090, 0.0010, 0.0050, 0.0210, 0.0010, 0.0030, 0.0010, 0.0020, 0.0040)
537
538 #descricao dos dados
539 summary(y)
540 var(y)
541 sd(y)
542 cv<- (sd(y))/(mean(y))
543 cv
544 len = length(y)
545 n=len
546 n
547 prop.z = sum(ifelse(y==0,1,0))/len
548 prop.z
549 prop.u = sum(ifelse(y==1,1,0))/len
550 prop.u
551 var_y=var(y)
552 media_y=mean(y)
553 media_y
554 var_y
555
556 fitib = ibetafit(y)
557 if (fitib$conv != 0)
558 {
559   cont.ib = cont.ib+1
560 }
561
562 fitik = ikumafit(y)
563 if (fitik$conv != 0)
564 {
565   cont.ik = cont.ik+1
566 }
567
568 fitigu = iuGAfit(y)
569
570 if ((fitigu$conv != 0) ){
571   cont.igu=cont.igu+1

```

```

572 }
573
574 fitib
575 fitik
576 fitigu
577 fitigu$mv
578
579 ##logverossimilhanaa
580 log.vero_IB = fitib$loglik #BI
581 log.vero_IK= fitik$loglik #KI
582 log.vero_IUG = fitigu$loglik #GUI
583
584 k=3 #inflacionado em um
585
586 #criterios#
587
588 ##AIC##
589 AIC_IB=-2*fitib$loglik+2*k #BI
590 AIC_IK= -2*fitik$loglik+2*k #KI
591 AIC_IUG = -2*fitigu$loglik+2*k #GUI
592
593 ##AICC##
594 AICC_IB=-2*fitib$loglik + (2*n*k)/(n-k-1) #BI
595 AICC_IK= -2*fitik$loglik + (2*n*k)/(n-k-1) #KI
596 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1) #GUI
597
598 ##BIC##
599 BIC_IB=-2*fitib$loglik+k*log(n) #BI
600 BIC_IK=-2*fitik$loglik+k*log(n) #KI
601 BIC_IUG=-2*fitigu$loglik+k*log(n) #GUI
602
603 ##BICC##
604 BICC_IB=-2*fitib$loglik+(n*k*log(n))/(n-k-1) #BI
605 BICC_IK=-2*fitik$loglik+(n*k*log(n))/(n-k-1) #KI
606 BICC_IUG=-2*fitigu$loglik+(n*k*log(n))/(n-k-1) #GUI
607
608 ##HQ##
609 HQ_IB= -2*fitib$loglik + 2*k*log(log(n)) #BI
610 HQ_IK= -2*fitik$loglik + 2*k*log(log(n)) #KI
611 HQ_IUG= -2*fitigu$loglik + 2*k*log(log(n)) #GUI
612
613 ##HQC##
614 HQC_IB= -2*fitib$loglik +(2*n*k*log(log(n)))/(n-k-1) #BI
615 HQC_IK= -2*fitik$loglik +(2*n*k*log(log(n)))/(n-k-1) #KI
616 HQC_IUG= -2*fitigu$loglik +(2*n*k*log(log(n)))/(n-k-1) #GUI
617
618 ##testes_hipotese#

```

```

619 #Gama Unitaria Inflacionada
620 ks.iuGA = ks.test(y, "pgui",alpha0=fitigu$mv[1],alpha1=fitigu$mv[2],gama=fitigu$
      mv[3], phi=fitigu$mv[4])$p.value
621 ks.iuGA
622
623 library(DescTools)
624 ad.iuGA = AndersonDarlingTest(y, null="pgui",alpha0=fitigu$mv[1], alpha1=fitigu$
      mv[2],gama=fitigu$mv[3], phi=fitigu$mv[4])$p.value
625 ad.iuGA
626
627 cvm.iuGA = cvm.test(y, null="pgui",alpha0=fitigu$mv[1],alpha1=fitigu$mv[2], gama=
      fitigu$mv[3], phi=fitigu$mv[4])$p.value
628 cvm.iuGA
629
630 #nu=p0/p2 tau=p1/p2
631 p0=prop.z
632 p1=prop.u
633 p2=1-p0-p1
634
635 dp=sqrt(1/((fitib$mv[4])+1))
636
637 #Beta Inflacionada
638 ks.iBE = ks.test(y, "pBEINFO",mu=fitib$mv[3] , sigma=dp, nu=p0/p2)$p.value
639 ks.iBE
640
641 #library(DescTools)
642 ad.iBE = AndersonDarlingTest(y, null="pBEINFO",mu=fitib$mv[3] , sigma=dp, nu=p0/
      p2)$p.value
643 ad.iBE
644
645 cvm.iBE = cvm.test(y, null="pBEINFO",mu=fitib$mv[3] , sigma=dp, nu=p0/p2)$p.value
646 cvm.iBE
647
648 #Kumaraswamy Iflacionada
649 ks.ikum = ks.test(y, "pikum",lambda=fitik$coef[1], p=fitik$coef[2],omega=fitik$
      coef[3], phi=fitik$coef[4])$p.value
650 ks.ikum
651
652 #library(DescTools)
653 ad.ikum = AndersonDarlingTest(y, null="pikum",lambda=fitik$coef[1], p=fitik$coef
      [2],omega=fitik$coef[3], phi=fitik$coef[4])$p.value
654 ad.ikum
655
656 cvm.ikum = cvm.test(y, null="pikum",lambda=fitik$coef[1], p=fitik$coef[2],omega=
      fitik$coef[3], phi=fitik$coef[4])$p.value
657 cvm.ikum
658 ### Criterios de selecao

```

```

659 AIC_IUG
660 AICC_IUG
661 BIC_IUG
662
663 ks.iuGA # p-valores
664 ad.iuGA
665 cvm.iuGA
666
667 ##resutados
668 #Recebendo Resultados(AIC)
669 result_AIC=cbind(AIC_IB,AIC_IK,AIC_IUG)
670 result_AIC
671 #Recebendo Resultados(AICC)
672 result_AICC=cbind(AICC_IB,AICC_IK,AICC_IUG)
673 result_AICC
674 #Recebendo Resultados(BIC)
675 result_BIC=cbind(BIC_IB,BIC_IK,BIC_IUG)
676 result_BIC
677 #Recebendo Resultados(BICC)
678 result_BICC=cbind(BICC_IB,BICC_IK,BICC_IUG)
679 result_BICC
680 #Recebendo Resultados(HQ)
681 result_HQ=cbind(HQ_IB,HQ_IK,HQ_IUG)
682 result_HQ
683 #Recebendo Resultados(HQC)
684 result_HQC=cbind(HQC_IB,HQC_IK,HQC_IUG)
685 result_HQC
686
687 cvm.p.valor.iBE = (cvm.iBE)
688 ks.p.valor.iBE = (ks.iBE)
689 ad.p.valor.iBE = (ad.iBE)
690 cvm.p.valor.iuGA = (cvm.iuGA)
691 ks.p.valor.iuGA = (ks.iuGA)
692 ad.p.valor.iuGA = (ad.iuGA)
693 cvm.p.valor.ikum = (cvm.ikum)
694 ks.p.valor.ikum = (ks.ikum)
695 ad.p.valor.ikum = (ad.ikum)
696 result.p.valor.ks = cbind(ks.p.valor.iBE,ks.p.valor.ikum,ks.p.valor.iuGA)
697 result.p.valor.ad = cbind(ad.p.valor.iBE,ad.p.valor.ikum,ad.p.valor.iuGA)
698 result.p.valor.cvm = cbind(cvm.p.valor.iBE,cvm.p.valor.ikum,cvm.p.valor.iuGA)
699 M=rbind( result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,result_HQC,
        result.p.valor.ks,
700 result.p.valor.ad,result.p.valor.cvm)
701 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
702 rownames(M) <- c("AIC","AICC","BIC","BICC","HQ","HQC","p.valor.ks",
703 "p.valor.ad","p.valor.cvm")

```

```

704 glue::glue( "Tamanho amostral: {n}", "\n", "Prob.Zero: {round(prop.z,4)}", "\n",
      "Prob.Um: {round(prop.u,4)}",
705 "\n", "media: {round(media_y,4)}",
706 "\n", "var: {round(var_y,4)}")
707 print("Resultados")
708 print(M)
709 library(xtable)
710 xtable(M)
711
712 #NOVA TABELA
713 result.bi=cbind(AIC_IB,AICC_IB,BIC_IB,BICC_IB,HQ_IB,HQC_IB)
714 result.gui=cbind(AIC_IUG,AICC_IUG,BIC_IUG,BICC_IUG,HQ_IUG,HQC_IUG)
715 result.ki=cbind(AIC_IK,AICC_IK,BIC_IK,BICC_IK,HQ_IK,HQC_IK)
716 result.bi
717 result.ki
718 result.gui
719
720 #nova tabela p-valor
721 result_pvalor_bi=cbind({round(ks.p.valor.iBE,3)},{round(cvm.p.valor.iBE,4)},{
      round(ad.p.valor.iBE,4)})
722 result_pvalor_ki=cbind({round(ks.p.valor.ikum,4)},{round(cvm.p.valor.ikum,4)},{
      round(ad.p.valor.ikum,4)})
723 result_pvalor_gui=cbind({round(ks.p.valor.iuGA,4)},{round(cvm.p.valor.iuGA,4)},{
      round(ad.p.valor.iuGA,4)})
724 result_pvalor_bi
725 result_pvalor_ki
726 result_pvalor_gui
727
728 ##grafico pp plot##
729 set.seed(33)
730 library(stats)
731 par(mfrow=c(1,3))
732 ##grafico da BI
733 dados_teoricos <- rBEINF0(n,mu=fitib$mv[3] , sigma=dp, nu=p0/p2)
734 dados_observados <- y
735 xlim=c(0,1)
736 ylim=c(0,1)
737 plot(xlim = c(0,0.65), ylim = c(0,0.65),sort(dados_teoricos), sort(dados_
      observados), main = "BI[0,1]", xlab = "", ylab = "")
738 abline(0, 1, col = "black", lty = 1)
739
740 ##grafico da GUI
741 dados_teoricos <- riGU(n,alpha0=fitigu$mv[1],alpha1=fitigu$mv[2],gama=fitigu$mv
      [3], phi=fitigu$mv[4])
742 dados_observados <- y
743 xlim=c(0,1)
744 ylim=c(0,1)

```

