

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**MODELAGEM NÃO ESTACIONÁRIA DE FREQUÊNCIA
DE CHEIAS A NÍVEIS LOCAL E REGIONAL**

LUANA OLIVEIRA SALES

ORIENTADOR: DIRCEU SILVEIRA REIS JUNIOR

**DISSERTAÇÃO DE MESTRADO EM TECNOLOGIA AMBIENTAL E
RECURSOS HÍDRICOS**

PUBLICAÇÃO: PTARH.DM – 255/2023

BRASÍLIA/DF: AGOSTO – 2023

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL**

**MODELAGEM NÃO ESTACIONÁRIA DE FREQUÊNCIA DE
CHEIAS A NÍVEIS LOCAL E REGIONAL**

LUANA OLIVEIRA SALES

**DISSERTAÇÃO SUBMETIDA AO DEPARTAMENTO DE
ENGENHARIA CIVIL E AMBIENTAL DA FACULDADE DE
TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE
DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU
DE MESTRE EM TECNOLOGIA AMBIENTAL E RECURSOS
HÍDRICOS.**

APROVADA POR:

**Prof. Dirceu Silveira Reis Junior, PhD (ENC-UnB)
(Orientador)**

**Prof. Carlos Henrique Ribeiro Lima, PhD (ENC-UnB)
(Examinador Interno)**

**Prof. Pedro Luiz Borges Chaffe, Dr. (UFSC)
(Examinador Externo)**

BRASÍLIA/DF, 29 DE AGOSTO DE 2023

FICHA CATALOGRÁFICA

SALES, LUANA OLIVEIRA

Modelagem não estacionária de frequência de cheias a níveis local e regional [Distrito Federal] 2023.

xvii, 162p., 210 x 297 mm (ENC/FT/UnB, Mestre, Tecnologia Ambiental e Recursos Hídricos, 2023).

Dissertação de Mestrado – Universidade de Brasília. Faculdade de Tecnologia.

Departamento de Engenharia Civil e Ambiental.

1. Cheias

2. Não estacionariedade

3. Análise de frequência

4. GEV

I. ENC/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

SALES, L. O. (2023). *Modelagem não estacionária de frequência de cheias a níveis local e regional*. Dissertação de Mestrado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH.DM-255/2023, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 162p.

CESSÃO DE DIREITOS

AUTOR: Luana Oliveira Sales.

TÍTULO: Modelagem não estacionária de frequência de cheias a níveis local e regional.

GRAU: Mestre

ANO: 2023

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa dissertação de mestrado pode ser reproduzida sem autorização por escrito do autor.

Luana Oliveira Sales
luanaoliveirasales@hotmail.com

*Dedico este trabalho a Deus, a minha mãe
Magda, ao Lucas e ao meu irmão Vitor.*

“Quanto a vós, sede fortes, não vos acovardeis, pois vosso labor terá sua recompensa”

(II Crônicas 15:7)

AGRADECIMENTOS

A Deus, por estar comigo e me proporcionar saúde, ânimo e força para percorrer toda essa trajetória.

À minha família, minha mãe e meu irmão, pelo apoio, incentivo, amor incondicional e por estarem sempre comigo nessa jornada.

Ao Lucas, pela paciência, apoio, amor, carinho, incentivo, compreensão e por sempre estar comigo em todos os momentos bons e ruins dessa etapa.

A esta Universidade, seu corpo docente, direção e administração, por me fornecerem os seus conhecimentos e auxílios.

Aos órgãos de fomento e apoio à pesquisa - Fundação de Amparo à Pesquisa do Distrito Federal (FAPDF), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e Decanato de Pós-Graduação (DPG) da Universidade de Brasília - pelo auxílio financeiro.

Um agradecimento especial ao meu orientador, Prof. Dirceu Silveira Reis Junior, pelo conhecimento e orientação nesta trajetória.

Aos membros da banca, Prof. Carlos Henrique Ribeiro Lima e Prof. Pedro Luiz Borges Chaffe, por todo o auxílio na construção e melhoria deste trabalho.

Ao Eng. Saulo Aires de Souza, por todo o auxílio na construção deste trabalho, principalmente com a geração de dados.

Um agradecimento especial ao meu antigo orientador e professor de hidrologia, Prof. Antover Panazzolo Sarmento, por todo conhecimento, apoio e ensinamentos que me levaram ao interesse de seguir nessa área.

A todos os meus colegas e amigos que fiz durante essa jornada, e fora dela, pela companhia e apoio que me fizeram continuar e tornar essa árdua caminhada mais leve, com um agradecimento especial para a Alice Pereira e para o Thiago Lappicy.

Enfim, a todos os que, por algum motivo, contribuíram para a realização deste trabalho

RESUMO

MODELAGEM NÃO ESTACIONÁRIA DE FREQUÊNCIA DE CHEIAS A NÍVEIS LOCAL E REGIONAL

Anualmente, as cheias são responsáveis por diversos desastres naturais, desastres que podem ser influenciados por mudanças no comportamento das cheias, devido a alterações nas condições da bacia hidrográfica causadas por mecanismos de origem natural e/ou antropogênica. A análise de frequência de cheias não estacionárias auxilia no estudo dessas mudanças das cheias ao investigar a existência, as possíveis causas e o grau de intensidade de tendências nos dados hidrológicos. Em análises de frequência de cheias não estacionárias, é usual selecionar o modelo que melhor se adere a cada série de dados em nível local, sem uma avaliação regional dos modelos, avaliação importante que pode controlar a taxa do Erro Tipo I (falso-positivos). Assim, este trabalho apresenta uma abordagem metodológica para detectar, modelar e avaliar o comportamento não estacionário das cheias a níveis local e regional. A abordagem consiste na análise de frequência dos quantis das cheias com o emprego da distribuição Generalizada de Valores Extremos (GEV) aplicada a um modelo estatístico estacionário e três não estacionários em funções do Tempo e de outras covariáveis influentes na área de estudo. Em que, avaliam-se as incertezas dos quantis das cheias e dos parâmetros dos modelos não estacionários. Na análise local para cada série, há a seleção de um modelo, dentre os quatro propostos, por meio do Critério de Informação Bayesiano (BIC). Para controlar o Erro Tipo I ao nível regional, aplica-se a taxa do False Discovery Rate (FDR). No presente estudo, realiza-se a aplicação dessa abordagem metodológica para 33 séries de vazões máximas anuais na Região Hidrográfica (RH) do Uruguai, localizada no Brasil. A modelagem dos quantis de cheias associados aos potenciais mecanismos de mudanças (covariáveis) na RH tem como foco mecanismos climáticos: El Niño Oscilação Sul (ENOS) e Oscilação Decenal do Pacífico (ODP), além do Tempo. Ao nível local, identifica-se nessa RH altas taxas de séries que melhor se aderem aos modelos não estacionários propostos, principalmente considerando os índices El Niño 1+2 e 3. Ao nível regional, essas taxas continuam presentes em menores proporções, com alterações relevantes entre os quantis de cheias de 50 anos ($Q_{0.98}$) e com probabilidades de excedência relacionadas ao $Q_{0.98}$ estacionário entre 0 e 24%. Resultados que mostram a relevância do levantamento da não estacionariedade das cheias não só ao nível local, mas também regional, diante de possíveis cenários de subestimação/superestimação de cheias estacionárias.

ABSTRACT

NON-STATIONARY MODELING OF FLOOD FREQUENCY AT LOCAL AND REGIONAL LEVELS

Several natural disasters are caused by floods every year. These disasters can be influenced by changes in flood behavior as a response to watershed conditions that can be altered by natural and/or anthropogenic mechanisms. Non-stationary frequency analysis of floods supports the study of these flood changes by investigating the existence, possible causes, and degree of intensity of trends in the time series. In non-stationary frequency analysis of floods, it is usual to select the model that best fits each data series at a local level, without a regional analysis of the models, an important analysis that can control the rate of Type I errors (false positives). Thus, this study presents a methodological approach on detecting, modeling, and checking non-stationary flood behavior at local and regional levels. This approach consists of performing a frequency analysis of flood quantiles using the Generalized Extreme Values Distribution (GEV) applied to one stationary statistical model and three non-stationary ones as a function of time and other possibly influential covariates in the study area. The uncertainties associated with both the flood quantiles and the parameters of the non-stationary models are evaluated. The Bayesian Information Criterion (BIC) is used to select a model from the four proposed that best fits the historical series. To control Type I Error (false positives) at the regional level, the False Discovery Rate (FDR) is applied. In the present study, an example of the application of this methodological approach is presented for the 33 series of maximum annual flows in the Hydrographic Region (RH) of Uruguay, located in Brazil. The modeling of the flood quantiles associated with potential mechanisms of change (covariates) in the RH focuses on two large-scale climate mechanisms, the El Niño Southern Oscillation (ENSO) and Pacific Decadal Oscillation (PDO), as well as Time. Based on this modeling, high rates of series that best fit the proposed non-stationary models were identified at the local level. At the regional level, these rates are still present, but in smaller proportions, with relevant changes between the 50-year flood quantiles ($Q_{0.98}$), and with exceedance probabilities related to the stationary $Q_{0.98}$ between 0 and 24%. These results show the relevance of investigating the non-stationarity of floods not only at a local level, but also at a regional level, in view of possible scenarios of underestimation/overestimation of stationary floods.

SUMÁRIO

1 - INTRODUÇÃO	1
2 - OBJETIVOS DO TRABALHO	3
2.1 - OBJETIVO GERAL	3
2.2 - OBJETIVOS ESPECÍFICOS.....	3
3 - REVISÃO BIBLIOGRÁFICA.....	4
3.1 - EVENTOS EXTREMOS DE CHEIAS	4
3.2 - MECANISMOS INFLUENCIADORES DAS CHEIAS.....	6
3.3 - ANÁLISE DE FREQUÊNCIAS DE CHEIAS E NÃO ESTACIONARIEDADE	11
3.3.1 - Análise local	18
3.3.2 - Análise regional	20
4 - METODOLOGIA	23
4.1 - ESTRATÉGIA DE AÇÃO.....	23
4.2 - ANÁLISE DE FREQUÊNCIAS DE CHEIAS.....	24
4.2.1 - Distribuição Generalizada de Valores Extremos	24
4.2.2 - Modelos estatísticos	26
4.2.3 - Estimativa de parâmetros.....	29
4.2.4 - Análise de incertezas	31
4.2.5 - Análise local	34
4.2.6 - Análise regional	36
4.3 - ESTUDO DE CASO: RH URUGUAI.....	39
4.3.1 - Séries de vazões.....	40
4.3.2 - Covariáveis: Indicadores climáticos	43
5 - RESULTADOS E DISCUSSÃO	49
5.1 - ANÁLISE LOCAL	49
5.2 - ANÁLISE REGIONAL.....	53
5.3 - ANÁLISE DO COMPORTAMENTO NÃO ESTACIONÁRIO	72
6 - CONCLUSÃO	87

REFERÊNCIAS BIBLIOGRÁFICAS	89
APÊNDICES.....	98
APÊNDICE A - ESTAÇÕES FLUVIOMÉTRICAS ANALISADAS NA REGIÃO HIDROGRÁFICA DO URUGUAI.....	99
APÊNDICE B - VALORES DO CRITÉRIO DE INFORMAÇÃO BAYESIANO (BIC) PARA CADA SÉRIE DAS ESTAÇÕES DA REGIÃO HIDROGRÁFICA DO URUGUAI CONSIDERANDO CADA MODELO ESTATÍSTICO E CADA COVARIÁVEL ANALISADA.....	101
APÊNDICE C - QUANTIS DA CHEIA DE 50 ANOS CONSIDERANDO OS ÍNDICES EXTREMOS PARA CADA COVARIÁVEL NAS SÉRIES SELECIONADAS POR MODELOS NÃO ESTACIONÁRIOS E A HIPÓTESE DE ESTACIONARIEDADE PARA ESSAS SÉRIES.....	110
APÊNDICE D - RESULTADOS PARA AS SÉRIES TEMPORAIS DAS ESTAÇÕES MODELADAS POR MODELOS NÃO ESTACIONÁRIOS NA REGIÃO HIDROGRÁFICA DO URUGUAI PARA AS COVARIÁVEIS ANALISADAS. A) VAZÕES MÁXIMAS ANUAIS E ESTIMATIVAS DO $Q_{0.98}$ PARA O MODELO ESTACIONÁRIO E NÃO ESTACIONÁRIO E SEUS RESPECTIVOS IC DE 95%. B) PDF DO MODELO ESTACIONÁRIO E NÃO ESTACIONÁRIO PARA OS VALORES EXTREMOS DA SÉRIE HISTÓRICA DAS COVARIÁVEIS. C) VAZÕES ANUAIS MÁXIMAS E ESTIMATIVAS DE $Q_{0.5}$ PARA O MODELO ESTACIONÁRIO E NÃO ESTACIONÁRIO. D) PDF EM B) COM SEUS RESPECTIVOS P-VALORES BASEADOS NO QUANTIL DE REFERÊNCIA DE 50 ANOS ESTACIONÁRIO.....	116
APÊNDICE E - ANÁLISE DE FREQUÊNCIA DE CHEIAS NA RH DO URUGUAI PARA AS COVARIÁVEIS OSCILAÇÃO MULTIDECENAL DO ATLÂNTICO (OMA), OSCILAÇÃO DO ÁRTICO (OA) E OSCILAÇÃO DO ATLÂNTICO NORTE (OAN).....	159