```

745 plot(xlim = c(0,0.65), ylim = c(0,0.65),sort(dados_teoricos), sort(dados_
      observados), main = "GUI[0,1)", xlab = "", ylab = "")
746 abline(0, 1, col = "black", lty = 1)
747
748 ##grafico da KI
749 dados_teoricos <- rikum(n,lambda=fitik$coef[1], p=fitik$coef[2],omega=fitik$coef
      [3], phi=fitik$coef[4])
750 dados_observados <- y
751 plot(xlim = c(0,0.65), ylim = c(0,0.65),sort(dados_teoricos), sort(dados_
      observados), main = "KI[0,1)", xlab = "", ylab = "")
752 abline(0, 1, col = "black", lty = 1)
753 dev.off()

```

```

1      ##APLICACAO COM INFLACIONAMENTO EM ZERO##
2 #Proporcao de nascidos vivos nos municipios do estado da Paraiba, com 4000 gramas
   ou mais em 2021.
3 #Obs: usando como referencia a residencia da mae
4 #Fonte dos dados: https://datasus.saude.gov.br/
5 #conjunto de dados#
6 y<-c(0.0833, 0.0794, 0.0694, 0.0583, 0.0565, 0.1146, 0.0862, 0.0686,
7 0.0851, 0.0357, 0.0217, 0.0973, 0.0735, 0.0531, 0.0386, 0.0882,
8 0.0708, 0.0723, 0.0833, 0.0722, 0.0675, 0.0635, 0.0851, 0.0629,
9 0.0825, 0.0644, 0.0701, 0.0492, 0.0141, 0.1143, 0.0494, 0.0625,
10 0, 0.0338, 0.0868, 0.0781, 0.0645, 0.0505, 0.0137, 0.0588,
11 0.1321, 0.0641, 0.0432, 0.0682, 0.0658, 0.0485, 0.1154, 0.0428,
12 0.0222, 0.0533, 0.0842, 0.0519, 0.0455, 0.0933, 0, 0.0976,
13 0.0313, 0.0355, 0.0241, 0.0285, 0.0674, 0.0629, 0.0348, 0.0699,
14 0, 0.0744, 0.1391, 0.0460, 0.0381, 0.1043, 0.0976, 0.0606,
15 0.0857, 0.0414, 0.0200, 0.0843, 0.0647, 0.0566, 0.0250, 0.0447,
16 0.0446, 0, 0.1007, 0.0702, 0.0909, 0.0566, 0.1169, 0.0567,
17 0.0785, 0.0929, 0.0765, 0.0836, 0.0585, 0.1121, 0.0723, 0.0588,
18 0.0317, 0.0733, 0.0270, 0.0735, 0.0603, 0.0943, 0.0301, 0.0505,
19 0.0444, 0.0795, 0.1250, 0.0536, 0.0500, 0, 0.0629, 0.0361,
20 0.0625, 0.0569, 0.0130, 0.0850, 0.0726, 0.0610, 0.0357, 0.0379,
21 0.0750, 0.0467, 0, 0.0597, 0.0642, 0.0690, 0.0309, 0.1176,
22 0.1154, 0, 0.0349, 0.0227, 0.0526, 0.1429, 0, 0.0634,
23 0.0705, 0.0952, 0.0533, 0.0828, 0.1000, 0.0283, 0.0909, 0.0938,
24 0.0825, 0.1260, 0.1088, 0.0517, 0.0196, 0.0682, 0.0833, 0.0417,
25 0.0498, 0.0480, 0.0916, 0.0526, 0.0518, 0.0845, 0.1081, 0.0520,
26 0.0779, 0.0526, 0.0319, 0.0817, 0.0698, 0.0464, 0.1024, 0.1094,
27 0.0435, 0, 0.0505, 0.0600, 0.1250, 0, 0.0651, 0.0833,
28 0.0714, 0.0350, 0.0926, 0.0625, 0, 0, 0.0556, 0.0377,
29 0.0704, 0.0860, 0.1071, 0.1250, 0.0290, 0.0377, 0.0800, 0,
30 0.0652, 0.0816, 0.1034, 0.0758, 0.0576, 0.1351, 0.0689, 0.0625,
31 0.0476, 0.0588, 0.0556, 0.0594, 0.0274, 0.0897, 0.0413, 0.0488,
32 0.0450, 0.0526, 0.0322, 0.0762, 0.0648, 0.0354, 0.0287, 0.0783,
33 0.0698, 0.0381, 0.0536, 0.0417, 0.1379, 0.1111, 0.0323)

```

```

1      ##APLICACAO COM INFLACIONAMENTO EM ZERO##
2      #Porcentagem de pacientes com tuberculose e VIH em 2005 nos paises do mundo.
3      #Fonte dos dados: https://ourworldindata.org/
4      #conjunto de dados
5      y<-c(0.0000, 0.0030, 0.0030, 0.2000, 0.5000, 0.0600, 0.0310, 0.0490, 0.0370,
6           0.0250,
7           0.4200, 0.0150, 0.0010, 0.3600, 0.0190, 0.0550, 0.2400, 0.1900, 0.0410, 0.0310,
8           0.0010, 0.7900, 0.0720, 0.0120, 0.0020, 0.2200, 0.3000, 0.0880, 0.4300, 0.0770,
9           0.0470, 0.5100, 0.2200, 0.0930, 0.0160, 0.0690, 0.0180, 0.4100, 0.1300, 0.4700,
10          0.0110, 0.0000, 0.0600, 0.0070, 0.2200, 0.0490, 0.3500, 0.0860, 0.0090, 0.0510,
11          0.0020, 0.1200, 0.4300, 0.1600, 0.0670, 0.7600, 0.2300, 0.0080, 0.0180, 0.1000,
12          0.4500, 0.2400, 0.0080, 0.0460, 0.2800, 0.0360, 0.0000, 0.0620, 0.2000, 0.3900,
13          0.1800, 0.2900, 0.0980, 0.0080, 0.0080, 0.1000, 0.0760, 0.0160, 0.0230, 0.0000,
14          0.0460, 0.0540, 0.0920, 0.3500, 0.0080, 0.0010, 0.0060, 0.5400, 0.0060, 0.0080,
15          0.0260, 0.0430, 0.0060, 0.7300, 0.2800, 0.0180, 0.0300, 0.0630, 0.0030, 0.0080,
16          0.6700, 0.1300, 0.0000, 0.2000, 0.0260, 0.0000, 0.0800, 0.0170, 0.0490, 0.0010,
17          0.0030, 0.0050, 0.0140, 0.6100, 0.1100, 0.7000, 0.0320, 0.0540, 0.0250, 0.0310,
18          0.0810, 0.2000, 0.0010, 0.0000, 0.0360, 0.0390, 0.0010, 0.0000, 0.1300, 0.0990,
19          0.0660, 0.0530, 0.0010, 0.0170, 0.2300, 0.3400, 0.0000, 0.0160, 0.0410, 0.4500,
20          0.2000, 0.0330, 0.0080, 0.1100, 0.0020, 0.1100, 0.0590, 0.0010, 0.0120, 0.0390,
21          0.7100, 0.1400, 0.0050, 0.0280, 0.1900, 0.0270, 0.1000, 0.0010, 0.0040, 0.4700,
22          0.2300, 0.3500, 0.3400, 0.0060, 0.0010, 0.0920, 0.5100, 0.1200, 0.0200, 0.0670,
           0.1500, 0.1300, 0.0040, 0.1700, 0.0580, 0.0050, 0.7000, 0.7100)

```

```

1      ##APLICACAO COM INFLACIONAMENTO EM ZERO e UM ##
2      #aplicacao_inflacionado_zero_um
3      #proporcao da populacao urbana residente em domicilios ligados a rede de
4      #Fonte dos dados: http://www.atlasbrasil.org.br/
5      library(goftest) #ad e cvm
6      source("ikumafit.R")
7      source("iuga_fitv4.R")
8      source("ibetafit.R")
9      source("iuga_v2.R")
10     source("ikum-omega-phi.R")
11     library(gamlss)
12     library(gamlss.dist)
13     library(gamlss.data)
14     library(betareg)
15     library(MASS)
16
17
18     "ikumafit" <- function(y){
19
20         y <- as.vector(y)
21

```

```

22 n <- length(y)
23 n0<- sum(y==0) # number of zeros
24 n1<- sum(y==1) # number of ones
25
26 lambda <- (n0+n1)/n # lambda estimator
27 p <- n1/(n0+n1)# p estimator
28
29 u<-1
30 if(n0 == 0)
31 {
32   p=1
33   u=0
34 }
35
36 if(n1 == 0)
37 {
38   p=0
39   u=0
40 }
41
42 i01 <- (y==0)+(y==1)
43
44 loglik <- function(theta)
45 {
46   omega <- theta[1]
47   phi <- theta[2]
48
49   #####
50   l2 = 0
51   if(u!=0)
52   {
53     l2a = ifelse((y == 1), log(p), 0)
54     l2b = ifelse((y == 0), log(1-p), 0)
55     l2 = l2a + l2b
56   }
57
58   l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
59
60   l3 = ifelse((i01 == 1), 0,
61   log(phi)+
62   log(log(0.5)/log(1-omega^phi))+
63   (phi-1)*log(y)+
64   ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
65   )
66
67   sum(l1 + l2 + l3)
68 }

```



```

69
70 escore <- function(theta)
71 {
72   omega <- theta[1]
73   phi <- theta[2]
74
75   delta = log(0.5)/log(1-omega^phi)
76   ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi
77     )+1)
78
79   c = ifelse((y == 0), 0, ci)
80   c = ifelse((y == 1), 0, c)
81
82   Uomega <- phi*sum(c)
83
84   v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
85     (delta-1)*((y^phi)*log(y)/(1-y^phi)))
86   v = ifelse((y == 1), 0, v)
87
88   Uphi <- sum(v)
89
90   derivada=c(Uomega,Uphi)
91   derivada
92 }
93
94 ### initial values
95 ys01<- y
96 if(any(y==0)) ys01<- ys01[-which(y==0)]
97 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
98
99 # fit <- vglm(ys01 ~ 1, kumar)
100 # par<-Coef(fit)
101
102 phi <- 5 #par[1]
103 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
104
105 #print(c(lambda,p,omega,phi))
106 ini <- c(omega,phi)
107
108 #####
109
110 opt <- optim(ini, loglik, escore, # hessian = T,
111 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e
112 -9))
113
114 # opt <- optim(ini, loglik, escore,
115 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol

```

```

    = 1e-9),
114 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$
    double.eps),
115 # # upper = rep(.Machine$double.xmax,(r+2))
116 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
117 # upper = rep(.Machine$double.xmax,(r+2))
118 # )
119
120 # opt <- optim(ini, loglik, escore)
121
122 # print(opt$par)
123
124 # print(names(opt))
125 # print(summary(opt) )
126 # print(summary(opt)[1:6] )
127 # print(opt$kkt1)
128
129
130 if (opt$conv != 0)
131 warning("FUNCTION DID NOT CONVERGE!")
132
133 k <- c()
134
135 # print("AQUI1")
136 # print(gradient(escore, opt$par))
137
138 coef <- c(lambda,p,opt$par)
139 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
140 # print(coef)
141 k$coef <- coef
142 k$conv <- opt$conv
143 k$loglik <- opt$value
144 k$counts <- as.numeric(opt$counts[1])
145
146 # library(rootSolve)
147 # library(numDeriv)
148 # escores<-rbind(
149 # escore(coef),
150 # gradient(loglik, coef),
151 # grad(loglik, coef))
152 # print(round(escores,5))
153
154 # k$Knum<-gradient(escore, coef)
155
156 # print(k$Knum)
157 # k$Knum<-hessian(escore, coef, method="complex")
158 # print(k$Knum)

```

```

159
160 # # Expected information matrix
161 #
162 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
163 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
164 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
165 #
166 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
167 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)
168 # delta <- log(0.5)/log(1-k$omega^k$phi)
169 #
170 # kapa<- 0.5772156649
171 # k0<- (pi^2)/6+kapa^2-2*kapa
172 #
173 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(
174 # delta*log(1-y^k$phi)+1)
175 #
176 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
177 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
178 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
179 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
180 #
181 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
182 #
183 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
184 #
185 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
186 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)
187 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta
188 # # -2)*k$phi^3))
189 #
190 # # si <- (1-k$lambda)*(b2) # ifelse(y==c,0,b2) #
191 #
192 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(
193 # delta+1)-kapa)/((delta-1)*k$phi)) )
194 #
195 # L = diag(-1/(k$lambda*(1-k$lambda)))
196 # V = diag((k$lambda-1)*k$phi^2*h2)
197 # M = diag(mi)
198 # S = diag(si)
199 #
200 # Igg = -t(z1) %%% L %%% (T1^2) %%% z1
201 # Ibb = -t(x1) %%% V %%% (T3^2) %%% x1
202 # Ibs = -t(x1) %%% T3 %%% M %%% T4 %%% q1

```

```

201 # Isb = t(Ibs)
202 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
203 #
204 # if(u!=0)
205 # {
206 #   k$pi <- as.vector(coef[(m+1):(m+u)])
207 #   eta_hat2 <- as.vector(w1%*%k$pi)
208 #   k$p <- as.vector(linkinv2(eta_hat2))
209 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
210 #   P = diag(-k$lambda/(k$p*(1-k$p)))
211 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
212 #
213 #   I <- rbind(
214 #     cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=
215 #       m,ncol=s)),
216 #     cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=
217 #       u,ncol=s)),
218 #     cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
219 #     cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
220 #   )
221 # }else{
222 #   I <- rbind(
223 #     cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
224 #     cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
225 #     cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
226 #   )
227 # }
228 # k$I <- I
229 #
230 #
231 # #####
232 #
233 # # print(-k$Knum)
234 # # print(k$I)
235 #
236 # # vcov <- try(solve(-k$Knum))
237 # vcov <- try(solve(k$I))
238 # # vcov <- chol2inv(chol(k$I))
239 # #vcov <- K #somente para nao trancar simulacao
240 #
241 # k$cov_ok = 0
242 # if (class(vcov) == "try-error")
243 # {
244 #   vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
245 #     with inversion

```

```

245     # k$cov_ok = 1
246     #
247     # if (class(vcov) == "try-error") #
248     # {
249     #   vcov <- k$Knum^2
250     #   warning("Problem with the variance and covariance matrix. The p-values
251     #           are not correct.")
252     #   k$cov_ok = 2
253     # }
254
255
256     # k$vcov <- vcov
257     # stderror <- sqrt(diag(k$vcov))
258     # k$stderror <- stderror
259
260     return(k)
261   }
262
263   ibetafit<-function(x)
264   {
265
266     n<- length(x) # sample size
267     n0<- sum(x==0) # number of zeros
268     n1<- sum(x==1) # number of ones
269     m<- n0 + n1
270
271     xm0<-x[which(x>0)]
272     x01<-xm0[which(xm0<1)]
273
274     #MV
275     loglik<-function(par)
276     {
277       alpha0<-par[1]
278       alpha1<-par[2]
279       gama<-par[3]
280       phi<-par[4]
281
282       alpha0 = ifelse(n0==0,0,alpha0)
283       alpha1 = ifelse(n1==0,0,alpha1)
284
285       #print(c(alpha0,alpha1,gama,phi))
286
287       c<- 1- alpha0*(1-gama)-alpha1*gama
288       mu<- gama*(1-alpha1)/c
289
290

```

```

291 10 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
292 11 = ifelse( (x == 1), log(alpha1*gama), 0)
293 12 = ifelse(((x == 0) | (x == 1)), 0, log(c))
294 13 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi,
      (1 - mu) * phi, log = TRUE)))
295
296
297 #print("soma")
298 #print(sum(10 + 11 + 12+ 13))
299 sum(10 + 11 + 12+ 13)
300 }
301
302 escore<-function(par)
303 {
304   alpha0<-par[1]
305   alpha1<-par[2]
306   gama<-par[3]
307   phi<-par[4]
308
309   c<- 1- alpha0*(1-gama)-alpha1*gama
310   mu<- (gama*(1-alpha1))/c
311
312   a= mu * phi
313   b = a * (1 - mu)/mu
314
315   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
316   mustar <- digamma(a) - digamma(b)
317
318   Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
319   #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
320   Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar
      -mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
321   Ualpha0 = sum(Ualpha01 + Ualpha03)
322
323   Ualpha0 = ifelse(n0==0,0,Ualpha0)
324
325
326   Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
327   #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
328   Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar
      )*gama*(1-gama)*(1-alpha0))/ (c^2) ) )
329   #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
      digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
330   Ualpha1 = sum(Ualpha11 - Ualpha13)
331
332   Ualpha1 = ifelse(n1==0,0,Ualpha1)
333

```

```

334   Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
335   Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
336   Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*(
        ystar-mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
337
338   Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
339
340   Uphi0 = ifelse( ((x == 0) | (x == 1)),0,
341   #(mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+
        b)-digamma(b))
342   mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
343   )
344   Uphi = sum(Uphi0)
345
346
347   c(Ualpha0,Ualpha1,Ugama,Uphi)
348 }
349
350 # metodo dos momentos para iniciarlizacao
351 x_bar<-mean(x01)
352 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
353
354 p<-x_bar*((x_bar*(1-x_bar))/sigma2_hat)-1)
355 q<-(1-x_bar)*((x_bar*(1-x_bar))/sigma2_hat)-1)
356
357 #print(c(x_bar,sigma2_hat,p,q))
358
359 delta0<- n0/n
360 delta1<- n1/n
361
362 a0<- delta0/(1-x_bar)
363 a1<- delta1/(x_bar)
364
365 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
366 par_ini<-c(a0,a1,p/(p+q),p+q)
367
368 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
369
370 #print("par_ini")
371 #print(par_ini)
372
373 max<-optim(par_ini,loglik,
374   escore,
375   method="BFGS",
376   #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
        (0.99999,0.99999,0.99999,9999999999),
377   control=list(fnscale=-1))

```

```

378
379   if(max$convergence != 0) print("Non-convergence")
380   # return
381   z<-c()
382   z$mv<-max$par
383   #print(z$mv)
384   z$conv<-max$convergence
385   z$loglik <- max$value
386   return(z)
387 }
388
389 iuGAfit <- function(y)
390
391 {
392
393   n <- length(y) # sample size
394   n0 <- sum(y == 0) # number of zeros
395   n1 <- sum(y == 1) # number of ones
396   m <- n0 + n1
397
398   ys01 <- y
399   if(any(y==0)) ys01<- ys01[-which(y==0)]
400   if(any(y==1)) ys01<- ys01[-which(ys01==1)]
401
402   i01 <- (y==0)+(y==1)
403
404   #Maxima verossimilhanca
405
406   loglik <- function (par){
407
408     alpha0 <- par[1]
409     alpha1 <- par[2]
410     gama <- par[3]
411     phi <- par[4]
412
413     alpha0 = ifelse(n0 == 0, 0, alpha0)
414     alpha1 = ifelse(n1 == 0, 0, alpha1)
415
416     c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
417     mu <- gama * (1 - alpha1) / c
418     d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
419
420     l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
421     l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
422     l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
423     l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi)
      )))

```



```

424
425     #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
426
427     sum(l0 + l1 + l2 + l3)
428
429 }
430 escore <- function (par) {
431
432     alpha0 <- par[1]
433     alpha1 <- par[2]
434     gama <- par[3]
435     phi <- par[4]
436
437     alpha0 <- ifelse(n0 == 0, 0, alpha0)
438     alpha1 <- ifelse(n1 == 0, 0, alpha1)
439
440     c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
441     mu <- gama * (1 - alpha1) / c
442     d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
443     ystar <- ifelse(((y == 0) | (y == 1)), 0, log(y))
444     mustar <- ifelse(((y == 0) | (y == 1)), 0, -phi / d)
445
446
447     Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
448     Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 +
449         d) / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1)
450         / (c ^ 2))
451     Ualpha0 <- sum(Ualpha01 + Ualpha03)
452
453     Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
454
455     Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
456     Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d))
457         / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) /
458         (c ^ 2))
459     Ualpha1 <- sum(Ualpha11 + Ualpha13)
460
461     Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
462
463     Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
464     Ugama02 <- ifelse((y == 1), 1 / gama, 0)
465     Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d *
466         (1 + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1)
467         ) / (c ^ 2))
468
469     Ugama <- sum(Ugama01 + Ugama02 + Ugama04)

```

```

465
466   Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(
      mu))/phi - ((d^2) *log(mu)* log(y)) / ((phi^2) * (mu ^ (1 / phi))) -
      digamma(phi) - log(mu^(1/phi)))
467
468   Uphi = sum(Uphi0)
469
470   c(Ualpha0, Ualpha1, Ugama, Uphi)
471 }
472
473 #Inicializacao
474
475 y_bar <- mean(y)
476 y_bar0 <- mean(ys01)
477
478 delta0 <- n0/n
479 delta1 <- n1/n
480
481 a0 <- delta0/(1-y_bar)
482 a1 <- delta1/(y_bar)
483
484 #fit <- vglm(ys01 ~ 1, gamma2)
485 #par<-Coef(fit)
486
487 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
488 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
489 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
490 #phi_til = 5
491 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
492
493 par_ini <- c(a0, a1, y_bar, phi_til)
494
495 max<-optim(par_ini, loglik, escore,method = "BFGS",
496 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
497 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
      (0.99999,0.99999,0.99999,9999999999),
498 control=list(fnscale=-1))
499
500 if(max$convergence != 0) print("Non-convergence")
501 # return
502 z <- c()
503 z$ini <- par_ini
504 z$mv <- max$par
505 z$conv <- max$convergence
506 z$loglik <- max$value
507 return(z)

```