LISTA DE FIGURAS

Figura 3.1 - Divisão do globo terrestre em regiões terrestres (cinza) e oceânicas (azul) de referência do IPCC (IPCC, 2021).....	5
Figura 3.2 - Esquema representando o quantil de cheias de referência ($Zp0$) para a suposição da: a) estacionariedade da série com probabilidade de excedência (q) e não excedência (p) constantes no tempo, e da b) não estacionariedade com probabilidade de excedência (qt) e não excedência (pt) variantes no tempo (adaptado de Salas & Obeysekera, 2014).	13
Figura 4.1 - Fluxograma do trabalho, com etapas (azul escuro) e subetapas (azul claro) metodológicas necessárias para o alcance dos objetivos propostos.	24
Figura 4.2 - Localização da RH do Uruguai (pontilhado verde) entre as 12 RH do Brasil (verde-escuro). A RH do Uruguai faz parte da Bacia do Uruguai (branco) na América do Sul (verde-claro).	39
Figura 4.3 - a) Localização na RH do Uruguai das 33 estações com séries de cheias selecionadas para o estudo. Os rótulos indicam o código de oito dígitos atribuídos pela ANA para cada estação. b) Número de séries temporais estudadas disponíveis por ano. c) Histograma do tamanho das séries em anos para as séries consideradas neste estudo. d) Área em Log_{10} das estações com as séries analisadas neste estudo.	43
Figura 4.4 - Mapa indicando as regiões do oceano onde as médias de temperatura da superfície do mar (TSM) são medidas para calcular os índices Niño 1+2, Niño 3, Niño 3.4, Niño 4 e PDO.	46
Figura 4.5 - Média dos períodos por ano da anomalia de temperatura da superfície do mar (TSM) em °C causada pelos índices climáticos (Índice Niño 1+2, Niño 3, Niño 3.4, Niño 4 e ODP) nos períodos com maior correlação entre as cheias na RH do Uruguai.	48
Figura 5.1 - Séries da RH do Uruguai selecionadas por modelos não estacionários (Modelo 1, 2 ou 3) após aplicação local de pelo menos um dos critérios de informação, AIC ou BIC. Considera-se cada covariável analisada (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP). O Modelo 0 (estacionário) é representado pelas barras que alcançam a linha tracejada, e os modelos não estacionários são representados pelas barras que ultrapassam a linha tracejada. Os rótulos indicam o número da estação com a série de dados (Figura 4.3).	50
Figura 5.2 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise local (BIC). Considera-se cada índice da covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP) e o modelo escolhido na análise local (BIC): Modelo	

0 (preto), Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).	52
Figura 5.3 - Análise regional empregando o <i>False Discovery Rate</i> (linha crítica em pontilhado), com $\alpha_R=5\%$ e $m=33$. Considera-se para cada índice da covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP) as séries temporais que tiveram o modelo não estacionário escolhido na análise local (BIC): Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).	55
Figura 5.4 - Intervalos de confiança de 95% de r_1 . Considera-se para cada covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4 e El Niño 4) séries temporais que tiveram o modelo não estacionário como escolhido após análise regional (FDR): Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).	57
Figura 5.5 - Intervalos de confiança de 95% de β_1 . Considera-se para cada covariável (El Niño 1+2, El Niño 3, El Niño 4) séries temporais que tiveram o Modelo 3 (roxo), modelo não estacionário, como escolhido após análise regional (FDR). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).	58
Figura 5.6 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise regional (FDR + IC). Considera-se cada índice da covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP) e o modelo escolhido em análise local (BIC) e regional (FDR + IC). O modelo estacionário escolhido na análise local: Modelo 0 (preto); e o modelo não estacionário escolhido na análise local que mudou para um modelo estacionário após a análise regional: de Modelo 1 para 0 (verde), de Modelo 2 para 0 (vermelho) ou de Modelo 3 para 0 (azul-escuro). O modelo não estacionário escolhido após análise regional: Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).	62
Figura 5.7 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise regional (FDR + IC) associadas com o suporte relativo (ΔBIC) após análise local. Considera-se cada índice da covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP) e o modelo escolhido em análise local (BIC) e regional (FDR + IC). O modelo estacionário escolhido na análise local: Modelo 0 (círculo preto); e o modelo não estacionário escolhido na análise local que mudou para um modelo estacionário após a análise regional: de Modelo 1 para 0 (círculo verde), de Modelo 2 para 0 (círculo vermelho) ou de Modelo 3 para 0 (círculo azul-escuro). O modelo não estacionário escolhido após	

análise regional: Modelo 1 (círculo verde-claro), Modelo 2 (círculo rosa) ou Modelo 3 (círculo roxo). O preenchimento dos círculos representa o suporte relativo ao uso do Modelo 0 para o BIC, quanto maior o Δ BIC, maior é o suporte contra a estacionariedade: 0 a 2 (branco), 2 a 6 (cinza-claro), 6 a 10 (cinza-escuro), > 10 (preto). Os rótulos indicam o número da estação com a série de dados (Figura 4.3). 66

Figura 5.8 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise local (BIC), regional (FDR + IC) e comparação entre os BIC. Considera-se o índice da covariável (El Niño 1+2, El Niño 3, El Niño 3.4 ou El Niño 4) e o modelo (Modelo 1, 2 ou 3) escolhido quando há a comparação entre BIC. O modelo estacionário escolhido na análise local: Modelo 0 (preto); Modelo 1 Niño 1+2 (azul-claro); Modelo 2 Niño 1+2 (rosa-claro); Modelo 3 Niño 1+2 (roxo-claro); Modelo 1 Niño 3 (azul), Modelo 2 Niño 3 (rosa); Modelo 3 Niño 3 (lilás); Modelo 2 Niño 3.4 (bege). Os rótulos indicam o número da estação com a série de dados (Figura 4.3). 69

Figura 5.9 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise local (BIC), regional (FDR + IC) e comparação entre os BIC associadas com o suporte relativo (Δ BIC). Considera-se o índice da covariável (El Niño 1+2, El Niño 3, El Niño 3.4 ou El Niño 4) e o modelo (Modelo 1, 2 ou 3) escolhido quando há a comparação entre BIC. A cor representada no segundo quadrante se refere a hipótese com menor valor de BIC, e no primeiro quadrante a hipótese com o segundo menor BIC. O modelo estacionário escolhido na análise local: Modelo 0 (preto); Modelo 1 Niño 1+2 (azul-claro); Modelo 2 Niño 1+2 (rosa-claro); Modelo 3 Niño 1+2 (roxo-claro); Modelo 1 Niño 3 (azul), Modelo 2 Niño 3 (rosa); Modelo 3 Niño 3 (lilás); Modelo 2 Niño 3.4 (bege). Os rótulos indicam o número da estação com a série de dados (Figura 4.3). O preenchimento dos círculos representa a diferença entre o grau de influência entre as hipóteses nas cheias, quanto maior o Δ BIC, maior é a diferença: 0 a 2 (branco), 2 a 6 (cinza-claro), 6 a 10 (cinza-escuro), > 10 (preto). Os rótulos indicam o número da estação com a série de dados (Figura 4.3). 71

Figura 5.10 - Taxas percentuais de mudanças da cheia de 50 anos versus os p-valores associados ao TRV. Considera-se cada covariável (Tempo, El Niño 1+2, 3, 3.4 e 4) e o modelo não estacionário escolhido após análise regional (FDR + IC): Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3). 73

Figura 5.11 - Quantis da cheia de 50 anos. Considera-se os índices extremos para cada covariável (Tempo, El Niño 1+2, 3, 3.4 e 4) para séries selecionadas por modelos não

estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade (Modelo 0) para essas séries. Menor índice da covariável: Modelo 1 (verde-claro), Modelo 2 (rosa-claro) e Modelo 3 (roxo-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro), Modelo 2 (rosa-escuro) e Modelo 3 (roxo-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3)..... 76

Figura 5.12 - Resultados para séries temporais da estação 1 (70200000) para a covariável Tempo. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em verde-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 1 no ano inicial (verde-claro) e no ano final (verde-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (verde-claro). d) PDF em b) com seus respectivos p-valores baseados no $ZQ_{0.98}Modelo0$, e o ξ de cada PDF..... 79

Figura 5.13 - Resultados para séries temporais da estação 6 (71550000) para a covariável de El Niño 3. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em verde-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 1 considerando a menor anomalia (verde-claro) e a maior anomalia (verde-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (verde-claro). d) PDF em b) com seus respectivos p-valores baseados no $ZQ_{0.98}Modelo0$, e o ξ de cada PDF..... 81

Figura 5.14 - Resultados para séries temporais da estação 33 (76750000) para a covariável El Niño 3.4. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 2 considerando a menor anomalia (rosa-claro) e a maior anomalia (rosa-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 2 (rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $ZQ_{0.98}Modelo0$, e o ξ de cada PDF..... 83

Figura 5.15 - Resultados para séries temporais da estação 33 (76750000) para a covariável El Niño 4. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 2 considerando a menor anomalia (rosa-claro) e a maior anomalia (rosa-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 2 (rosa-claro).

d) PDF em b) com seus respectivos p-valores baseados no ZQ0.98Modelo0, e o ξ de cada PDF.....	84
Figura 5.16 - Resultados para séries temporais da estação 29 (76100000) para a covariável El Niño 1+2. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 3 (não estacionário, em roxo-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 3 considerando a menor anomalia (roxo-claro) e a maior anomalia (roxo-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 3 (roxo-claro).	
d) PDF em b) com seus respectivos p-valores baseados no ZQ0.98Modelo0, e o ξ de cada PDF.....	86
Figura 0.1 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável Tempo em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 1 (verde-claro) e Modelo 2 (rosa-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro) e Modelo 2 (rosa-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).....	110
Figura 0.2 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável El Niño 1+2 em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 1 (verde-claro), Modelo 2 (rosa-claro) e Modelo 3 (roxo-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro), Modelo 2 (rosa-escuro) e Modelo 3 (roxo-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).....	112
Figura 0.3 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável El Niño 3 em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 1 (verde-claro), Modelo 2 (rosa-claro) e Modelo 3 (roxo-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro), Modelo 2 (rosa-escuro) e Modelo 3 (roxo-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).....	114
Figura 0.4 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável El Niño 3.4 em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 1 (verde-claro) e Modelo 2 (rosa-claro). Sem índice (estacionariedade):	

Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro), Modelo 2 (rosa-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3)..... 114

Figura 0.5 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável El Niño 4 em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 2 (rosa-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 2 (rosa-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3)..... 115

Figura 0.6 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável Tempo. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em azul-claro), ou Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 1: azul-claro; Modelo 2: rosa-claro) e a maior anomalia (Modelo 1: azul-escuro; Modelo 2: rosa-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (azul-claro), ou Modelo 2 (em rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $ZQ_{0.98}Modelo0$, e o ξ de cada PDF..... 120

Figura 0.7 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável ENOS na região El Niño 1+2. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em azul-claro), Modelo 2 (não estacionário, em rosa-claro), ou Modelo 3 (não estacionário, em roxo-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 1: azul-claro; Modelo 2: rosa-claro, Modelo 3: roxo-claro) e a maior anomalia (Modelo 1: azul-escuro; Modelo 2: rosa-escuro, Modelo 3: roxo-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (azul-claro), Modelo 2 (em rosa-claro), ou Modelo 3 (roxo-claro). d) PDF em b) com seus respectivos p-valores baseados no $ZQ_{0.98}Modelo0$, e o ξ de cada PDF..... 133

Figura 0.8 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável ENOS na região El Niño 3. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em azul-claro), Modelo 2 (não

estacionário, em rosa-claro), ou Modelo 3 (não estacionário, em roxo-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 1: azul-claro; Modelo 2: rosa-claro, Modelo 3: roxo-claro) e a maior anomalia (Modelo 1: azul-escuro; Modelo 2: rosa- escuro, Modelo 3: roxo- escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (azul-claro), Modelo 2 (em rosa-claro), ou Modelo 3 (roxo-claro). d) PDF em b) com seus respectivos p-valores baseados no $ZQ_{0.98}Modelo0$, e o ξ de cada PDF..... 148

Figura 0.9 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável ENOS na região El Niño 3.4. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em azul-claro), ou Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 1: azul-claro; Modelo 2: rosa-claro) e a maior anomalia (Modelo 1: azul-escuro; Modelo 2: rosa- escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (azul-claro), ou Modelo 2 (em rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $ZQ_{0.98}Modelo0$, e o ξ de cada PDF. 157

Figura 0.10 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável ENOS na região El Niño 4. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 2: rosa-claro) e a maior anomalia (Modelo 2: rosa-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 2 (em rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $ZQ_{0.98}Modelo0$, e o ξ de cada PDF..... 158

Figura 0.11 - Média dos períodos por ano dos índices climáticos com maior correlação entre as cheias na RH do Uruguai. 159

Figura 0.12 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai considerando cada índice da covariável e o modelo escolhido na análise local (BIC): Modelo 0 (preto), Modelo 1 (verde-claro), Modelo 2 (rosa) e Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3). 160

Figura 0.13 - Análise regional empregando False Discovery Rate, com $\alpha_R=5\%$ e $m=33$, considerando cada covariável para as séries temporais que tiveram o modelo não estacionário escolhido na análise local (BIC): Modelo 1 (verde-claro), Modelo 2 (rosa) e Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