```

508 }
509
510 #dados da aplicacao
511
512 y<-c(0.0193, 1, 0.2758, 0.7458, 1, 0.2185, 0.9853, 0.7473, 0.9885, 0.2561,
513      0.8328, 0.9000, 0.0162, 0.5427, 0.0000, 0.1208, 0.7202, 0.9242, 0.4548,
514      0.8917,
515      0.9478, 0.7091, 0.7137, 0.2797, 0.9475, 0.9940, 0.4273, 0.7106, 0.5896,
516      0.8747,
517      0.9758, 0.7600, 0.0997, 0.7841, 0.0883, 0.2894, 0.4514, 0.5736, 0.7382, 1,
518      0.4992, 0.5043, 0.5363, 0.5318, 0.5932, 0.4457, 0.4916, 0.6633, 0.3491, 1,
519      0.3216, 0.6037)
520
521 #descricao dos dados
522 summary(y)
523 var(y)
524 sd(y)
525 cv<- (sd(y))/(mean(y))
526 cv
527
528 len = length(y)
529 n=len
530 n #52
531 prop.z = sum(ifelse(y==0,1,0))/len
532 prop.z
533 prop.u = sum(ifelse(y==1,1,0))/len
534 prop.u
535 var_y=var(y)
536 media_y=mean(y)
537 media_y
538 var_y
539
540 fitib = ibetafit(y)
541 if (fitib$conv != 0)
542 {
543   cont.ib = cont.ib+1
544 }
545
546 fitik = ikumafit(y)
547 if (fitik$conv != 0)
548 {
549   cont.ik = cont.ik+1
550 }
551
552 fitigu = iuGAfit(y)
553
554 if ((fitigu$conv != 0) ){
555   cont.igu=cont.igu+1

```

```

553     }
554
555     fitib
556     fitik
557     fitigu
558     fitigu$mv
559     #fitigu$mv
560     #[1] 0.06218530 0.00000000 0.06253998 38.97782620
561
562
563     ##logverossimilhanca
564     # Beta inflacionada
565     log.vero_IB = fitib$loglik
566     # Kuma inflacionada
567     log.vero_IK= fitik$loglik
568     # Gamma Unitaria inflacionada
569     log.vero_IUG = fitigu$loglik
570
571     k=4 #inflacionado em zero e um
572
573     #criterios#
574
575     ##AIC##
576     #Beta Inflacionada
577     AIC_IB=-2*fitib$loglik+2*k
578     #Kumaraswamy Inflacionada
579     AIC_IK= -2*fitik$loglik+2*k
580     # Gamma Unitaria inflacionada
581     AIC_IUG = -2*fitigu$loglik+2*k
582
583     ##AICC##
584     #Beta Inflacionada
585     AICC_IB=-2*fitib$loglik + (2*n*k)/(n-k-1)
586     #Kumaraswamy Inflacionada
587     AICC_IK= -2*fitik$loglik + (2*n*k)/(n-k-1)
588     # Gamma Unitaria inflacionada
589     AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1)
590
591     ##BIC##
592     #Beta Inflacionada
593     BIC_IB=-2*fitib$loglik+k*log(n)
594     #Kumaraswamy Inflacionada
595     BIC_IK=-2*fitik$loglik+k*log(n)
596     # Gamma Unitaria inflacionada
597     BIC_IUG=-2*fitigu$loglik+k*log(n)
598
599     ##BICC##

```

```

600 #Beta Inflacionada
601 BICC_IB=-2*fitib$loglik+(n*k*log(n))/(n-k-1)
602 #Kumaraswamy Inflacionada
603 BICC_IK=-2*fitik$loglik+(n*k*log(n))/(n-k-1)
604 # Gamma Unitaria inflacionada
605 BICC_IUG=-2*fitigu$loglik+(n*k*log(n))/(n-k-1)
606
607 ##HQ##
608 #Beta Inflacionada
609 HQ_IB= -2*fitib$loglik + 2*k*log(log(n))
610 #Kumaraswamy Inflacionada
611 HQ_IK= -2*fitik$loglik + 2*k*log(log(n))
612 # Gamma Unitaria inflacionada
613 HQ_IUG= -2*fitigu$loglik + 2*k*log(log(n))
614
615 ##HQC##
616 #Beta Inflacionada
617 HQC_IB= -2*fitib$loglik +(2*n*k*log(log(n)))/(n-k-1)
618 #Kumaraswamy Inflacionada
619 HQC_IK= -2*fitik$loglik +(2*n*k*log(log(n)))/(n-k-1)
620 # Gamma Unitaria inflacionada
621 HQC_IUG= -2*fitigu$loglik +(2*n*k*log(log(n)))/(n-k-1)
622
623 ##testes_hipotese#
624 #Gama Unitaria Inflacionada
625 ks.iuGA = ks.test(y, "pgui",alpha0=fitigu$mv[1],alpha1=fitigu$mv[2],gama=
        fitigu$mv[3], phi=fitigu$mv[4])$p.value
626 ks.iuGA
627
628 library(DescTools)
629 ad.iuGA = AndersonDarlingTest(y, null="pgui",alpha0=fitigu$mv[1], alpha1=
        fitigu$mv[2],gama=fitigu$mv[3], phi=fitigu$mv[4])$p.value
630 ad.iuGA
631
632 cvm.iuGA = cvm.test(y, null="pgui",alpha0=fitigu$mv[1],alpha1=fitigu$mv[2],
        gama=fitigu$mv[3], phi=fitigu$mv[4])$p.value
633 cvm.iuGA
634
635 #nu=p0/p2 tau=p1/p2
636 p0=prop.z
637 p1=prop.u
638 p2=1-p0-p1
639
640 dp=sqrt(1/((fitib$mv[4])+1))
641
642 #Beta Inflacionada
643 ks.iBE = ks.test(y, "pBEINF",mu=fitib$mv[3] , sigma=dp, nu=p0/p2, tau=p1/p2)

```

```

    $p.value
644 ks.iBE
645
646 #library(DescTools)
647 ad.iBE = AndersonDarlingTest(y, null="pBEINF",mu=fitib$mv[3] , sigma=dp, nu=
    p0/p2, tau=p1/p2)$p.value
648 ad.iBE
649
650 cvm.iBE = cvm.test(y, null="pBEINF",mu=fitib$mv[3] , sigma=dp, nu=p0/p2, tau
    =p1/p2)$p.value
651 cvm.iBE
652
653 #Kumaraswamy Iflacionada
654 ks.ikum = ks.test(y, "pikum",lambda=fitik$coef[1], p=fitik$coef[2],omega=
    fitik$coef[3], phi=fitik$coef[4])$p.value
655 ks.ikum
656
657 #library(DescTools)
658 ad.ikum = AndersonDarlingTest(y, null="pikum",lambda=fitik$coef[1], p=fitik$
    coef[2],omega=fitik$coef[3], phi=fitik$coef[4])$p.value
659 ad.ikum
660
661 cvm.ikum = cvm.test(y, null="pikum",lambda=fitik$coef[1], p=fitik$coef[2],
    omega=fitik$coef[3], phi=fitik$coef[4])$p.value
662 cvm.ikum
663 ### Critérios de selecao
664 AIC_IUG
665 AICC_IUG
666 BIC_IUG
667
668 ### p-valores
669 ks.iuGA
670 ad.iuGA
671 cvm.iuGA
672
673 ##resutados
674 #Recebendo Resultados(AIC)
675 result_AIC=cbind(AIC_IB,AIC_IK,AIC_IUG)
676 result_AIC
677 #Recebendo Resultados(AICC)
678 result_AICC=cbind(AICC_IB,AICC_IK,AICC_IUG)
679 result_AICC
680 #Recebendo Resultados(BIC)
681 result_BIC=cbind(BIC_IB,BIC_IK,BIC_IUG)
682 result_BIC
683 #Recebendo Resultados(BICC)
684 result_BICC=cbind(BICC_IB,BICC_IK,BICC_IUG)

```

```

685 result_BICC
686 #Recebendo Resultados(HQ)
687 result_HQ=cbind(HQ_IB,HQ_IK,HQ_IUG)
688 result_HQ
689 #Recebendo Resultados(HQC)
690 result_HQC=cbind(HQC_IB,HQC_IK,HQC_IUG)
691 result_HQC
692
693 cvm.p.valor.iBE = (cvm.iBE)
694
695 ks.p.valor.iBE = (ks.iBE)
696
697 ad.p.valor.iBE = (ad.iBE)
698
699 cvm.p.valor.iuGA = (cvm.iuGA)
700
701 ks.p.valor.iuGA = (ks.iuGA)
702
703 ad.p.valor.iuGA = (ad.iuGA)
704
705 cvm.p.valor.ikum = (cvm.ikum)
706
707 ks.p.valor.ikum = (ks.ikum)
708
709 ad.p.valor.ikum = (ad.ikum)
710
711 result.p.valor.ks = cbind(ks.p.valor.iBE,ks.p.valor.ikum,ks.p.valor.iuGA)
712
713 result.p.valor.ad = cbind(ad.p.valor.iBE,ad.p.valor.ikum,ad.p.valor.iuGA)
714
715 result.p.valor.cvm = cbind(cvm.p.valor.iBE,cvm.p.valor.ikum,cvm.p.valor.iuGA
716 )
717
718 M=rbind( result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,result_HQC
719 ,result.p.valor.ks,
720 result.p.valor.ad,result.p.valor.cvm)
721 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
722 rownames(M) <- c("AIC","AICC","BIC", "BICC","HQ","HQC", "p.valor.ks",
723 "p.valor.ad","p.valor.cvm")
724 glue::glue( "Tamanho amostral: {n}", "\n", "Prob.Zero: {round(prop.z,4)}", "
725 \n", "Prob.Um: {round(prop.u,4)}",
726 "\n", "media: {round(media_y,4)}",
727 "\n", "var: {round(var_y,4)}")
728 print("Resultados")
729 print(M)
730 library(xtable)
731 xtable(M)

```