..... 160

Figura 0.14 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai considerando cada índice da covariável e o modelo escolhido em análise local (BIC) e regional (FDR + IC). O modelo estacionário escolhido na análise local: Modelo 0 (preto); e o modelo não estacionário escolhido na análise local que mudou para um modelo estacionário após a análise regional: de Modelo 1 para 0 (verde), de Modelo 2 para 0 (vermelho), de Modelo 3 para 0 (azul-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3)..... 161

Figura 0.15 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai considerando cada índice da covariável e o modelo escolhido em análise local (BIC) e regional (FDR + IC). O modelo estacionário escolhido na análise local: Modelo 0 (círculo preto); e o modelo não estacionário escolhido na análise local que mudou para um modelo estacionário após a análise regional: de Modelo 1 para 0 (círculo verde), de Modelo 2 para 0 (círculo vermelho), de Modelo 3 para 0 (círculo azul-escuro). O preenchimento dos círculos representa o suporte relativo (ΔBIC) ao uso do Modelo 0 para o BIC, quanto maior o ΔBIC , maior é o suporte contra a estacionariedade: 0 a 2 (branco), 2 a 6 (cinza-claro), 6 a 10 (cinza-escuro), > 10 (preto). Os rótulos indicam o número da estação com a série de dados (Figura 4.3). 162

LISTA DE TABELAS

Tabela 3.1 - Exemplos de possíveis mecanismos influenciadores no regime das cheias com as variáveis associadas (Merz et al., 2012, modificado)	7
Tabela 3.2 - Exemplos de trabalhos que relacionam as cheias com suas/seus possíveis variáveis/mecanismos influenciadores nas mudanças das cheias.....	9
Tabela 3.3 - Exemplos de trabalhos com análises de frequência de cheias. κ , α e ξ são os parâmetros de forma, de escala e de posição respectivamente, e μ é a média da distribuição.	16
Tabela 3.4 - Exemplos de trabalhos relacionados a análises de frequência de cheias com seus métodos de seleção local.	19
Tabela 3.5 - Exemplos de trabalhos relacionados a não estacionariedade hidrológica com seus mecanismos de seleção regional.	22
Tabela 4.1 - Parâmetros (posição (ξ), escala (α) e forma (κ)) da distribuição GEV para os quatro modelos estatísticos propostos (Modelo 0, 1, 2 e 3).	27
Tabela 4.2 - Informações sobre os índices climáticos (covariáveis) da RH do Uruguai.....	46
Tabela 4.3 - Períodos com maior correlação entre os índices climáticos (Índice Niño 1+2, Niño 3, Niño 3.4, Niño 4 e ODP) e as cheias na RH do Uruguai.....	47
Tabela 5.1 - Número e proporção de estações com séries de cheias da RH do Uruguai selecionadas por cada um dos modelos estatísticos propostos (Modelo 0, 1, 2 ou 3) em análise local (BIC). Considera-se cada covariável analisada (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP).	53
Tabela 5.2 - Número de estações com séries hidrológicas selecionadas por cada um dos modelos estatísticos propostos (Modelo 0, 1, 2 ou 3) após análise local (BIC) e regional (FDR+IC). Considera-se cada covariável analisada (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP).	63
Tabela 0.1 - Estações fluviométricas analisadas na Região Hidrográfica do Uruguai.....	99
Tabela 0.2 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável Tempo	101
Tabela 0.3 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável El Niño 1+2.....	102

Tabela 0.4 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável El Niño 3	103
Tabela 0.5 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável El Niño 3.4	105
Tabela 0.6 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável El Niño 4	106
Tabela 0.7 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável ODP	107

1 - INTRODUÇÃO

De 1998 a 2017, inundações afetaram mais de 2 bilhões de pessoas no mundo, resultando em mais de 142 mil mortes e mais de 650 bilhões de dólares em prejuízos (Wallemacq et al., 2018). O Brasil é o país mais suscetível a inundações na América Latina e está entre os 15 países do mundo com a maior população exposta ao risco de inundação fluvial. Entre 2000 e 2019, o país enfrentou 70 desastres relacionados a cheias, afetando mais de 70 milhões de pessoas (OCHA, 2020). Em 2022, Petrópolis (Brasil) vivenciou o maior desastre natural de sua história, com inundações em fevereiro que causaram mais de 270 mortes, classificando-se entre os 10 desastres naturais mais mortais do mundo em 2022 (CRED, 2023; WMO, 2023). Essa vulnerabilidade às cheias destaca a necessidade contínua de estudos nessa área.

Para compreender os eventos de cheias, é fundamental estudar os mecanismos que influenciam suas ocorrências e que podem resultar em alterações nas frequências e intensidades desses eventos. Essas mudanças no comportamento das cheias são reações às alterações nas condições da bacia hidrográfica, que são causadas por diversos mecanismos atuando de forma simultânea, interligada e em diferentes escalas espaciais e temporais (Merz et al., 2012). Esses mecanismos de mudança podem ter origem natural e/ou antropogênica e estão relacionados à atmosfera (ex. mecanismos atmosféricos e oceânicos de larga escala), à bacia (ex. alterações no uso e ocupação do solo) e ao próprio rio (ex. operações em reservatórios) (ASCE, 2018; Blöschl et al., 2015; IPCC, 2021; Merz et al., 2012).

A análise de frequência de cheias relaciona as magnitudes das cheias com suas frequências de ocorrência (AghaKouchak et al., 2013). Análise essencial no planejamento e gerenciamento hídrico, como em casos de projetos e operações de estruturas hidráulicas (ex. barragens), e em situações de avaliação e controle dos riscos e de prevenção de danos (ANA, 2016; Tucci, 2001). Tradicionalmente, a análise de frequência de cheias parte da premissa da estacionariedade das séries (Salas et al., 2018). Premissa a qual não abrange as mudanças significativas nas frequências e nas magnitudes de eventos hidrológicos (Anzolin & Chaffe, 2021; L. Slater et al., 2021; Vogel et al., 2011) causadas por mecanismos de mudanças.

Assim, surge um debate sobre o uso da estacionariedade e não estacionariedade na hidrologia (Milly et al., 2008; Montanari & Koutsoyiannis, 2014). O debate ocorre em parte por desafios e incertezas associadas à detecção, estimativa e extrapolação de tendências em

séries hidrológicas (Luke et al., 2017; Serago & Vogel, 2018). Levando a um empenho em: investigar a existência e intensidade de tendências nos dados históricos (ex. Prosdocimi & Kjeldsen, 2021; Slater et al., 2021); analisar possíveis causas (covariáveis) das alterações nas séries (ex. Anzolin & Chaffe, 2021; Ouarda & Charron, 2019); e estudar e desenvolver estratégias de modelagem não estacionária (ver Salas et al., 2018; Serago & Vogel, 2018).

Em uma inferência válida, a análise de dados segue um processo de formulação cuidadosa de modelos *a priori*, seleção de modelos, estimativa de parâmetros e medição da precisão com a incerteza do modelo (Burnham & Anderson, 2004). Sem uma teoria específica voltada ao comportamento assintótico de valores extremos e sem um consenso na modelagem não estacionária, uma estratégia usual na formulação de modelos é adaptar modelos estatísticos existentes considerando a não estacionariedade (Read & Vogel, 2015). É comum também em modelagens não estacionárias (Bartiko et al., 2017; Šraj et al., 2016) a seleção de modelos (estacionários ou não) ocorrer somente localmente, análise por série. Porém, a falta de uma avaliação regional do problema, análise das séries em conjunto, pode resultar em um aumento significativo da taxa de falsos-positivos (Erro Tipo I), inflacionando o número de séries com tendências em uma região (Benjamini & Hochberg, 1995; Ventura et al., 2004).

Diante da relevância das cheias e do conhecimento ainda limitado sobre a não estacionariedade relativo à capacidade de detecção, modelagem e avaliação local e regional de modelos, este estudo visa contribuir na abordagem metodológica da análise de frequência não estacionária das cheias. Essa abordagem inclui a modelagem dos quantis de cheias, que descrevem o comportamento das vazões máximas, usando quatro modelos estatísticos (estacionário e não estacionários) para avaliar como as cheias se ajustam aos parâmetros que variam distintamente. Inclui o levantamento das incertezas dos parâmetros não estacionários e dos quantis de cheias. A avaliação local e regional para identificar o modelo que melhor se adere aos dados, reduzindo a taxa de Erro Tipo I. E detecta a presença e magnitude da influência de covariáveis pela modelagem de diferentes mecanismos de mudanças das cheias. Essa abordagem metodológica é aplicada na Região Hidrográfica (RH) do Uruguai, Brasil, área escolhida devido às altas taxas de inundações e à identificação de tendências nas cheias (Anzolin & Chaffe, 2021; Bartiko et al., 2017; Slater et al., 2021). Além do Tempo, mecanismos climáticos atuantes nessa RH são analisados como covariáveis: El Niño Oscilação Sul (ENOS) e Oscilação Decenal do Pacífico (ODP), devido as suas séries de dados extensas, auxiliando em análises de atribuição de mudanças de longo prazo nas cheias.

2 - OBJETIVOS DO TRABALHO

2.1 - OBJETIVO GERAL

Detectar, modelar e avaliar o comportamento não estacionário em séries de vazões máximas anuais a níveis local e regional por meio de modelos estatísticos tendo como estudo de caso a Região Hidrográfica do Uruguai.

2.2 - OBJETIVOS ESPECÍFICOS

Em busca de alcançar o objetivo geral, foram delineados os seguintes objetivos específicos:

- a) Identificar o modelo estatístico mais adequado (estacionário ou não estacionário) para representar as séries de vazões máximas anuais ao nível local, avaliando modelos individualmente em cada série e investigando as covariáveis que explicam possíveis mudanças na distribuição de probabilidades ao longo do tempo;
- b) Avaliar a não estacionariedade considerando o conjunto de séries de vazões máximas anuais da região, analisando modelos estatísticos em nível regional e assim controlando o Erro Tipo I na região para evitar um excesso de falsas detecções;
- c) Analisar o comportamento não estacionário nas séries de vazões máximas anuais, por meio da quantificação das taxas de mudanças nos quantis de cheia ao longo do tempo obtidas a partir dos modelos não estacionários selecionados após avaliação local e regional.

3 - REVISÃO BIBLIOGRÁFICA

3.1 - EVENTOS EXTREMOS DE CHEIAS

O conceito de eventos extremos pode variar entre diferentes áreas (ex. climatologia, ciências da terra e sociais, ecologia, engenharia e hidrologia, ver McPhillips et al., 2018) e literaturas (ver IPCC, 2012). Portanto, é de extrema importância definir claramente o significado desse termo em cada estudo (IPCC, 2012, 2021; McPhillips et al., 2018; Stephenson, 2008). Na hidrologia, eventos extremos podem se referir a diversas variáveis hidrológicas (ex. precipitações e vazões) em cenários de baixas e/ou altas intensidades (Collischonn & Tassi, 2008; Naghettini & Pinto, 2007). Na engenharia, eventos extremos estão amplamente relacionados à definição de padrões de projetos associados a probabilidades de ocorrência de eventos com períodos de retorno específicos, ambos calculados por meio de métodos estatísticos (McPhillips et al., 2018). No presente estudo, atrelando a hidrologia com a engenharia, o termo “eventos extremos” faz referência aos eventos hidrológicos extremos de cheias associados às vazões máximas anuais observadas em estações fluviométricas.

Eventos de cheias são fenômenos hidrológicos que podem ser descritos como a ocorrência de valores elevados das vazões do rio, as vazões máximas, que divergem dos níveis majoritariamente observados em uma determinada seção do rio durante um determinado período de tempo (IPCC, 2014; MCID & IPT, 2007; Naghettini & Pinto, 2007). Devido às magnitudes mais altas, os eventos extremos de cheias estão normalmente associados a uma frequência de ocorrência menor do que a ocasionada por eventos moderados (Chow et al., 1988; IPCC, 2012; Naghettini & Pinto, 2007; Wilks, 2005).

Apesar da menor frequência de ocorrência, dependendo da severidade do evento extremo, o volume da água tem a capacidade de extravasar os limites do leito menor do corpo d'água e acarretar desastres naturais como as inundações, que ocorrem quando há o transbordamento da água em áreas marginais (IPCC, 2014, 2021; Kobiyama et al., 2006; MCID & IPT, 2007). A inundação é a categoria de desastre natural mais frequente no mundo e que causa grande preocupação na sociedade, pois pode resultar em devastação generalizada, com perdas significativas de vidas e danos severos à economia, ao meio ambiente e à saúde (ANA, 2016; Marengo et al., 2009; OCHA, 2020; Wallemacq et al., 2018; WHO & WMO, 2012).

Dada a vulnerabilidade da sociedade aos eventos extremos de cheias e seus impactos subsequentes, é essencial estudar o processo de formação desses eventos. Ainda assim, essa área de pesquisa apresenta desafios e requer avanços contínuos (ANA, 2016; Blöschl et al., 2019; Wallemacq et al., 2018). Segundo o IPCC (2021), em escalas continental e regional (domínios poligonais, subcontinentais, conforme ilustrado na Figura 3.1 e definidos pela combinação de fatores ambientais, climáticos e não climáticos), os estudos sobre eventos extremos de cheias e suas mudanças apresentam resultados com média confiança em relação a tendências nas cheias em escala global, mas baixa confiança em mudanças regionais. Observa-se um aumento na frequência e/ou magnitude das cheias na Ásia (Sudeste e Norte) e na Índia, com alta concordância entre os estudos. Na África (Leste e tropical) e nas altas latitudes da América do Norte, há uma média concordância. Além disso, há uma diminuição de frequência e/ou magnitude de cheias na Europa (Central e Oriental) e no Mediterrâneo com alta confiança entre os estudos. Em partes da América do Sul, na América do Norte (Sul e Centro) e no sudoeste da África, a confiança é baixa (IPCC, 2021). O grau de confiança e concordância varia conforme o número de estudos sobre cheias no mundo e os resultados obtidos nesses estudos, além das incertezas associadas às modelagens de cheias.