```

729
730 #nova tabela
731 result.bi=cbind(AIC_IB,AICC_IB,BIC_IB,BICC_IB,HQ_IB,HQC_IB)
732 result.gui=cbind(AIC_IUG,AICC_IUG,BIC_IUG,BICC_IUG,HQ_IUG,HQC_IUG)
733 result.ki=cbind(AIC_IK,AICC_IK,BIC_IK,BICC_IK,HQ_IK,HQC_IK)
734 result.bi
735 result.ki
736 result.gui
737 #nova tabela p_valor
738 result_pvalor_bi=cbind({round(ks.p.valor.iBE,4)},{round(cvm.p.valor.iBE,4)
    },{round(ad.p.valor.iBE,4)})
739 result_pvalor_ki=cbind({round(ks.p.valor.ikum,4)},{round(cvm.p.valor.ikum,4)
    },{round(ad.p.valor.ikum,4)})
740 result_pvalor_gui=cbind({round(ks.p.valor.iuGA,4)},{round(cvm.p.valor.iuGA
    ,4)},{round(ad.p.valor.iuGA,4)})
741 result_pvalor_bi
742 result_pvalor_ki
743 result_pvalor_gui
744
745 #grafico pp plot##
746 set.seed(33)
747 library(stats)
748 par(mfrow=c(1,3))
749 ##grafico da BI
750 dados_teoricos <- rBEINF(n,mu=fitib$mv[3] , sigma=dp, nu=p0/p2, tau=p1/p2)
751 dados_observados <- y
752 xlim=c(0,1)
753 ylim=c(0,1)
754 plot(xlim = c(0,1),ylim = c(0,1),sort(dados_teoricos), sort(dados_observados
    ), main = "Beta Inflacionada", xlab = "", ylab = "")
755 abline(0, 1, col = "black", lty = 1)
756
757 ##grafico da GUI
758 dados_teoricos <- riGU(n,alpha0=fitigu$mv[1],alpha1=fitigu$mv[2],gama=fitigu
    $mv[3], phi=fitigu$mv[4])
759 dados_observados <- y
760 xlim=c(0,1)
761 ylim=c(0,1)
762 plot(xlim = c(0,1),ylim = c(0,1),sort(dados_teoricos), sort(dados_observados
    ), main = "Gama Unitaria Inflacionada", xlab = "", ylab = "")
763 abline(0, 1, col = "black", lty = 1)
764
765 ##grafico da KI
766 dados_teoricos <- rikum(n,lambda=fitik$coef[1], p=fitik$coef[2],omega=fitik$
    coef[3], phi=fitik$coef[4])
767 dados_observados <- y
768 xlim=c(0,1)

```



```

769     ylim=c(0,1)
770     plot(xlim = c(0,1),ylim = c(0,1),sort(dados_teoricos), sort(dados_observados
       ), main = "Kumaraswamy Inflacionada", xlab = "", ylab = "")
771     abline(0, 1, col = "black", lty = 1)
772     dev.off()

```

```

1  ##APLICACAO COM INFLACIONAMENTO EM ZERO e UM ##
2  #Porcentagem da populacao urbana residente em domicilios ligados a rede de
   esgoto sanitario em 2016 no estado do Rio Grande do Norte.
3  #Fonte dos dados: http://www.atlasbrasil.org.br/
4  #dados da aplicacao
5  y<-c( 1, 0.7913, 0.5856, 0.0193, 0, 0.3302, 0.0934, 0.1248, 0.7136, 0.4666,
6  0.5787, 0.8989, 0.7766, 0.4275, 0.9869, 0.3277, 1, 0.2329, 0.9913, 0.3821,
7  0.1131, 0.3597, 0.6715, 0.6107, 0.7127, 0.9976, 0.0501, 0.8636, 0.1316, 0.4896,
8  0.3817, 0.2949, 0.6211, 1, 0.0358, 0.9001, 0.1501, 0.8130, 0.4072, 0.3600,
9  0.9163, 0.9631, 1, 0.1367, 1, 0.2050, 0.0135, 0.3246, 0.7891, 0.2133,
10 0.8845, 0.4994, 1, 1, 0.4557)

```

```

1  ##APLICACAO COM INFLACIONAMENTO EM UM ##
2  #Proporcao de votos para o candidato bolsonaro nas secoes eleitorais da cidade de
   Chaves-PA no segundo turno do ano de 2022.
3  #Fonte dos dados: https://www.tse.jus.br/
4  library(goftest) #ad e cvm
5  source("ikumafit.R")
6  source("iuga_fitv4.R")
7  source("ibetafit.R")
8  source("iuga_v2.R")
9  source("ikum-omega-phi.R")
10 library(gamlss)
11 library(gamlss.dist)
12 library(gamlss.data)
13 library(betareg)
14 library(MASS)
15 library(extraDistr)
16
17 "ikumafit" <- function(y){
18
19   y <- as.vector(y)
20
21   n <- length(y)
22   n0<- sum(y==0) # number of zeros
23   n1<- sum(y==1) # number of ones
24
25   lambda <- (n0+n1)/n # lambda estimator
26   p <- n1/(n0+n1)# p estimator
27
28   u<-1

```

```

29  if(n0 == 0)
30  {
31      p=1
32      u=0
33  }
34
35  if(n1 == 0)
36  {
37      p=0
38      u=0
39  }
40
41  i01 <- (y==0)+(y==1)
42
43  loglik <- function(theta)
44  {
45      omega <- theta[1]
46      phi <- theta[2]
47
48      l2 = 0
49      if(u!=0)
50      {
51          l2a = ifelse((y == 1), log(p), 0)
52          l2b = ifelse((y == 0), log(1-p), 0)
53          l2 = l2a + l2b
54      }
55
56      l1 = ifelse((i01 == 1), log(lambda), log(1-lambda))
57
58      l3 = ifelse((i01 == 1), 0,
59      log(phi)+
60      log(log(0.5)/log(1-omega^phi))+
61      (phi-1)*log(y)+
62      ( (log(0.5)/log(1-omega^phi))-1)*log(1-y^phi)
63      )
64
65      sum(l1 + l2 + l3)
66  }
67
68  escore <- function(theta)
69  {
70      omega <- theta[1]
71      phi <- theta[2]
72
73      delta = log(0.5)/log(1-omega^phi)
74      ci = ((omega^(phi-1))/((1-omega^phi)*log(1-omega^phi)))*(delta*log(1-y^phi)
+1)

```

```

75
76 c = ifelse((y == 0), 0, ci)
77 c = ifelse((y == 1), 0, c)
78
79 Uomega <- phi*sum(c)
80
81 v = ifelse((y == 0), 0, 1/phi + log(y) + ci*omega*log(omega) -
82 (delta-1)*((y^phi)*log(y)/(1-y^phi)))
83 v = ifelse((y == 1), 0, v)
84
85 Uphi <- sum(v)
86
87 derivada=c(Uomega,Uphi)
88 derivada
89 }
90
91 ### initial values
92 ys01<- y
93 if(any(y==0)) ys01<- ys01[-which(y==0)]
94 if(any(y==1)) ys01<- ys01[-which(ys01==1)]
95
96 # fit <- vglm(ys01 ~ 1, kumar)
97 # par<-Coef(fit)
98
99 phi <- 5 #par[1]
100 omega <- median(ys01)# (1-0.5^(1/par[2]))^(1/phi)
101
102 #print(c(lambda,p,omega,phi))
103 ini <- c(omega,phi)
104
105 opt <- optim(ini, loglik, escore, # hessian = T,
106 method = "BFGS", control = list(fnscale = -1)) # , maxit = 500, reltol = 1e-9))
107
108 # opt <- optim(ini, loglik, escore,
109 # method = "L-BFGS-B", control = list(fnscale = -1),#, maxit = 500, reltol = 1e
110 # # lower = c(rep(-.Machine$double.xmax, r),.Machine$double.eps,.Machine$double
111 # # upper = rep(.Machine$double.xmax,(r+2))
112 # lower = c(rep(-.Machine$double.xmax, r),1.0,0.001),
113 # upper = rep(.Machine$double.xmax,(r+2))
114 # )
115
116 # opt <- optim(ini, loglik, escore)
117
118 # print(opt$par)
119

```

```

120 # print(names(opt))
121 # print(summary(opt) )
122 # print(summary(opt)[1:6] )
123 # print(opt$kkt1)
124
125
126 if (opt$conv != 0)
127 warning("FUNCTION DID NOT CONVERGE!")
128
129 k <- c()
130
131 # print("AQUI1")
132 # print(gradient(escore, opt$par))
133
134 coef <- c(lambda,p,opt$par)
135 # coef <- as.numeric(summary(opt)[1:(m+u+r+s)]) # opt$par
136 # print(coef)
137 k$coef <- coef
138 k$conv <- opt$conv
139 k$loglik <- opt$value
140 k$counts <- as.numeric(opt$counts[1])
141
142 # library(rootSolve)
143 # library(numDeriv)
144 # escores<-rbind(
145 #   escore(coef),
146 #   gradient(loglik, coef),
147 #   grad(loglik, coef))
148 # print(round(escores,5))
149
150 # k$Knum<-gradient(escore, coef)
151
152 # print(k$Knum)
153 # k$Knum<-hessian(escore, coef, method="complex")
154 # print(k$Knum)
155
156
157 # # Expected information matrix
158 #
159 # T1 = diag(as.vector( 1/diflink1(k$lambda) ))
160 # T3 = diag(as.vector( 1/diflink3(k$omega) ))
161 # T4 = diag(as.vector( 1/diflink4(k$phi) ))
162 #
163 # h1 <- k$omega^(k$phi-2)/ ((1-k$omega^k$phi)*log(1-k$omega^k$phi))
164 # h2 <- k$omega^(2*k$phi-2)/ ((1-k$omega^k$phi)^(2)*log(1-k$omega^k$phi)^(2))
165 # delta <- log(0.5)/log(1-k$omega^k$phi)
166 #

```