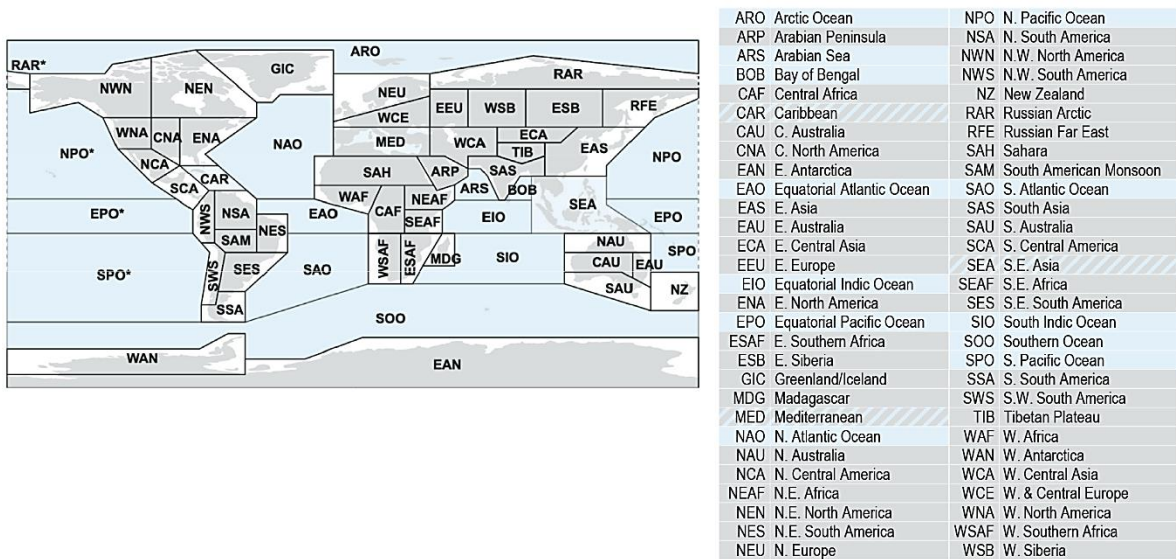


Figura 3.1 - Divisão do globo terrestre em regiões terrestres (cinza) e oceânicas (azul) de referência do IPCC (IPCC, 2021).

3.2 - MECANISMOS INFLUENCIADORES DAS CHEIAS

Para compreender os eventos hidrológicos, como as cheias, é necessário estudar a relação das condições do ambiente nos processos hidrológicos. Essa relação é de grande complexidade tanto em sua ocorrência quanto em seu efeito na sociedade (IPCC, 2021). O estudo dessa relação aumentou com a/o: melhor compreensão dos mecanismos atmosféricos e oceânicos de grande escala e oscilações; aquecimento global; aumento da população e seus impactos no ambiente e na disponibilidade hídrica; e melhor entendimento dos efeitos de processos atmosférico-oceânicos e dos fatores antrópicos no ciclo hidrológico (Salas et al., 2018). Em eventos de cheias, essa complexidade se dá em parte pelo processo de formação de cheias, influenciado pelas condições na bacia hidrográfica, como topografia, relevo, geologia, geomorfologia, rede de drenagem, uso e ocupação do solo e regime de chuvas da área de influência da bacia (Tominaga et al., 2009; Tucci, 2001).

Portanto, as mudanças no comportamento de cheias são respostas naturais às condições da bacia hidrográfica proporcionadas pela relação complexa de diferentes mecanismos de origem natural e/ou antropogênica que podem agir em paralelo, interagir entre si e atuar em diferentes escalas espaciais e temporais (Blöschl et al., 2015; Merz et al., 2012). Essas mudanças nos regimes das cheias podem acarretar alterações nas frequências e nas intensidades das cheias (IPCC, 2007; Kobiyama et al., 2006; Marengo et al., 2009). Merz et al. (2012) categorizam os possíveis mecanismos de mudanças das cheias em três grupos: atmosfera, bacia hidrográfica e rios, conforme apresentado na Tabela 3.1. Esses três grupos abrangem diversos exemplos de mecanismos de mudanças das cheias que também são mencionados pelo IPCC (2021).

Tabela 3.1 - Exemplos de possíveis mecanismos influenciadores no regime das cheias com as variáveis associadas (Merz et al., 2012, modificado)

Grupos	Processo	Variáveis	Mecanismos de mudanças
Atmosfera	Meteorológico	Temperatura; Regime das chuvas; Cobertura de neve; Degelo; Distribuição sazonal das variáveis climáticas; Sazonalidade das cheias	Variabilidade climática natural em diferentes escalas de tempo; Mudanças climáticas antropogênicas
Bacia hidrográfica	Geração de escoamento; Tempo de concentração	Capacidade de infiltração; Coeficiente de <i>runoff</i> ; Capacidade de armazenamento de água; Evapotranspiração	Urbanização; Desmatamento; Incêndios florestais; Práticas de manejo agrícola; Drenagens de áreas alagadas e agricultáveis; Construções de bacias de detenção
Rios	Propagação da onda de cheia; Superposição de ondas de cheia	Morfologia do rio; Transporte da água; Rugosidade; Níveis de água; Descarga; Áreas inundadas	Condicionamento do rio; Redução do comprimento do rio; Construção de diques, quebra-mares e calhas; Operação de usinas hidrelétricas e de reservatórios

No grupo da atmosfera, os processos meteorológicos modificam os fluxos de água e energia da bacia hidrográfica, o que altera o balanço hídrico (Blöschl et al., 2015; Hall et al., 2014; Mediero et al., 2014; Merz et al., 2012). As mudanças causadas pela variabilidade climática natural em diferentes escalas de tempo (variações decorrentes das características do clima) podem ocorrer devido: à dinâmica interna do sistema climático, como o fenômeno do El Niño Oscilação Sul (ENOS) e a Oscilação Decenal do Pacífico (ODP); ou aos agentes externos, como flutuações periódicas na radiação solar e alterações abruptas derivadas de erupções vulcânicas. As variações causadas por mudanças climáticas antropogênicas

(alterações em processos climáticos devido à atividade antrópica) podem ocorrer devido, por exemplo, aos aerossóis antropogênicos e gases estufas que contribuem para o aquecimento global (Blöschl et al., 2015; Ishak et al., 2013; Merz et al., 2012). Em relação à bacia hidrográfica há a entrada de matéria e energia, como a água da chuva e o derretimento de neve que escoam pela superfície e/ou se infiltra na subsuperfície. Então, alterações nas bacias, ou seja, na superfície da terra, e/ou nos solos, e/ou nos aquíferos subterrâneos, acarretam modificações nos regimes das vazões de um rio ao longo do seu percurso (Blöschl et al., 2015; Hall et al., 2014; Mediero et al., 2014; Merz et al., 2012). Por fim, no grupo dos rios, certas alterações nas estruturas dos rios visam aumentar a capacidade de transporte da água. O que tende a amplificar a velocidade com que as ondas de cheia se propagam, levando a um acréscimo no volume da descarga a jusante, essa descarga altera o comportamento das vazões no espaço e no tempo (Blöschl et al., 2015; Hall et al., 2014; Mediero et al., 2014; Merz et al., 2012).

Com o aumento no número e na intensidade de eventos extremos, houve um crescimento de estudos que buscam compreender como diferentes mecanismos de origem natural e/ou antropogênica podem influenciar o comportamento das cheias em diversas bacias hidrográficas ao redor do mundo (IPCC, 2021). Alguns estudos relacionados a cheias podem ser encontrados em ordem alfabética na Tabela 3.2, que apresenta o local de estudo e as variáveis ou mecanismos de mudanças das cheias analisados. Conforme observado pelo IPCC (2012) em análises, esses mecanismos têm uma certa interferência nos eventos de cheias, podendo provocar alterações na frequência e na intensidade das cheias, resultados que também são encontrados nas análises da Tabela 3.2. No entanto, ainda são poucos os estudos no mundo que se concentram na atribuição de mudanças de longo prazo nas cheias, tendo o maior foco em alterações nos eventos de cheias pontuais, ou nas cheias repentinas e nas urbanas, interligadas a eventos extremos de precipitação (IPCC, 2021). Quando se estuda a relação entre cheias e índices climáticos, como nas análises de Hodgkins et al. (2017) e Ishak et al. (2013) (Tabela 3.2), essa atribuição de mudanças com maior prazo nas cheias pode ocorrer, uma vez que diversos fenômenos climáticos ocorrem em períodos de maior duração, abrangendo escalas desde anuais até multidecenais (Ishak et al., 2013), exigindo, portanto, séries de dados climáticos mais longas.

Tabela 3.2 - Exemplos de trabalhos que relacionam as cheias com suas/seus possíveis variáveis/mecanismos influenciadores nas mudanças das cheias

Referência	Local	Variáveis/mecanismos de mudanças
Anzolin & Chaffe (2021)	Brasil (América do Sul)	Temperatura; ENOS; Precipitação
Blöschl et al. (2017)	Europa	Temperatura
Chagas & Chaffe (2019)	Brasil (América do Sul)	Índices de umidade antecedente; Precipitação; Demanda hídrica da bacia; Cobertura de florestas naturais
Hodgkins et al. (2017)	América do Norte e Europa	Oscilação Decenal do Pacífico Oscilação Multidecenal do Atlântico
Ishak et al. (2013)	Austrália (Oceania)	Oscilação Antártica; ENOS; Oscilação Interdecadal do Pacífico
Mediero et al. (2014)	Espanha (Europa)	Evapotranspiração; Índices de umidade antecedente; Relação entre <i>runoff</i> e precipitação
Slater et al. (2015)	EUA (América do Norte)	Redução da capacidade da rede de drenagem

Embora múltiplos mecanismos afetem a geração de cheias, os estudos tendem a limitar o número de possíveis influenciadores por bacia hidrográfica, como pode ser visto, por exemplo, na Tabela 3.2. Essa limitação ocorre em parte devido ao fato de que os mecanismos de mudanças não são conhecidos *a priori* e nem são aparentes, além de serem divergentes e mutáveis tanto no tempo quanto no espaço, apresentando uma gama de opções. Assim, é comum levantar hipóteses sobre os mecanismos influentes na área de estudo com base na literatura, na consulta a especialistas e na análise qualitativa e quantitativa dos dados históricos, a fim de obter uma melhor compreensão do comportamento das cheias (Harrigan et al., 2014).

Outra limitação e um desafio de grande complexidade é conseguir separar mecanismos que podem estar interagindo de diferentes formas na área e no período histórico de interesse. Um exemplo é o estudo da influência de mecanismos climáticos nas cheias, que idealmente deve ser feito sem a interferência humana (Hodgkins et al., 2017). Raramente se encontram bacias sem interferência humana (ex. construção e operação de reservatórios), o que leva a estudos que envolvem correlação entre dados de índices climáticos e de vazão e precipitação (Khouakhi et al., 2017); uso de dados de locais pouco impactados por atividades antrópicas (Hodgkins et al., 2017); e modelagem climática (Slater & Villarini, 2017). Uma forma possível de filtrar dados em que há o impacto potencial nas vazões a jusante causado por reservatórios é através do grau de regulação ou *degree of regulation* (DoR). O DoR é um índice que mede a proporção do fluxo anual de um rio que pode ser retido por um ou mais reservatórios na bacia hidrográfica. Um valor alto indica uma grande probabilidade de que volumes substanciais de vazões possam ser armazenados ao longo de um tempo e liberados posteriormente, alterando diretamente o regime natural da vazão dos rios (Lehner et al., 2011; Nilsson et al., 2005; Vörösmarty et al., 1997).

Estudos de Vörösmarty et al. (1997) e Nilsson et al. (2005) utilizaram o DoR como componente chave em análises do impacto da regulação de reservatórios no mundo. Ambos os estudos tiveram escala e extensão limitadas, devido à baixa disponibilidade de dados de reservatórios e de hidrografia, e, portanto, concentraram-se principalmente em grandes bacias hidrográficas. Lehner et al. (2011) estimaram o DoR de forma inédita com cálculos avançados e especialmente detalhados em escala global. No entanto, em alguns países, como o Brasil, as estimativas também se concentraram em bacias maiores devido à falta de dados. Estudos que envolvem a avaliação do impacto de reservatórios por meio do DoR ocorre não apenas em escala global, mas também regional (ver Liu et al., 2021; Mailhot et al., 2018; Yang et al., 2019). No Brasil, o DoR foi calculado por de Souza & Reis (2021) para toda a base hidrográfica brasileira. Com os índices calculados, de Souza & Reis (2021) também avaliaram o impacto dos reservatórios nas 12 regiões hidrográficas (RH) brasileiras. Com exceção da RH da Amazônia, em todas as outras RH houve a presença de valores significativos de DoR, principalmente associadas aos rios principais em que há importantes usinas de geração hidroelétrica, áreas com alta densidade populacional, e intensa atividade agrícola.