```

167 # kapa<- 0.5772156649
168 # k0<- (pi^2)/6+kapa^2-2*kapa
169 #
170 # ci = ((k$omega^(k$phi-1))/((1-k$omega^k$phi)*log(1-k$omega^k$phi)))*(delta*
      log(1-y^k$phi)+1)
171 #
172 # b1 <- delta*k$omega^2*h2*log(k$omega)^2*log(1-y^k$phi)
173 # b2 <- 2*delta*k$omega^2*log(k$omega)*h1*((y^k$phi * log(y))/(1-y^k$phi))
174 # b3 <- (delta -1)*((y^k$phi * log(y)^2)/((1-y^k$phi)^2))
175 # b4 <- (ci*k$omega*log(k$omega)^2)*(h1*k$omega^2+ 1/(1-k$omega^k$phi))
176 #
177 # b1 <- as.vector(-1/(k$phi^2) + b1 - b2 - b3 + b4)
178 #
179 # si <- ifelse((i01 == 1),0,b1)# (1-k$lambda)*(b)
180 #
181 # # b2 = -(-1/(k$phi^2) - (k$omega^2)*h2*log(k$omega)^2 -
182 # # 2*delta*k$omega^2*log(k$omega)*h1*((1-digamma(delta+1)-kapa)/((delta-1)*k$
      phi)) -
183 # # (digamma(delta)*(digamma(delta)+2*(kapa-1))-trigamma(delta)+k0)/((delta-2)*
      k$phi^3))
184 # #
185 # # si <- (1-k$lambda)*(b2) # ifelse(y==c,0,b2) #
186 #
187 # mi = (k$lambda-1)*k$phi*k$omega*(log(k$omega)*h2+delta*h1*((1-digamma(delta
      +1)-kapa)/((delta-1)*k$phi)) )
188 #
189 # L = diag(-1/(k$lambda*(1-k$lambda)))
190 # V = diag((k$lambda-1)*k$phi^2*h2)
191 # M = diag(mi)
192 # S = diag(si)
193 #
194 #
195 # Igg = -t(z1) %*% L %*% (T1^2) %*% z1
196 # Ibb = -t(x1) %*% V %*% (T3^2) %*% x1
197 # Ibs = -t(x1) %*% T3 %*% M %*% T4 %*% q1
198 # Isb = t(Ibs)
199 # Iss = -t(q1) %*% S %*% (T4^2) %*% q1
200 #
201 # if(u!=0)
202 # {
203 #   k$pi <- as.vector(coef[(m+1):(m+u)])
204 #   eta_hat2 <- as.vector(w1%*%k$pi)
205 #   k$p <- as.vector(linkinv2(eta_hat2))
206 #   T2 = diag(as.vector( 1/diflink2(k$p) ))
207 #   P = diag(-k$lambda/(k$p*(1-k$p)))
208 #   Ipp = -t(w1) %*% P %*% (T2^2) %*% w1
209 #

```

```

210 # I <- rbind(
211 # cbind(Igg,matrix(0,nrow=m,ncol=u),matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,
212 # ncol=s)),
213 # cbind(matrix(0,nrow=u,ncol=m),Ipp,matrix(0,nrow=u,ncol=r),matrix(0,nrow=u,
214 # ncol=s)),
215 # cbind(matrix(0,nrow=r,ncol=m),matrix(0,nrow=r,ncol=u),Ibb,Ibs),
216 # cbind(matrix(0,nrow=s,ncol=m),matrix(0,nrow=s,ncol=u),Isb,Iss)
217 # )
218 # }else{
219 # I <- rbind(
220 # cbind(Igg,matrix(0,nrow=m,ncol=r),matrix(0,nrow=m,ncol=s)),
221 # cbind(matrix(0,nrow=r,ncol=m),Ibb,Ibs),
222 # cbind(matrix(0,nrow=s,ncol=m),Isb,Iss)
223 # )
224 # }
225 # k$I <- I
226 #
227 #
228 # #####
229 #
230 # # print(-k$Knum)
231 # # print(k$I)
232 #
233 # # vcov <- try(solve(-k$Knum))
234 # vcov <- try(solve(k$I))
235 # # vcov <- chol2inv(chol(k$I))
236 # #vcov <- K #somente para nao trancar simulacao
237 #
238 # k$cov_ok = 0
239 # if (class(vcov) == "try-error")
240 # {
241 # vcov <- try(solve(-k$Knum)) # it use numeric hessian if we have problems
242 # with inversion
243 # k$cov_ok = 1
244 #
245 # if (class(vcov) == "try-error") #
246 # {
247 # vcov <- k$Knum^2
248 # warning("Problem with the variance and covariance matrix. The p-values
249 # are not correct.")
250 # k$cov_ok = 2
251 # }
252 # }

```

```

253 # k$vcov <- vcov
254 # stderror <- sqrt(diag(k$vcov))
255 # k$stderror <- stderror
256
257 return(k)
258 }
259
260 ibetafit<-function(x)
261 {
262
263   n<- length(x) # sample size
264   n0<- sum(x==0) # number of zeros
265   n1<- sum(x==1) # number of ones
266   m<- n0 + n1
267
268   xm0<-x[which(x>0)]
269   x01<-xm0[which(xm0<1)]
270
271   #MV
272   loglik<-function(par)
273   {
274     alpha0<-par[1]
275     alpha1<-par[2]
276     gama<-par[3]
277     phi<-par[4]
278
279     alpha0 = ifelse(n0==0,0,alpha0)
280     alpha1 = ifelse(n1==0,0,alpha1)
281
282     #print(c(alpha0,alpha1,gama,phi))
283
284     c<- 1- alpha0*(1-gama)-alpha1*gama
285     mu<- gama*(1-alpha1)/c
286
287
288     l0 = ifelse( (x == 0), log(alpha0*(1-gama)), 0)
289     l1 = ifelse( (x == 1), log(alpha1*gama), 0)
290     l2 = ifelse(((x == 0) | (x == 1)), 0, log(c))
291     l3 = ifelse(((x == 0) | (x == 1)), 0, suppressWarnings(dbeta(x, mu * phi, (1
      - mu) * phi, log = TRUE)))
292
293
294     #print("soma")
295     #print(sum(l0 + l1 + l2+ l3))
296     sum(l0 + l1 + l2+ l3)
297   }
298

```

```

299 escore<-function(par)
300 {
301   alpha0<-par[1]
302   alpha1<-par[2]
303   gama<-par[3]
304   phi<-par[4]
305
306   c<- 1- alpha0*(1-gama)-alpha1*gama
307   mu<- (gama*(1-alpha1))/c
308
309   a= mu * phi
310   b = a * (1 - mu)/mu
311
312   ystar <- ifelse( ((x == 0) | (x == 1)), 0, log(x01/(1-x01)) )
313   mustar <- digamma(a) - digamma(b)
314
315   Ualpha01 = ifelse((x == 0), (1/alpha0), 0)
316   #Ualpha02 = ifelse( (x == 1) ,((1-gama)/c) ,0)
317   Ualpha03 = ifelse( ((x == 0) | (x == 1)), 0, -((1-gama)/c) + ((phi*( ystar-
318     mustar )*gama*(1-gama)*(1-alpha1))/ (c^2) ) )
319   Ualpha0 = sum(Ualpha01 + Ualpha03)
320
321   Ualpha0 = ifelse(n0==0,0,Ualpha0)
322
323   Ualpha11 = ifelse((x == 1), (1/alpha1), 0)
324   #Ualpha12 = ifelse( (x == 1) , (gama/c) ,0)
325   Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (gama/c) + ((phi*(ystar-mustar)*
326     gama*(1-gama)*(1-alpha0))/ (c^2) ) )
327   #Ualpha13 = ifelse( ((x == 0) | (x == 1)),0, (phi*(log(x01)-log(1-x01)-
328     digamma(a)+digamma(b))*gama*(1-gama)*(1-alpha0))/c^2)
329   Ualpha1 = sum(Ualpha11 - Ualpha13)
330
331   Ualpha1 = ifelse(n1==0,0,Ualpha1)
332
333   Ugama01 = ifelse((x == 0), (1/(1-gama)), 0)
334   Ugama02 = ifelse( (x == 1) ,(1/gama) ,0)
335   Ugama04 = ifelse( ((x == 0) | (x == 1)), 0, (alpha0-alpha1)/c +(phi*( ystar-
336     mustar )*(1-alpha0)*(1-alpha1)/ (c^2)))
337
338   Ugama = sum(-Ugama01 + Ugama02 + Ugama04)
339
340   Uphio = ifelse( ((x == 0) | (x == 1)),0,
341     #(mu * (log(x01)-log(1-x01)-digamma(a)+digamma(b)) + log(1-x01)+digamma(a+b)-
342       digamma(b))
343     mu*(ystar-mustar) + digamma(phi) + log(1-x01) - digamma( (1-mu)*phi )
344   )

```



```

341     Uphi = sum(Uphi0)
342
343
344     c(Ualpha0,Ualpha1,Ugama,Uphi)
345 }
346
347 # metodo dos momentos para iniciarlizacao
348 x_bar<-mean(x01)
349 sigma2_hat<-(1/(n-m-1))*sum((x01-x_bar)^2)
350
351 p<-x_bar*((x_bar*(1-x_bar))/sigma2_hat)-1)
352 q<-(1-x_bar)*((x_bar*(1-x_bar))/sigma2_hat)-1)
353
354 #print(c(x_bar,sigma2_hat,p,q))
355
356 delta0<- n0/n
357 delta1<- n1/n
358
359 a0<- delta0/(1-x_bar)
360 a1<- delta1/(x_bar)
361
362 #par_ini<-c(a0+0.05,a1+0.05,p/(p+q)+0.1,p+q)
363 par_ini<-c(a0,a1,p/(p+q),p+q)
364
365 #par_ini<-c(a0,a1,delta1+(1-delta0-delta1)*(p/(p+q)),p+q)
366
367 #print("par_ini")
368 #print(par_ini)
369
370 max<-optim(par_ini,loglik,
371     escore,
372     method="BFGS",
373     #method="L-BFGS-B", lower = rep(0.00001,4), upper = c
374         (0.99999,0.99999,0.99999,9999999999),
375     control=list(fnscale=-1))
376
377 if(max$convergence != 0) print("Non-convergence")
378 # return
379 z<-c()
380 z$mv<-max$par
381 #print(z$mv)
382 z$conv<-max$convergence
383 z$loglik <- max$value
384 return(z)
385 }
386 iuGAfit <- function(y)

```

```

387
388 {
389
390   n <- length(y) # sample size
391   n0 <- sum(y == 0) # number of zeros
392   n1 <- sum(y == 1) # number of ones
393   m <- n0 + n1
394
395   ys01 <- y
396   if(any(y==0)) ys01<- ys01[-which(y==0)]
397   if(any(y==1)) ys01<- ys01[-which(ys01==1)]
398
399   i01 <- (y==0)+(y==1)
400
401   #Maxima verossimilhanca
402
403   loglik <- function (par){
404
405     alpha0 <- par[1]
406     alpha1 <- par[2]
407     gama <- par[3]
408     phi <- par[4]
409
410     alpha0 = ifelse(n0 == 0, 0, alpha0)
411     alpha1 = ifelse(n1 == 0, 0, alpha1)
412
413     c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
414     mu <- gama * (1 - alpha1) / c
415     d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
416
417     l0 <- ifelse((y == 0), log(alpha0 * (1-gama)), 0)
418     l1 <- ifelse((y == 1), log(alpha1 * gama), 0)
419     l2 <- ifelse(((y == 0) | (y == 1)), 0, log(c))
420     l3 <- ifelse(((y == 0) | (y == 1)), 0, suppressWarnings(log(dGU(y, mu, phi))))
421
422     #phi*log(d)-log(gamma(phi))+(d-1)*log(y)+(phi-1)*log(log(1/y))
423
424     sum(l0 + l1 + l2 + l3)
425
426   }
427   escore <- function (par) {
428
429     alpha0 <- par[1]
430     alpha1 <- par[2]
431     gama <- par[3]
432     phi <- par[4]
433

```

```

434 alpha0 <- ifelse(n0 == 0, 0, alpha0)
435 alpha1 <- ifelse(n1 == 0, 0, alpha1)
436
437 c <- 1 - alpha0 * (1 - gama) - alpha1 * gama
438 mu <- gama * (1 - alpha1) / c
439 d <- (mu ^ (1 / phi)) / (1 - mu ^ (1 / phi))
440 ystar <- ifelse((y == 0) | (y == 1), 0, log(y))
441 mustar <- ifelse((y == 0) | (y == 1), 0, -phi / d)
442
443
444 Ualpha01 <- ifelse((y == 0), 1 / alpha0, 0)
445 Ualpha03 <- ifelse(((y == 0) | (y == 1)), 0, - (1 - gama) / c + (d * (1 + d)
    / (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha1) / (c
    ^ 2))
446 Ualpha0 <- sum(Ualpha01 + Ualpha03)
447
448 Ualpha0 = ifelse(n0 == 0, 0, Ualpha0)
449
450 Ualpha11 <- ifelse((y == 1), 1 / alpha1, 0)
451 Ualpha13 <- ifelse(((y == 0) | (y == 1)), 0, - (gama / c) - ((d * (1 + d)) /
    (mu * phi)) * (ystar - mustar) * gama * (1 - gama) * (1 - alpha0) / (c ^
    2))
452 Ualpha1 <- sum(Ualpha11 + Ualpha13)
453
454 Ualpha1 <- ifelse(n1 == 0, 0, Ualpha1)
455
456
457 Ugama01 <- ifelse((y == 0), -1 / (1 - gama), 0)
458 Ugama02 <- ifelse((y == 1), 1 / gama, 0)
459 Ugama04 <- ifelse(((y == 0) | (y == 1)), 0, (alpha0 - alpha1) / c + ((d * (1
    + d)) / (mu * phi)) * (ystar - mustar) * (1 - alpha0) * (1 - alpha1) / (c
    ^ 2))
460
461 Ugama <- sum(Ugama01 + Ugama02 + Ugama04)
462
463 Uphi0 <- ifelse(((y == 0) | (y == 1)), 0, log(-log(y)) + log(d) - (d*log(mu))
    / phi - ((d^2) * log(mu) * log(y)) / ((phi^2) * (mu ^ (1 / phi))) - digamma(
    phi) - log(mu^(1/phi)))
464
465 Uphi = sum(Uphi0)
466
467
468 c(Ualpha0, Ualpha1, Ugama, Uphi)
469 }
470
471 #Inicializacao
472

```

```

473 y_bar <- mean(y)
474 y_bar0 <- mean(ys01)
475
476 delta0 <- n0/n
477 delta1 <- n1/n
478
479 a0 <- delta0/(1-y_bar)
480 a1 <- delta1/(y_bar)
481
482 #fit <- vglm(ys01 ~ 1, gamma2)
483 #par<-Coef(fit)
484
485 #mu <- (y_bar*(1-a1))/(1-a0*(1-y_bar)-a1*y_bar)
486 #phi_til <- -mean(log(ys01))*(mu/(1 - mu))
487 #phi_til <- -(log(mean(ys01)))*(y_bar0^{1/phi0})/(1 - y_bar0^{1/phi0})
488 #phi_til = 5
489 phi_til <- (y_bar0/(1 - y_bar0))*sum(-log(ys01)/(n-m))
490
491 par_ini <- c(a0, a1, y_bar, phi_til)
492
493 max<-optim(par_ini, loglik, escore,method = "BFGS",
494 #method="Nelder-Mead",#lower = rep(0.00001,4), upper = c
495 (0.99999,0.99999,0.99999,9999999999),
496 #method="L-BFGS-B",lower = rep(0.00001,4), upper = c
497 (0.99999,0.99999,0.99999,9999999999),
498 control=list(fnscale=-1))
499
500 if(max$convergence != 0) print("Non-convergence")
501 # return
502 z <- c()
503 z$ini <- par_ini
504 z$mv <- max$par
505 z$conv <- max$convergence
506 z$loglik <- max$value
507 return(z)
508 }
509
510 #dados da aplicacao
511 y<-c(0.4148, 0.3750, 0.1935, 0.0833, 0.5059, 0.5208, 0.4180, 0.1676, 0.1829,
512 0.3355, 0.2118, 0.2571, 0.2571, 0.2338, 0.1096, 0.1271, 0.1964, 0.1569,
513 0.2055, 0.4052, 0.2697, 0.4379, 0.1100, 0.2749, 0.5947, 0.2013, 0.3317,
514 0.3239, 0.3830, 0.1579, 0.2889, 0.3252, 0.1770, 0.8485, 0.7877, 1 ,
515 0.3950, 0.2980, 0.2533, 0.6238, 0.1633, 0.4056, 0.1631, 0.1622, 0.4534,
516 0.2136, 0.1250, 0.4417, 0.4685, 0.1477, 0.2697, 0.4045, 0.4956 )
517
518 #descricao dos dados
519 summary(y)
520 var(y)

```

```

518 sd(y)
519 cv<- (sd(y))/(mean(y))
520 cv
521
522 len = length(y)
523 n=len
524 n #n=53
525 prop.z = sum(ifelse(y==0,1,0))/len
526 prop.z
527 prop.u = sum(ifelse(y==1,1,0))/len
528 prop.u
529 var_y=var(y)
530 media_y=mean(y)
531 media_y
532 var_y
533
534 fitib = ibetafit(y)
535 if (fitib$conv != 0)
536 {
537   cont.ib = cont.ib+1
538 }
539
540 fitik = ikumafit(y)
541 if (fitik$conv != 0)
542 {
543   cont.ik = cont.ik+1
544 }
545
546 fitigu = iuGAfit(y)
547
548 if ((fitigu$conv != 0) ){
549   cont.igu=cont.igu+1
550 }
551
552 fitib
553 fitik
554 fitigu
555 fitigu$mv
556
557 ##logverossimilhanca
558 log.vero_IB = fitib$loglik #BI
559 log.vero_IK= fitik$loglik #KI
560 log.vero_IUG = fitigu$loglik #GUI
561
562 k=3 #inflacionado em um
563
564 #criterios#

```

```

565 ##AIC##
566 AIC_IB=-2*fitib$loglik+2*k #BI(Beta Inflacionada)
567 AIC_IK= -2*fitik$loglik+2*k #KI(Kumaraswamy Inflacionada)
568 AIC_IUG = -2*fitigu$loglik+2*k #GUI(Gama Unitaria Inflacionada)
569
570 ##AICC##
571 AICC_IB=-2*fitib$loglik + (2*n*k)/(n-k-1) #BI
572 AICC_IK= -2*fitik$loglik + (2*n*k)/(n-k-1) #KI
573 AICC_IUG=-2*fitigu$loglik+(2*n*k)/(n-k-1) #GUI
574
575 ##BIC##
576 BIC_IB=-2*fitib$loglik+k*log(n) #BI
577 BIC_IK=-2*fitik$loglik+k*log(n) #KI
578 BIC_IUG=-2*fitigu$loglik+k*log(n) #GUI
579
580 ##BICC##
581 BICC_IB=-2*fitib$loglik+(n*k*log(n))/(n-k-1) #BI
582 BICC_IK=-2*fitik$loglik+(n*k*log(n))/(n-k-1) #KI
583 BICC_IUG=-2*fitigu$loglik+(n*k*log(n))/(n-k-1) #GUI
584
585 ##HQ##
586 HQ_IB= -2*fitib$loglik + 2*k*log(log(n)) #BI
587 HQ_IK= -2*fitik$loglik + 2*k*log(log(n)) #KI
588 HQ_IUG= -2*fitigu$loglik + 2*k*log(log(n)) #GUI
589
590 ##HQC##
591 HQC_IB= -2*fitib$loglik +(2*n*k*log(log(n)))/(n-k-1) #BI
592 HQC_IK= -2*fitik$loglik +(2*n*k*log(log(n)))/(n-k-1) #KI
593 HQC_IUG= -2*fitigu$loglik +(2*n*k*log(log(n)))/(n-k-1) #GUI
594
595
596 ##testes_hipotese#
597 #Gama Unitaria Inflacionada
598 ks.iuGA = ks.test(y, "pgui",alpha0=fitigu$mv[1],alpha1=fitigu$mv[2],gama=fitigu$
    mv[3], phi=fitigu$mv[4])$p.value
599 ks.iuGA
600
601 library(DescTools)
602 ad.iuGA = AndersonDarlingTest(y, null="pgui",alpha0=fitigu$mv[1], alpha1=fitigu$
    mv[2],gama=fitigu$mv[3], phi=fitigu$mv[4])$p.value
603 ad.iuGA
604
605 cvm.iuGA = cvm.test(y, null="pgui",alpha0=fitigu$mv[1],alpha1=fitigu$mv[2], gama=
    fitigu$mv[3], phi=fitigu$mv[4])$p.value
606 cvm.iuGA
607
608 #nu=p0/p2 tau=p1/p2

```

```

609 p0=prop.z
610 p1=prop.u
611 p2=1-p0-p1
612
613 dp=sqrt(1/((fitib$mv[4])+1))
614
615 #Beta Inflacionada
616 ks.iBE = ks.test(y, "pBEINF1",mu=fitib$mv[3] , sigma=dp, nu=p1/p2)$p.value
617 ks.iBE
618
619 #library(DescTools)
620 ad.iBE = AndersonDarlingTest(y, null="pBEINF1",mu=fitib$mv[3] , sigma=dp, nu=p1/
    p2)$p.value
621 ad.iBE
622
623 cvm.iBE = cvm.test(y, null="pBEINF1",mu=fitib$mv[3] , sigma=dp, nu=p1/p2)$p.value
624 cvm.iBE
625
626 #Kumaraswamy Inflacionada
627 ks.ikum = ks.test(y, "pikum",lambda=fitik$coef[1], p=fitik$coef[2],omega=fitik$
    coef[3], phi=fitik$coef[4])$p.value
628 ks.ikum
629
630 #library(DescTools)
631 ad.ikum = AndersonDarlingTest(y, null="pikum",lambda=fitik$coef[1], p=fitik$coef
    [2],omega=fitik$coef[3], phi=fitik$coef[4])$p.value
632 ad.ikum
633
634 cvm.ikum = cvm.test(y, null="pikum",lambda=fitik$coef[1], p=fitik$coef[2],omega=
    fitik$coef[3], phi=fitik$coef[4])$p.value
635 cvm.ikum
636 ### Criterios de selecao
637 AIC_IUG
638 AICC_IUG
639 BIC_IUG
640
641 ### p-valores
642 ks.iuGA
643 ad.iuGA
644 cvm.iuGA
645
646 ##resutados
647 #Recebendo Resultados(AIC)
648 result_AIC=cbind(AIC_IB,AIC_IK,AIC_IUG)
649 result_AIC
650 #Recebendo Resultados(AICC)
651 result_AICC=cbind(AICC_IB,AICC_IK,AICC_IUG)

```