3.3 - ANÁLISE DE FREQUÊNCIAS DE CHEIAS E NÃO ESTACIONARIEDADE

O processo de formação de eventos hidrológicos, como as cheias, envolve um grande grau de aleatoriedade nos mecanismos que influenciam esses eventos, acarretando incertezas associadas à quantificação das cheias e à interdependência dos seus mecanismos de mudanças. Isso contribui para que o comportamento das cheias no espaço e no tempo não possa ser totalmente conhecido. O que torna os eventos de cheias em eventos aleatórios na dinâmica de suas ocorrências, podendo ser classificados como estocásticos e analisados por meio das leis de probabilidades e da estatística, como a análise de frequência de cheias (Naghetini & Pinto, 2007).

A análise de frequência de cheias é uma técnica usual tanto nas ciências hidrológicas quanto na engenharia, auxiliando no planejamento e no gerenciamento dos recursos hídricos, de forma a atenuar impactos econômicos, sociais e ambientais. Essa técnica é fundamental em projetos hidráulicos de pontes, barragens, diques e galerias de drenagem, e de controle dos riscos e prevenção de danos (ANA, 2016; Milly et al., 2008; Tucci, 2001). A análise de frequência de cheias se torna de grande auxílio ao relacionar as intensidades dos eventos de cheias com as suas frequências de ocorrência. Essa relação entre intensidade e frequência possibilita a estimativa e modelagem do comportamento das cheias com base em séries históricas de dados hidrometeorológicas de estações fluviométricas, pluviométricas ou climatológicas da região de interesse (Chow et al., 1988; Coles, 2001; Kiang et al., 2011; Naghetini & Pinto, 2007).

Os métodos usuais na análise de frequência de cheias são os analíticos. Nessa metodologia, a aleatoriedade dos dados de cheias é tratada e quantificada com base em distribuições probabilísticas. A análise de frequência analítica envolve o ajuste da distribuição teórica de probabilidades à série de dados (Naghetini & Pinto, 2007). Esse ajuste possibilita a determinação das propriedades dessa distribuição, dos parâmetros que a descrevem e dos valores das cheias para um conjunto de probabilidades de excedência (probabilidade de um evento ser igualado ou superado em um ano qualquer), conhecidos como quantis de cheias. A magnitude de um evento de cheia é inversamente relacionada à frequência de sua ocorrência (Chow et al., 1988; Collischonn & Tassi, 2008; Salas & Obeysekera, 2014; Stedinger, 1980; Tucci, 2001).

Diversos sistemas hídricos foram e ainda são projetados e operados a partir da hipótese de estacionariedade das séries hidrológicas (de Souza et al., 2013). Essa suposição pressupõe que o comportamento da variável hidrológica permanecerá constante ao longo da vida útil do empreendimento. A estacionariedade traz a ideia de que os processos nos sistemas naturais ocorrem dentro de um envelope imutável de variabilidade após a exclusão de flutuações aleatórias (Milly et al., 2008). Ou seja, as propriedades das séries hidrológicas não se alteram significativamente ao longo do tempo. Assim, na análise de frequência de cheias estacionária, os parâmetros da função densidade de probabilidade (PDF) que modelam o comportamento das cheias permanecem constantes, resultando em probabilidades de excedência constantes para eventos extremos de cheias (ANA, 2016; Kiang et al., 2011; Milly et al., 2008; Naghettini & Pinto, 2007; Read & Vogel, 2015).

Como o processo de formação de cheias é influenciado pelas condições na bacia hidrográfica, alterações em tais condições podem acarretar mudanças no comportamento das cheias. Na suposição de estacionariedade, essas variações são consideradas suficientemente pequenas a ponto de se aceitar a invariabilidade das condições da bacia (Milly et al., 2008; Salas & Obeysekera, 2014). Entretanto, a premissa de estacionariedade nem sempre pode ser verificada quando essas alterações se tornam significativas em consequência da influência dos mecanismos de mudanças das cheias, como variações climáticas, mudanças no uso e ocupação do solo e construção e operação de obras hidráulicas, por exemplo (ASCE, 2018; Blöschl et al., 2015; IPCC, 2021; Merz et al., 2012; Milly et al., 2008; Salas & Obeysekera, 2014). Alterações significativas podem afetar tanto a frequência quanto a intensidade das cheias, e consequentemente nos seus efeitos perante a sociedade, levando à suposição da estacionariedade ser questionada e ao avanço em estudos relacionados a não estacionariedade (Milly et al., 2008; Read & Vogel, 2015).

A não estacionariedade parte da proposição da variabilidade dos dados hidrológicos. Envolve a presença de tendências, e/ou saltos, e/ou quebras, e/ou periodicidade nas séries históricas, como resultado da influência dos mecanismos de mudanças das cheias (ANA, 2016; Naghettini & Pinto, 2007; Salas & Obeysekera, 2014). A análise de frequência de cheias não estacionárias se distingue das estacionárias ao modelar as séries históricas de cheias por funções de probabilidades com padrões estatísticos (parâmetros e/ou momentos da função) que variam ao longo da série de dados, o que provoca alterações nas

probabilidades de excedência e nos quantis de cheias no decorrer do tempo (Read & Vogel, 2015; Salas & Obeysekera, 2014), como pode ser visto na Figura 3.2.

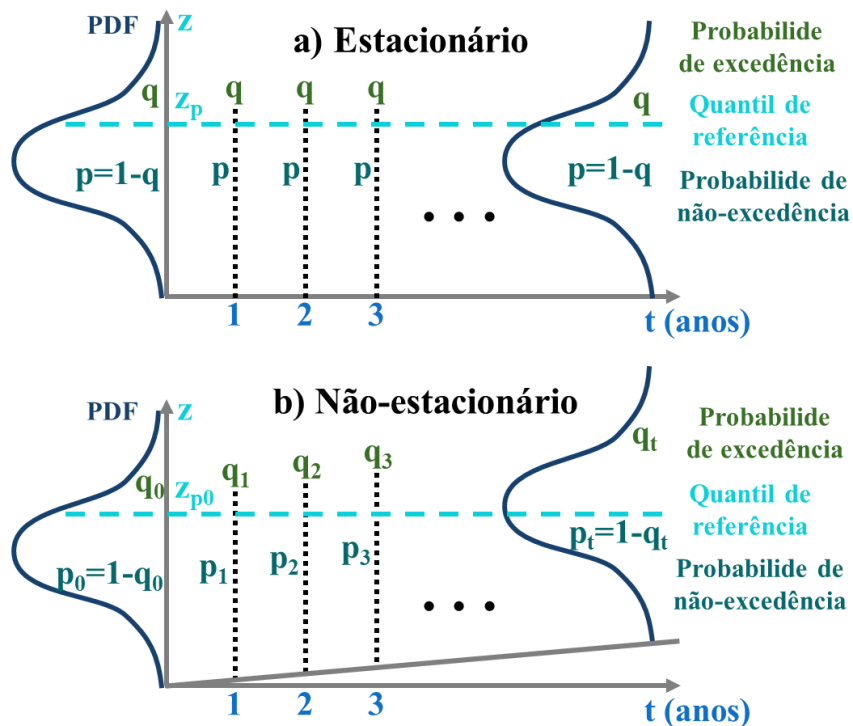


Figura 3.2 - Esquema representando o quantil de cheias de referência (Z_{p_0}) para a suposição da: a) estacionariedade da série com probabilidade de excedência (q) e não excedência (p) constantes no tempo, e da b) não estacionariedade com probabilidade de excedência (q_t) e não excedência (p_t) variantes no tempo (adaptado de Salas & Obeysekera, 2014).

É importante destacar que apesar dos avanços alcançados nos últimos anos em relação às cheias e da crescente atenção dada aos possíveis mecanismos de mudanças de cheias, ainda não existe um consenso sobre como conduzir as análises de frequências. Questiona-se a validade da premissa da estacionariedade e sobre o uso da suposição da não estacionariedade na modelagem de séries hidrológicas. Milly et al. (2008) mencionam que a “estacionariedade está morta” devido as significativas mudanças hidroclimatológicas que acarretam alterações tanto nas médias quanto nos extremos de eventos de precipitação, evapotranspiração e taxas de descarga dos rios. Outros trabalhos como de Montanari & Koutsoyiannis (2014) cujo título aborda sobre a imortalidade da estacionariedade, de Serinaldi & Kilsby (2015) e de Luke et al. (2017) questionam a adequabilidade e sugerem cautela no uso de modelos não estacionários. Tais autores abordam sobre a importância das relações determinísticas que

expliquem a evolução do processo hidrológico analisado no tempo antes de desconsiderá-lo estacionário e considerá-lo não estacionário.

No estudo da não estacionariedade, a busca por compreender a evolução do processo de cheias ao longo da série histórica e no futuro, considerando a interação entre os mecanismos de mudanças e as condições da bacia hidrográfica é complexa. Há a possibilidade de vários cenários nas bacias em escala temporal e espacial. Essa complexidade na compreensão e no estudo de cheias no contexto não estacionário traz alto grau de incerteza associada à capacidade de detectar, atribuir e modelar as tendências nas séries históricas; e a uma incerteza ainda maior nas estimativas de tendências hidrológicas (Koutsoyiannis & Montanari, 2015; Luke et al., 2017; Serago & Vogel, 2018; Serinaldi & Kilsby, 2015). Mesmo quando há uma conexão entre o processo hidrológico e a não estacionariedade dos dados, ainda há incerteza na análise de frequência de cheias devido ao uso de modelos não estacionários, o que deve ser considerado ao comparar o modelo estacionário com o não estacionário (Luke et al., 2017; Salas et al., 2018).

É importante ressaltar que a seleção de um modelo não estacionário é uma opção, e não uma solução universal na modelagem (Montanari & Koutsoyiannis, 2014), mas que deve ser considerada diante dos efeitos das cheias na sociedade. Em bacias com inclinações positivas/negativas, ao somente considerar a premissa de estacionariedade dos dados, pode haver a subestimação/superestimação de cheias (Šraj et al., 2016). Uma subestimação em um cenário em que a margem de segurança para o modelo estacionário é superada pelas ocorrências pode acarretar um risco de inundação maior, comprometimento nas estruturas hídricas e civis, no abastecimento de água e na qualidade da água (Salas et al., 2018; Salas & Obeysekera, 2014; Šraj et al., 2016). Contudo, uma bacia que apresente uma tendência positiva/negativa em uma análise não estacionária em um certo período, mas, que em outro ou até no mesmo intervalo de tempo evidencie um comportamento estacionário, ou uma inclinação negativa/positiva pode acarretar também em uma subestimação, ou superestimação de cheias (Luke et al., 2017).

Neste contexto, para uma análise mais eficiente e com maior grau de confiança na frequência de cheias considerando a premissa de não estacionariedade, é imprescindível a disponibilidade, continuidade e qualidade das observações (Milly et al., 2008; Montanari & Koutsoyiannis, 2014; Naghettini & Pinto, 2007). A quantidade de dados é responsável pela

representatividade da amostra e confiabilidade dos parâmetros calculados na análise (Milly et al., 2008; Montanari & Koutsoyiannis, 2014; Naghettini & Pinto, 2007). Em análises de séries de dados curtas, conclusões equivocadas podem ser alcançadas, como classificar erroneamente um evento de longa memória como não estacionário devido a tendências em um período específico, quando, na verdade, a bacia apresenta características estacionárias no geral (Koutsoyiannis, 2011; Salas et al., 2018).

Como há a ausência de uma teoria geral, especificamente voltada ao comportamento assintótico de valores extremos em que a não estacionariedade seja considerada (Coles, 2001), e na busca de métodos que melhor descrevam o comportamento das cheias e os seus mecanismos de mudança, pesquisadores procuram adaptar modelos estatísticos existentes de forma a considerar a não estacionariedade das séries, mas ainda sem um consenso (Milly et al., 2008; Read & Vogel, 2015; Serago & Vogel, 2018; Šraj et al., 2016). Na Tabela 3.3 são apresentados alguns exemplos de trabalhos, organizados por ordem alfabética, relacionados à análise de frequência de cheias em todo o mundo. Nessa tabela é possível observar abordagens comuns em análises da frequência de cheias não estacionárias, que são baseadas em distribuições usuais em estudos de cheias originadas ou da teoria clássica dos valores extremos, como as distribuições de Gumbel, Fréchet, Weibull e Generalizada de Valores Extremos (GEV), ou de teorias não extremas como Pearson III, Log-Pearson III (LPIII) e Log-Normal de dois parâmetros (LN2) (Naghettini & Pinto, 2007; Salas et al., 2018; Salas & Obeysekera, 2014; Serago & Vogel, 2018). Essas distribuições são adaptadas pela combinação de funções de densidade de probabilidade (PDF) com parâmetros e/ou momentos relacionados as covariáveis (mecanismos de mudanças das cheias) que variam ao longo do período (Salas & Obeysekera, 2014; Serago & Vogel, 2018). Na Tabela 3.3 observa-se a predominância das PDF modeladas em função do Tempo, e não em covariáveis influentes explicativas, uma vez que os mecanismos de mudança (covariáveis) frequentemente não são conhecidos previamente e podem interagir de diferentes formas no tempo e no espaço (Harrigan et al., 2014; Merz et al., 2012).

Tabela 3.3 - Exemplos de trabalhos com análises de frequência de cheias. κ , α e ξ são os parâmetros de forma, de escala e de posição respectivamente, e μ é a média da distribuição.

Referência	Local	Distrib.	Estrutura do modelo não estacionário	Covariável (c)
Anjos et al. (2013)	Paraná - Brasil (América do Sul)	Gumbel	$\xi_c = \xi_0 + \xi_1 \cdot c$ $\alpha_c = \alpha_0 + \alpha_1 \cdot c$	Tempo; Índice climático
Anzolin & Chaffe (2021)	Brasil (América do Sul)	GEV	$\xi_c = \xi_0 + \xi_1 \cdot c$	Tempo; Temperatura; Índice climático; Precipitação
Bartiko et al. (2019)	Sul do Brasil (América do Sul)	LN	$\mu_c = \mu_0 + \mu_1 c$	Tempo
Hesarkazzazi et al. (2021)	Norte da Inglaterra (Europa)	GEV	$\xi_c = \xi_0 + \xi_1 \cdot c$ $\xi_c = \xi_0 + \xi_1 \cdot c_1 + \xi_2 \cdot c_2$	Tempo; Precipitação; Temperatura
Lima et al. (2015)	Manaus - Brasil (América do Sul)	GEV Gumbel Gaussiano LP3	$\xi_c = \xi_0 + \xi_1 \cdot c_1 + \xi_2 \cdot c_2$ $\alpha_c = e^{\alpha_0 + \alpha_1 \cdot c}$ $\alpha_c = e^{\alpha_0 + \alpha_1 \cdot c + \alpha_2 \cdot c_2}$	Tempo; Índice climático
Luke et al. (2017)	Estados Unidos (América do Norte)	LP3	$\mu_c = \mu_0 + \mu_1 c$	Tempo
Mondal & Daniel (2019)	Kerala - Índia (Ásia)	GEV	$\xi_c = \xi_0 + \xi_1 \cdot c$ $\alpha_c = e^{\alpha_0 + \alpha_1 \cdot c}$	Tempo
Obeysekera & Salas (2014)	New Jersey - USA (América do Norte)	Gumbel; GEV	$\xi_c = \xi_0 + \xi_1 \cdot c$ $\alpha_c = e^{\alpha_0 + \alpha_1 \cdot c}$ $\kappa_c = \kappa_0 + \kappa_1 \cdot c$	Tempo

Referência	Local	Distrib.	Estrutura do modelo não estacionário	Covariável (<i>c</i>)
Ouarda & Charron (2019)	British Columbia - Canada (América do Norte)	GEV	$\xi_c = \xi_0 + \xi_1 \cdot c$ $\alpha_c = \alpha_0 + \alpha_1 \cdot c$	Tempo; Índice climático
Prosdocimi et al. (2014)	Reino Unido (Europa)	LN	$\mu_c = \mu_0 + \mu_1 c$	Tempo; Precipitação
Prosdocimi & Kjeldsen (2021)	Massachusetts - USA (América do Norte)	GEV	$\xi_c = \xi_0 + \xi_1 \cdot c$ $\xi_c = \xi_0 \cdot e^{\xi_1 \cdot c}$ $\alpha_c = e^{\alpha_0 + \alpha_1 \cdot c}$	Tempo
Serinaldi & Kilsby (2015)	Estados Unidos (América do Norte)	Gumbel	$\xi_c = \xi_0 + \xi_1 \cdot c$ $\alpha_c = e^{\alpha_0 + \alpha_1 \cdot c}$	Tempo
Šraj et al. (2016)	Eslovênia (Europa)	GEV	$\mu_t = \mu_0 + \mu_1 c$ $\alpha_{cv} = e^{\alpha_0 + \alpha_1 \cdot c}$	Tempo; Precipitação
Silva et al. (2011)	São Paulo (Brasil)	Gumbel	$\xi_c = \xi_0 + \xi_1 \cdot c$ $\alpha_c = \alpha_0 + \alpha_1 \cdot c$	Tempo
Vogel et al. (2011)	Estados Unidos (América do Norte)	LN	$\mu_t = \mu_0 + \mu_1 c$	Tempo

Em vários países, o aumento do interesse nas cheias levou a um aumento em pesquisas relacionadas a análises de frequência de cheias, e a inclusão de abordagens não estacionárias em guias com diretrizes sobre a estimação de cheias (Ball et al., 2019; England et al., 2018). No Brasil, apesar de ser um país com densa rede de drenagem, com atuação de diferentes padrões climáticos, com variados usos e ocupações do solo e com alto grau de exposição da população ao risco de inundação fluvial (OCHA, 2020), ainda há relativamente poucos estudos relacionados à análise de frequência de cheias não estacionárias, dada a vastidão do país.

3.3.1 - Análise local

A seleção do modelo, seja estacionário ou não estacionário, que melhor se adeque a cada série de dados hidrológicos é uma etapa crítica e integral na modelagem das cheias, conduzindo a inferências válidas. No caso mais simples de detecção de mudanças, os registros de cheias de cada local são analisados separadamente (Hall et al., 2014), com a seleção do modelo estacionário ou não estacionário por série. Há diversas abordagens possíveis para realizar a seleção de um modelo dentre outros modelos concorrentes para os dados em estudo (Burnham & Anderson, 2004). Na estatística clássica, podem-se identificar três grandes grupos de abordagens, além dos variados métodos baseados em análise Bayesiana.

Uma das três grandes abordagens e bastante popular é a seleção de modelos baseada na realização de testes de hipóteses. Os testes de hipóteses são procedimentos comuns na inferência estatística e envolvem a formulação de uma hipótese na forma de um pressuposto sobre o comportamento probabilístico da população (Naghattini & Pinto, 2007; Wilks, 2005). Um dos testes de hipótese mais comuns é o teste da razão de verossimilhança (*Likelihood Ratio Test*, TRV) (AghaKouchak et al., 2013; Coles, 2001; Wilks, 2005). Essa popularidade ocorre em parte devido às suas propriedades estatísticas ótimas quando os modelos analisados são aninhados, ou seja, quando um modelo é um subconjunto do outro (*nested models*), anulando um ou mais parâmetros na hipótese alternativa, o que torna o modelo matematicamente equivalente à hipótese nula.

O segundo grupo de abordagens baseia-se na análise de erros preditivos, como o método fundamentado na métrica Erro de Predição Final (*Final Prediction Error*, FPE), introduzido por Akaike (1969), com o intuito de reduzir a chance de escolher modelos com excesso de parâmetros. A métrica FPE levou ao desenvolvimento posterior de vários outros métodos, um exemplo bastante popular é a estatística C_p desenvolvida por Mallows (1973), a qual é amplamente utilizada em modelos de regressão linear. Ainda dentro dessa linha baseada em erros preditivos, podem-se incluir métodos baseados em estudos de validação cruzada e na técnica de *Bootstrap* (Burnham & Anderson, 2004; Douglas et al., 2000; Teegavarapu et al., 2019).

No terceiro grupo, as abordagens são baseadas no critério de informação (*information criterion*), vinculadas ao conceito de distância de *Kullback-Lieber*, um dos pilares da Teoria da Informação (Burnham & Anderson, 2004). Um exemplo proeminente é o Critério de Informação de Akaike (*Akaike Information Criteria*, AIC), desenvolvido por Akaike (1992). Esse critério é baseado

na minimização do valor esperado da distância de *Kullback-Lieber* (AghaKouchak et al., 2013; Burnham & Anderson, 2004; Fabozzi et al., 2014; Raftery, 1995). Outro critério de seleção, bastante similar ao AIC, é o Critério de Informação Bayesiano (*Bayesian Information Criteria*, BIC), desenvolvido por Schwarz (1978). Esse segundo critério é definido em termos da probabilidade *a posteriori*, e apesar de ter o termo Bayesiano em seu nome, Schwarz (1978) somente usou um argumento Bayesiano para provar seu critério (AghaKouchak et al., 2013; Burnham & Anderson, 2004; Fabozzi et al., 2014; Raftery, 1995).

Os três grandes grupos são usados em análises de não estacionariedade de eventos hidrológicos, como as cheias, como pode ser visto na Tabela 3.4. Nessa tabela, são apresentados os modelos de seleção dos estudos de análises de frequência de cheias citados anteriormente na Tabela 3.3. Observa-se a presença significativa dos grupos de abordagens que incluem os critérios de informação e os testes de hipótese. Também é recorrente o uso de mais de um método de seleção por estudo.

Tabela 3.4 - Exemplos de trabalhos relacionados a análises de frequência de cheias com seus métodos de seleção local.

Referência	Grupo	Método
Anjos et al. (2013)		Q-Q Plot
	Erros Preditivos	Validação cruzada
Anzolin & Chaffe (2021)	Critério de Informação	AIC
	Critério de Informação	BIC
	Erros Preditivos	Validação
Bartiko et al. (2019)	Teste de hipótese	t de <i>Student</i>
	Teste de hipótese	Anderson-Darling
Hesarkazzazi et al. (2021)	Critério de Informação	AIC
Lima et al. (2015)	Critério de Informação	BIC
	Teste de hipótese	TRV
Luke et al. (2017)	Critério de Informação	AIC
	Critério de Informação	BIC
	Critério de Informação	DIC
Mondal & Daniel (2019)	Teste de hipótese	TRV

Referência	Grupo	Método
Obeysekera & Salas (2014)	Critério de Informação	AIC
	Teste de hipótese	Estatística de Desvio
Ouarda & Charron (2019)	Critério de Informação	AIC
	Critério de Informação	BIC
Prosdocimi et al. (2014)	Teste de hipótese	Mann-Kendal (MK)
Prosdocimi & Kjeldsen (2021)		Q-Q Plot
Serinaldi & Kilsby (2015)		Q-Q Plot
Šraj et al. (2016)	Critério de Informação	AIC
	Critério de Informação	DIC
	Teste de hipótese	TRV
Silva et al. (2011)		Q-Q Plot
	Erros Preditivos	Validação cruzada
Vogel et al. (2011)	Teste de hipótese	Teste t de <i>Student</i>

3.3.2 - Análise regional

O processo de seleção do modelo mais adequado para um dado local é incerto por natureza, uma vez que a disponibilidade limitada de séries de dados para realizar a inferência resulta em incertezas que afetam os resultados, independentemente do método empregado (Montgomery & Nyhan, 2010). Em estudos de detecção de tendências que analisam várias séries em uma determinada região, as incertezas associadas à seleção de modelos estacionários ou não estacionários podem aumentar quando se realiza apenas a análise de modelos sob uma perspectiva local, utilizando como por exemplo os métodos apresentados na seção anterior (3.3.1). Fato que ocorre ao não se considerar os resultados obtidos pelo mesmo processo de seleção quando aplicado às séries das outras estações da região, ou seja, não se considera as evidências existentes para as definições daquelas estações na região em que se considera a presença de tendências (Douglas et al., 2000; Renard et al., 2008; Svensson et al., 2006).

Em análises envolvendo várias séries localizadas em uma mesma região que envolvam múltiplas inferências, é comum recorrer à lógica estatística baseada em testes de hipóteses para avaliar a coerência dos resultados. O uso descuidado de procedimentos de inferência

baseados numa análise puramente local, sem uma perspectiva regional do problema, pode resultar em interpretações equivocadas sobre o que acontece na região, acarretando num aumento significativo da taxa de falsos-positivos (significância) e causando o efeito chamado de multiplicidade (Benjamini & Hochberg, 1995; Hall et al., 2014). Os falsos-positivos representam o Erro Tipo I, que ocorre quando se declara uma hipótese como verdadeira quando, na realidade, é falsa (Benjamini & Hochberg, 1995; Hall et al., 2014; Ventura et al., 2004), ou seja, quando se declara a não estacionariedade dos dados, mas, na verdade, a série é estacionária. No contexto das cheias, a avaliação simultânea de métodos localmente, por estação, pode levar a essa multiplicidade, afetando os resultados relacionados à detecção de alterações, e assim provocar o inflacionamento do número de séries com tendências significativas em uma região (de Souza & Reis, 2021; Souza et al., 2020).

Portanto, é importante analisar o conjunto de séries de uma região como um todo e selecionar modelos estacionários ou não estacionários em uma perspectiva regional. Isso permite aumentar o poder de detecção de tendências, reduzindo a presença de ruídos nas séries e, conseqüentemente, as incertezas associadas. E assim, é possível identificar com maior confiança mudanças consistentes entre diferentes séries em uma mesma região (Hall et al., 2014; Petrow & Merz, 2009). Dois mecanismos estatísticos usados que visam controlar a probabilidade de cometer o Erro Tipo I na região quando há comparações simultâneas são o *Family-Wise Type I Error (FWER)* e o *False Discovery Rate (FDR)* (Amorim, 2018; Bader et al., 2017).

O mecanismo FWER (Shaffer, 1995) é definido como a probabilidade de se ter pelo menos uma falsa rejeição ao realizar inferências simultâneas nas estações de uma região. Um exemplo de método que utiliza o mecanismo FWER é o teste de Bonferroni. O FDR (Benjamini & Hochberg, 1995; Ventura et al., 2004) é outro mecanismo a ser considerado, identificando o conjunto de testes significativos no local ao controlar a proporção esperada de hipóteses nulas falsamente rejeitadas, mas que são efetivamente verdadeiras (falsos-positivos).

Na Tabela 3.5 é possível observar estudos hidrológicos, não apenas análises de frequência de cheias, que ao realizarem análises regionais da não estacionariedade, utilizaram os mecanismos mencionados anteriormente, controlando a taxa de erros. Estudos que se

preocupem em avaliar não só localmente os modelos que melhor se adequam às séries, mas também avaliar de forma regional, não são abundantes, apesar de sua importância na redução das incertezas das análises (Renard et al., 2008; Souza et al., 2020; Svensson et al., 2006).

Tabela 3.5 - Exemplos de trabalhos relacionados a não estacionariedade hidrológica com seus mecanismos de seleção regional.