```

652 result_AICC
653 #Recebendo Resultados(BIC)
654 result_BIC=cbind(BIC_IB,BIC_IK,BIC_IUG)
655 result_BIC
656 #Recebendo Resultados(BICC)
657 result_BICC=cbind(BICC_IB,BICC_IK,BICC_IUG)
658 result_BICC
659 #Recebendo Resultados(HQ)
660 result_HQ=cbind(HQ_IB,HQ_IK,HQ_IUG)
661 result_HQ
662 #Recebendo Resultados(HQC)
663 result_HQC=cbind(HQC_IB,HQC_IK,HQC_IUG)
664 result_HQC
665
666 cvm.p.valor.iBE = (cvm.iBE)
667 ks.p.valor.iBE = (ks.iBE)
668 ad.p.valor.iBE = (ad.iBE)
669 cvm.p.valor.iuGA = (cvm.iuGA)
670 ks.p.valor.iuGA = (ks.iuGA)
671 ad.p.valor.iuGA = (ad.iuGA)
672 cvm.p.valor.ikum = (cvm.ikum)
673 ks.p.valor.ikum = (ks.ikum)
674 ad.p.valor.ikum = (ad.ikum)
675
676 result.p.valor.ks = cbind(ks.p.valor.iBE,ks.p.valor.ikum,ks.p.valor.iuGA)
677 result.p.valor.ad = cbind(ad.p.valor.iBE,ad.p.valor.ikum,ad.p.valor.iuGA)
678 result.p.valor.cvm = cbind(cvm.p.valor.iBE,cvm.p.valor.ikum,cvm.p.valor.iuGA)
679
680 M=rbind( result_AIC,result_AICC,result_BIC, result_BICC,result_HQ,result_HQC,
        result.p.valor.ks,
681 result.p.valor.ad,result.p.valor.cvm)
682 colnames(M) <- c("BIm.I","Kuma.I","GU.I")
683 rownames(M) <- c("AIC","AICC","BIC", "BICC","HQ", "HQC", "p.valor.ks",
684 "p.valor.ad","p.valor.cvm")
685 glue::glue( "Tamanho amostral: {n}", "\n", "Prob.Zero: {round(prop.z,4)}", "\n",
        "Prob.Um: {round(prop.u,4)}",
686 "\n", "media: {round(media_y,4)}",
687 "\n", "var: {round(var_y,4)}")
688 print("Resultados")
689 print(M)
690 library(xtable)
691 xtable(M)
692
693 #NOVA TABELA
694 result.bi=cbind(AIC_IB,AICC_IB,BIC_IB,BICC_IB,HQ_IB,HQC_IB)
695 result.gui=cbind(AIC_IUG,AICC_IUG,BIC_IUG,BICC_IUG,HQ_IUG,HQC_IUG)
696 result.ki=cbind(AIC_IK,AICC_IK,BIC_IK,BICC_IK,HQ_IK,HQC_IK)

```



```

697 result.bi
698 result.ki
699 result.gui
700 #nova tabela p_valor
701 result_pvalor_bi=cbind({round(ks.p.valor.iBE,4)},{round(cvm.p.valor.iBE,4)},{
      round(ad.p.valor.iBE,4)})
702 result_pvalor_ki=cbind({round(ks.p.valor.ikum,4)},{round(cvm.p.valor.ikum,4)},{
      round(ad.p.valor.ikum,4)})
703 result_pvalor_gui=cbind({round(ks.p.valor.iuGA,4)},{round(cvm.p.valor.iuGA,4)},{
      round(ad.p.valor.iuGA,4)})
704 result_pvalor_bi
705 result_pvalor_ki
706 result_pvalor_gui
707
708 #grafico pp plot##
709 set.seed(33)
710 library(stats)
711 par(mfrow=c(1,3))
712 ##grafico da BI
713 dados_teoricos <- rBEINF1(n,mu=fitib$mv[3] , sigma=dp, nu=p1/p2)
714 dados_observados <- y
715 plot(xlim = c(0,1), ylim = c(0,1),sort(dados_teoricos), sort(dados_observados),
      main = "BI(0,1)", xlab = "", ylab = "")
716 abline(0, 1, col = "black", lty = 1)
717
718 ##grafico da GUI
719 dados_teoricos <- riGU(n,alpha0=fitigu$mv[1],alpha1=fitigu$mv[2],gama=fitigu$mv
      [3], phi=fitigu$mv[4])
720 dados_observados <- y
721 plot(xlim = c(0,1), ylim = c(0,1),sort(dados_teoricos), sort(dados_observados),
      main = "GUI(0,1)", xlab = "", ylab = "")
722 abline(0, 1, col = "black", lty = 1)
723
724 ##grafico da KI
725 dados_teoricos <- rikum(n,lambda=fitik$coef[1], p=fitik$coef[2],omega=fitik$coef
      [3], phi=fitik$coef[4])
726 dados_observados <- y
727 plot(xlim = c(0,1), ylim = c(0,1),sort(dados_teoricos), sort(dados_observados),
      main = "KI(0,1)", xlab = "", ylab = "")
728
729 abline(0, 1, col = "black", lty = 1)
730 dev.off()

```

```

1  ##APLICACAO COM INFLACIONAMENTO EM UM ##
2  #Porcentagem de pessoas que reside em domicilio com acesso a energia eletrica
   no estado de santa catarina em 1991.
3  #Fonte dos dados: http://www.atlasbrasil.org.br/

```

```

4 #dados da aplicacao
5 y<-c(0.7218, 0.7738, 0.9557, 1, 0.9050, 0.8172, 0.9098, 0.9591, 0.9126, 0.9205,
6 0.7855, 0.9629, 0.4889, 0.8660, 0.9647, 0.9146, 0.9615, 0.9359, 0.9966, 1,
7 0.9810, 0.8235, 0.9818, 0.9869, 0.9950, 0.9663, 0.8925, 0.9963, 0.9767, 0.9677,
8 0.7782, 0.7497, 0.9418, 0.5249, 0.7767, 0.9861, 0.9938, 0.9993, 0.6707, 0.9886,
9 0.8288, 0.8421, 0.8168, 0.8635, 0.9985, 1, 0.9629, 0.3960, 0.9971, 0.9594,
10 0.9380, 0.4700, 0.9870, 0.9416, 0.5865, 0.7133, 0.8573, 0.9910, 0.8929, 0.6362,
11 0.9508, 0.9995, 0.9384, 0.8497, 0.6036, 0.3570, 0.9485, 0.9119, 1, 0.9625,
12 0.9122, 0.9182, 0.5836, 0.8621, 0.9769, 0.9963, 0.9222, 0.9361, 0.9344, 0.9250,
13 0.6623, 0.9497, 0.9637, 0.5034, 0.9952, 0.9471, 0.8561, 0.7231, 0.9953, 0.8936,
14 0.9969, 0.9317, 0.8239, 0.8329, 0.9888, 0.8353, 0.9932, 0.9953, 0.9424, 0.9940,
15 0.9944, 0.9083, 0.9851, 0.8754, 0.8220, 0.9729, 0.9011, 0.9665, 0.9694, 0.9981,
16 0.9931, 0.9710, 0.9901, 0.9656, 0.9949, 1, 0.9229, 0.9031, 0.6691, 0.8672,
17 0.8864, 0.8749, 0.6938, 0.7463, 0.7860, 0.9959, 0.9894, 0.9331, 0.8216, 0.9142,
18 0.9885, 0.9302, 0.9716, 0.9991, 0.9913, 0.6947, 0.9880, 0.9887, 0.8810, 0.7111,
19 0.9835, 0.9714, 0.9902, 0.9663, 0.9997, 0.9933, 0.6392, 0.9194, 0.8543, 0.9905,
20 0.9926, 0.9757, 0.7486, 0.9089, 0.9809, 0.6080, 0.9801, 0.9104, 0.8473, 0.9821,
21 0.7044, 0.9983, 0.8491, 0.8978, 0.8434, 0.9027, 0.6664, 1, 0.9967, 0.9827,
22 0.8957, 0.8729, 0.9679, 0.9887, 0.8726, 0.9911, 0.9316, 0.9716, 0.8363, 0.7689,
23 0.5986, 0.9874, 0.7826, 0.5986, 0.9091, 0.7500, 0.8308, 0.9475, 0.7617, 0.9834,
24 0.9931, 0.9928, 0.9587, 0.9469, 0.8984, 0.9981, 0.8344, 0.8036, 0.9950, 0.7068,
25 0.8387, 0.8263, 0.9895, 0.9136, 0.9695, 0.9526, 0.9778, 0.9959, 0.9330, 0.7353,
26 0.8015, 0.9864, 0.9092, 0.8893, 0.9931, 0.9805, 0.9989, 1, 0.9581, 0.7934,
27 0.7615, 0.9936, 0.7685, 0.9850, 0.5721, 0.9354, 0.9980, 0.8374, 0.8770, 0.9383,
28 0.9785, 0.5683, 0.6935, 0.8309, 0.9979, 0.9841, 0.6144, 0.9887, 0.9302, 0.7362,
29 0.8312, 0.9771, 0.9881, 0.8537, 0.9570, 0.9547, 0.9100, 0.8509, 0.4964, 0.9948,
30 0.8546, 1, 0.9721, 0.7675, 0.9469, 0.9437, 0.9356, 0.9648, 0.8918, 0.8406,
31 0.9884, 0.9941, 0.7900, 0.9676, 0.9508, 0.5143, 0.9857, 0.9885, 0.4693, 0.9973,
32 0.8732, 0.9985, 1, 0.9143, 0.9966, 0.9973, 0.9550, 0.9975, 0.8118, 0.9128,
33 0.8993, 0.9979, 0.8651, 0.9305, 0.6136, 0.9535, 0.9925, 0.8554, 0.9755, 0.9213,
34 0.9249, 0.9512, 0.9579)

```