Referência	Variável	Método	
		Local	Regional
Brenning (2005)	Deslizamento de terra	t de <i>Student</i>	FWER
Cammalleri et al. (2016)	Seca no solo	MK	FDR
Peñas et al. (2016)	Vazão	t de <i>Student</i>	FWER
Mallya et al. (2015)	Seca	MK	FDR
Sheng et al. (2017)	Florestamento/reflorestamento	AIC	FWER
de Souza & Reis (2022)	Vazão	MK	FDR
Sun et al., (2015)	Precipitação	Teste de Kolmogorov-Smirnov	FDR
Tramblay et al. (2013)	Precipitação	MK	FDR
Tramblay & Hertig (2018)	Seca	AIC BIC TRV	FDR

4 - METODOLOGIA

4.1 - ESTRATÉGIA DE AÇÃO

Com o foco em detectar, modelar e avaliar o comportamento não estacionário em séries de vazões máximas anuais em níveis local e regional mediante modelos estatísticos, realizou-se uma abordagem metodológica com as etapas apresentadas no fluxograma da Figura 4.1. Na Figura 4.1, além da apresentação das etapas e subetapas metodológicas, é possível observar também como a realização das etapas e subetapas permite a efetivação dos objetivos específicos apresentados na seção 2.2.

A estratégia na abordagem metodológica consiste em selecionar inicialmente as séries históricas de vazões máximas anuais a serem usadas na análise de frequência de cheias com base nos critérios apresentados na seção 4.3.1. Esses critérios são aplicados ao estudo de caso da Região Hidrográfica (RH) do Uruguai. Após selecionar os dados, realiza-se a análise de frequência de cheias, conforme descrito no item 4.2, com a utilização de modelos baseados na premissa da estacionariedade e da não estacionariedade (seção 4.2.2). Todos os modelos são oriundos da distribuição de probabilidade Generalizada de Valores Extremos (GEV) (item 4.2.1). Os modelos não estacionários são elaborados com base em três abordagens distintas, que envolvem variações de diferentes formas nos parâmetros da distribuição GEV (seção 4.2.2) ao longo do tempo, em função de covariáveis (mecanismos de mudanças das cheias) relevantes na região de interesse. Na seção 4.3.2 é detalhada as covariáveis de interesse da RH Uruguai. Com a modelagem dos modelos propostos na análise de frequência de cheias considerando cada covariável, seleciona-se a nível local através da avaliação do BIC, o modelo estatístico que melhor se ajusta à série de cheias, item descrito em 4.2.5. Os modelos não estacionários selecionados por BIC são submetidos a mais uma avaliação, agora a nível regional, com o intuito de controlar o Erro Tipo I na região, evitando assim um excesso de falsas detecções. Essa avaliação consiste no uso do FDR, detalhado na seção 4.2.6. Após a aplicação do FDR, avalia-se a seleção dos modelos não estacionários por meio do levantamento e análise das incertezas associadas aos parâmetros dos modelos não estacionários através de intervalos de confiança (item 4.2.4). Identificado o modelo que melhor representa cada séries de vazões máximas anuais, considerando as covariáveis, pode-se detectar possíveis repercussões da não estacionariedade ao analisar o comportamento não estacionário considerando os mecanismos de mudanças nas séries de

cheias. Etapa que pode ser feita a partir da análise dos quantis de cheias (secção 4.2.1) associados às suas incertezas (item 4.2.4) e das taxas de mudança nos quantis de cheia de 50 anos ao longo do tempo, obtidas pelos modelos não estacionários selecionados.

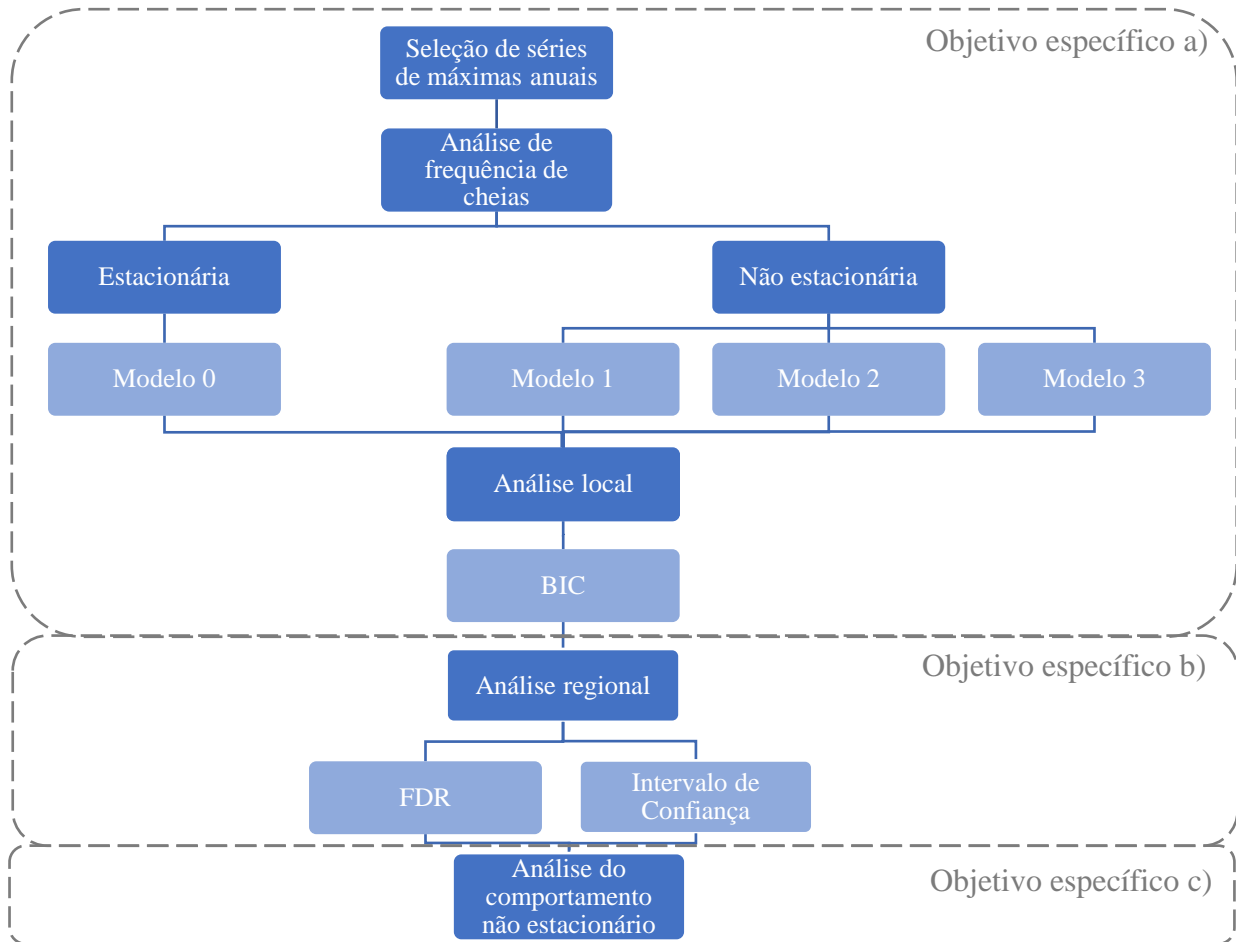


Figura 4.1 - Fluxograma do trabalho, com etapas (azul escuro) e subetapas (azul claro) metodológicas necessárias para o alcance dos objetivos propostos.

4.2 - ANÁLISE DE FREQUÊNCIAS DE CHEIAS

4.2.1 - Distribuição Generalizada de Valores Extremos

A distribuição escolhida para a realização da análise de frequência de cheias foi a distribuição Generalizada de Valor Extremo (GEV). Essa escolha se deve ao fato de ser uma das distribuições mais relevantes e usuais em cenários de alterações climáticas e na modelagem de séries de extremos hidrológicos (AghaKouchak et al., 2013; Committee on Adaptation to a Changing Climate, 2018; Salas et al., 2018 ex. Anzolin & Chaffe, 2021; Mondal & Daniel, 2019; Prosdocimi & Kjeldsen, 2021; Šraj et al., 2016). A utilidade da

GEV na modelagem de extremos está relacionada à teoria de valor extremo bem desenvolvida dessa distribuição (Coles, 2001; Naghettini & Pinto, 2007; Salas et al., 2018).

A distribuição Generalizada de Valores Extremos foi introduzida em Mises (1936) e em Jenkinson (1955). É uma distribuição que combina às três formas assintóticas de valores extremos em uma única família de modelos com três parâmetros: forma (κ), escala (α) e posição (ξ). Às três distribuições de valores extremos são: Gumbel, Fréchet e Weibull (Coles, 2001; Salas et al., 2018; Wilks, 2005). A união das três famílias elimina a necessidade de calcular e escolher individualmente entre as três famílias, reduzindo a incerteza de presumir erroneamente que uma das três distribuições se ajusta melhor à série histórica do que outra.

A função de distribuição acumulada (FAP) da distribuição Generalizada de Valores Extremos (GEV) é dada pela Equação (4.1) (Coles, 2001):

$$F(x) = \begin{cases} \exp \left\{ - \left[1 - \kappa \left(\frac{x - \xi}{\alpha} \right) \right]^{\frac{1}{\kappa}} \right\}, & \kappa \neq 0 \\ \exp \left[- \exp \left(- \frac{x - \xi}{\alpha} \right) \right], & \kappa = 0 \end{cases} \quad (4.1)$$

em que, $F(x)$ é a função de distribuição acumulada; ξ , α e κ são os parâmetros de posição, de escala e de forma respectivamente; x é o dado da amostra. O valor e o sinal do parâmetro de κ determinam a forma assintótica dos valores extremos máximos, definindo o comportamento da cauda da distribuição. Quando o parâmetro $\kappa < 0$, a distribuição GEV representa a distribuição de Fréchet (Tipo II, forma exponencial simples). Para $\kappa > 0$, a distribuição converge para a família de Weibull (Tipo III, forma exponencial com limite superior para máximos ou inferior para mínimos). No caso de $\kappa = 0$, a distribuição GEV se reduz à distribuição Gumbel (Tipo I, forma dupla exponencial), que possui dois parâmetros: escala e posição (Coles, 2001).

A utilização de distribuições de probabilidade na modelagem de cheias permite uma descrição do comportamento das vazões máximas por meio dos quantis de cheia x_p . A

função quantil de GEV é obtida por meio da função inversa da distribuição acumulada, Equação (4.2) (Coles, 2001):

$$x_p = \begin{cases} \xi + \frac{\alpha}{\kappa} \cdot [1 - (-\ln p)^\kappa], & \kappa \neq 0 \\ \xi - \alpha \cdot \ln(-\ln p), & \kappa = 0 \end{cases} \quad (4.2)$$

em que, p é a probabilidade de não excedência, ou seja, a probabilidade de que essa vazão não seja igualada ou superada em um ano qualquer, conforme ilustrado na Figura 3.2. No presente estudo, a análise do comportamento não estacionário das cheias ocorreu principalmente por meio da análise dos quantis de cheias de 50 anos, quando a probabilidade de excedência (q) da vazão ser igualada ou superada é de 2% do tempo ($Q_{0.98}$), ou seja, $p = 98\%$ na Equação (4.2). Outro quantil de cheias levantado é o de 2 anos ($Q_{0.50}$), com $p = 50\%$ na Equação (4.2). Tanto o $Q_{0.98}$ quanto o $Q_{0.50}$ são valores usualmente utilizados no planejamento e gerenciamento hídrico, como em casos de projetos e operações de estruturas hidráulicas, para obter o nível de segurança do empreendimento (Collischonn & Tassi, 2008).

4.2.2 - Modelos estatísticos

Com a falta de uma teoria geral assintótica de valores extremos sob a condição de não estacionariedade (Coles, 2001), optou-se, no presente trabalho, por uma estratégia usual na análise não estacionária de cheias: a regressão dos parâmetros da distribuição (Coles, 2001; Salas et al., 2018; ex. Anzolin & Chaffe, 2021; Mondal & Daniel, 2019; Prosdocimi & Kjeldsen, 2021; Silva et al., 2012). Nessa estratégia, os parâmetros da distribuição podem ser modelados de diferentes formas como uma função do mecanismo de mudança (covariável) da variável hidrológica de interesse que varia ao longo do tempo por meio de equações de regressões (Coles, 2001; Salas et al., 2018). Obeysekera & Salas (2014) sugerem métodos que permitem a estimação das incertezas nos quantis de cheias modeladas pelas regressões dos parâmetros, possibilitando uma maior confiança no uso dessa estratégia (Slater et al., 2021).

Sem ainda um consenso em como os parâmetros na regressão devem variar ao longo do tempo, o presente trabalho optou por testar três modelos estatísticos com propostas diferentes que consideram a não estacionariedade dos dados. Essas propostas já foram levantadas e

utilizadas em estudos de cheias, na busca do modelo que melhor represente o comportamento das séries de vazões máximas na área de interesse. Assim, a análise de frequência de cheias no presente estudo consistiu na aplicação de três modelos estatísticos não estacionários e um estacionário, todos baseados na aplicação da distribuição de GEV às séries anuais de vazões máximas anuais, conforme apresentado na Tabela 4.1. No Modelo 0, adota-se o pressuposto da estacionariedade das cheias, ou seja, os parâmetros não variam ao longo do tempo, permanecendo constantes $x \sim \text{GEV}(\xi, \alpha, \kappa)$.

Para os outros três modelos restantes, Modelo 1, Modelo 2 e Modelo 3 (modelos não estacionários), os parâmetros de GEV são funções de covariáveis que evoluem ao longo do tempo. Nos três modelos não estacionários, o parâmetro de posição (ξ) é função de uma covariável que varia linearmente no tempo, uma premissa usual na análise de cheias não estacionária (Anzolin & Chaffe, 2021; Prosdocimi & Kjeldsen, 2021; Silva et al., 2012) e sugerida em AghaKouchak et al. (2013) e Coles (2001). O parâmetro de escala (α) é modelado de maneira diferente para cada modelo não estacionário, como pode ser visto na Tabela 4.1. E o parâmetro de forma (κ) é mantido constante devido ao grande grau de incerteza associado à sua estimativa (AghaKouchak et al., 2013; Coles, 2001).

Tabela 4.1 - Parâmetros (posição (ξ), escala (α) e forma (κ)) da distribuição GEV para os quatro modelos estatísticos propostos (Modelo 0, 1, 2 e 3).

Modelo	Parâmetros de GEV			$x \sim \text{GEV}$
	ξ	α	κ	
0	ξ	α	κ	(ξ, α, κ)
1	$\xi(c) = \xi_0 + \xi_1 \cdot \Delta c$ $= \xi_0[1 + r_1 \cdot \Delta c]$	$\alpha(c) = \frac{\xi_0[1 + r_1 \cdot \Delta c]}{\xi_0/\alpha_0}$	κ	$(\phi, \xi_0, r_1, \kappa)$
2	$\xi(c) = \xi_0 + \xi_1 \cdot \Delta c$ $= \xi_0[1 + r_1 \cdot \Delta c]$	α	κ	$(\xi_0, r_1, \alpha, \kappa)$
3	$\xi(c) = \xi_0 + \xi_1 \cdot \Delta c$ $= \xi_0[1 + r_1 \cdot \Delta c]$	$\alpha(c) = \exp(\beta_0 + \beta_1 \cdot \Delta c)$	κ	$(\xi_0, r_1, \beta_0, \beta_1, \kappa)$

Na Tabela 4.1, Δc representa a variação do índice da covariável a ser analisada; e na equação de regressão do parâmetro de posição, ξ_0 e $r_1(\xi_1/\xi_0)$ são os parâmetros que devem ser estimados. O uso de r_1 é mais adequado em uma análise regional, na comparação entre séries

de diferentes estações, devido à relação direta entre os dois parâmetros ξ_0 e ξ_1 , o que possibilita o conhecimento da variação relativa entre esses parâmetros.

No Modelo 1 apresentado na Tabela 4.1, adotou-se a hipótese de que o coeficiente de variação (C_v) da distribuição seja constante ao longo do tempo. Essa hipótese não é habitualmente utilizada em cenários de alterações de extremos, mas é comum nas estimativas baseadas em séries de extremos ambientais. (Blanchet et al., 2018; Prosdocimi & Kjeldsen, 2021; Serago & Vogel, 2018). O uso habitual em estudos de extremos torna o levantamento da hipótese do C_v constante em análises de mudanças nas cheias (Prosdocimi et al., 2014; Prosdocimi & Kjeldsen, 2021; Vogel et al., 2011) uma hipótese interessante a ser testada.

O coeficiente de variação pode ser obtido pela primeira parte da Equação (4.3), em que $C_v = \frac{\sqrt{Var}}{\mu}$, podendo ser definido em função dos parâmetros, como demonstrada pela segunda parte da Equação (4.3). Quando se permite somente a livre variação do parâmetro de posição (ξ), os coeficientes de escala (α) e de forma (κ) permanecem constantes. O κ constante faz com que a variância da série (Var) também se mantenha constante. Já a variação de ξ mais o α constante acarreta μ variando, o que leva a variação de C_v (Serago & Vogel, 2018). Com o intuito de manter o coeficiente de variação (C_v) da distribuição GEV constante, como pode ser visto na parte três da Equação (4.3), o parâmetro de escala deve variar em função do parâmetro de posição para fornecer a compensação necessária (Salas & Obeysekera, 2014; Serago & Vogel, 2018).

$$C_v = \frac{\sqrt{Var}}{\mu} = \frac{\frac{1}{|\kappa|} \cdot [\Gamma(1 + 2 \cdot \kappa) - \Gamma^2(1 + \kappa)]^{\frac{1}{2}}}{\frac{\xi}{\alpha} + \frac{1}{\kappa} [1 - \Gamma(1 + \kappa)]} = \frac{C_0(\kappa)}{\phi + C_1(\kappa)} \quad (4.3)$$

em que, $\phi = \xi/\alpha$; e $C_0(\kappa)$ e $C_1(\kappa)$ são constantes no Modelo 1, pois o parâmetro de forma (κ) é mantido fixo no tempo.

No último modelo (Modelo 3) proposto na Tabela 4.1, a equação de regressão do parâmetro de escala é constituída por uma função exponencial que varia ao longo do tempo e que deve ser estritamente positiva, $\alpha_c > 0$ (AghaKouchak et al., 2013; Coles, 2001; ex. Mondal &

Daniel, 2019; Serinaldi & Kilsby, 2015; Šraj et al., 2016). Nesse modelo, β_0 e β_1 são os parâmetros a serem estimados.

4.2.3 - Estimativa de parâmetros

Para definir uma distribuição de probabilidade que melhor descreva as características probabilísticas da variável hidrológica, é necessário estimar os parâmetros da distribuição por meio de inferência estatística. A inferência estatística permite associar a realidade física das observações à concepção abstrata da função de distribuição de probabilidade da variável hidrológica. Um modo de inferência estatística é a estimativa pontual, que relaciona a atribuição de um único valor ao parâmetro populacional por meio de estatísticas amostrais. Dentro dessa abordagem há diversas formas de estimar os parâmetros, como o método dos momentos (MOM), dos momentos-L (MOM-L), de máxima verossimilhança (ML) e de máxima verossimilhança generalizada (GML) (Katz et al., 2002; Naghettini & Pinto, 2007).

No presente estudo, optou-se pelo método da máxima verossimilhança generalizada (GML) para estimar os parâmetros da distribuição GEV nos quatro modelos propostos (Modelo 0, 1, 2 e 3). A escolha do GML como método de estimativa deve-se à capacidade de limitar os valores do parâmetro de forma (κ). Em estudos de cheias, é possível inserir informações históricas e regionais com o uso do método do GML, construindo assim intervalos para os valores do parâmetro de forma que se restrinjam a faixas fisicamente e estatisticamente razoáveis e compatíveis com valores observados pelo mundo. Isso resulta em estimativas mais precisas para os parâmetros da distribuição, considerando tanto a suposição de estacionariedade quanto a de não estacionariedade (AghaKouchak et al., 2013; Alexandre et al., 2008; El Adlouni et al., 2007; Khaliq et al., 2006; Martins & Stedinger, 2000).

Martins & Stedinger (2000) abordam sobre como o método de máxima verossimilhança (ML) para amostras pequenas resulta em estimativas irreais para o parâmetro de forma (κ), e propõem assim o método de máxima verossimilhança generalizada (GML). O GML é baseado nos mesmos princípios do método de ML, no qual os parâmetros são estimados maximizando os logaritmos da função de verossimilhança, com a adição de uma distribuição *a priori* para restringir o valor do parâmetro κ com o intuito de eliminar valores potencialmente inválidos desse parâmetro.

O método GML consiste na estimativa dos parâmetros que maximizem a função de verossimilhança generalizada. Essa função é composta pela função de verossimilhança e a função de distribuição *a priori*. Para o cálculo da função de verossimilhança generalizada é comum usar o logaritmo da função de verossimilhança generalizada em substituição à própria função de verossimilhança generalizada. Esse tipo de substituição também é usual para o cálculo da função de verossimilhança, em que se utiliza o logaritmo da função de verossimilhança, conforme mostrado na Equação (4.4), invés da função de verossimilhança (Martins & Stedinger, 2000). Essa substituição pode ser feita uma vez que a função logarítmica é monotônica, ou seja, a verossimilhança logarítmica atinge o seu máximo no mesmo ponto que a função de verossimilhança, logo, a maximização da função de verossimilhança também ocorre no mesmo ponto da função de verossimilhança logarítmica (Coles, 2001).

$$\ln[L(\boldsymbol{\theta})] = -n \cdot \ln \alpha + \sum_{i=1}^n \left[\left(\frac{1}{\kappa} - 1 \right) \cdot \ln \left[1 - \left(\frac{\kappa}{\alpha} \right) \cdot (x - \xi) \right] - \left[1 - \left(\frac{\kappa}{\alpha} \right) \cdot (x - \xi) \right]^{\frac{1}{\kappa}} \right] \quad (4.4)$$

em que, $\ln[L(\boldsymbol{\theta})]$ é o logaritmo da função de verossimilhança; $\boldsymbol{\theta} = (\kappa, \alpha, \xi)$; κ , α e ξ são os parâmetros de forma, de escala e de posição, respectivamente.

Segundo Martins & Stedinger (2000), é possível supor que o conhecimento sobre o verdadeiro parâmetro κ da distribuição GEV possa ser representado por uma distribuição *a priori* ($\pi(\kappa)$) com intervalo $[\kappa_L; \kappa_U]$. Para a hidrologia, esse intervalo provavelmente estaria entre $[-0.3; 0]$, uma vez que em estudos de cheias, as caudas da distribuição geralmente se tornam mais pesadas quando $\kappa < 0$ (Alexandre et al., 2008; Martins & Stedinger, 2000). Martins & Stedinger (2000) também analisaram as funções de densidade de probabilidade (PDF) da GEV e observaram formas razoáveis para essas PDF quando o intervalo de κ ocorre entre $[-0.3; 0.3]$. Dentro desse intervalo, especificamente em $[-0.3; 0.1]$, as PDF apresentaram assimetria positiva com uma longa cauda superior, um comportamento esperado em picos de cheias.

A distribuição *a priori* adotada em Martins & Stedinger (2000) e adotada no presente estudo foi a distribuição Beta, conforme a Equação (4.5).

$$\pi(\kappa) = \frac{(0,5 + \kappa)^{\alpha_{\kappa}-1} \cdot (0,5 - \kappa)^{\beta_{\kappa}-1}}{[\Gamma(\alpha_{\kappa}) \cdot \Gamma(\beta_{\kappa})]/\Gamma(\alpha_{\kappa} + \beta_{\kappa})} \quad (4.5)$$

em que, o intervalo de κ é $[-0.5; 0.5]$; α_{κ} e β_{κ} são obtidos de modo que a média e a variância de κ sejam iguais a $E[\kappa] = -0.1$ e $Var[\kappa] = (0.122)^2$, respectivamente, resultando em $\alpha_{\kappa} = 6$ e $\beta_{\kappa} = 9$. A escolha da distribuição Beta com esses parâmetros ocorreu devido ao fato de ser uma distribuição *a priori* razoável para o parâmetro de forma em análises de cheias, com *a priori* relativamente suave quando κ está entre $[-0.3; 0.15]$, intervalo de interesse na análise de cheias.

A Equação (4.6) representa o logaritmo da função de verossimilhança generalizada ($\ln[LG(\boldsymbol{\theta})]$) e é composta pela soma do logaritmo da função de verossimilhança (Equação (4.4)) com o logaritmo natural da função da distribuição Beta (Equação (4.5)). A maximização da Equação (4.6) permite a estimativa dos parâmetros de escala, posição e forma para os quatro modelos baseados na distribuição da GEV: Modelo 0: ξ, α, κ ; Modelo 1: ϕ, ξ_0, r_1, κ ; Modelo 2: $\xi_0, r_1, \alpha, \kappa$; Modelo 3: $\xi_0, r_1, \beta_0, \beta_1, \kappa$.

$$\begin{aligned} \ln[LG(\boldsymbol{\theta})] = & -n \cdot \ln \alpha \\ & + \sum_{i=1}^n \left[\left(\frac{1}{\kappa} - 1 \right) \cdot \ln \left[1 - \left(\frac{\kappa}{\alpha} \right) \cdot (x - \xi) \right] - \left[1 - \left(\frac{\kappa}{\alpha} \right) \cdot (x - \xi) \right]^{\frac{1}{\kappa}} \right] \\ & + \ln \left(\frac{(0,5 + \kappa)^{\alpha_{\kappa}-1} \cdot (0,5 - \kappa)^{\beta_{\kappa}-1}}{[\Gamma(\alpha_{\kappa}) \cdot \Gamma(\beta_{\kappa})]/\Gamma(\alpha_{\kappa} + \beta_{\kappa})} \right) \end{aligned} \quad (4.6)$$

4.2.4 - Análise de incertezas

Algumas incertezas resultantes da qualidade das observações e dos erros associados às observações, bem como de suposições incorretas sobre a distribuição utilizada, são mais difíceis de quantificar. Contudo, as incertezas relacionadas aos parâmetros de distribuição e aos quantis de cheia podem ser estimadas e representadas por intervalos de confianças. Essas estimativas são importantes para a compreensão dos modelos de análise de frequência de cheias, considerando tanto a estacionariedade quanto a não estacionariedade, auxiliando no planejamento e gerenciamento de recursos hídricos (Mondal & Daniel, 2019; Obeysekera & Salas, 2014). Para maior compreensão do comportamento das cheias, nesse trabalho

estimou-se as incertezas associadas aos parâmetros dos modelos propostos baseados na distribuição GEV, e aos quantis de cheias obtidos a partir desses modelos (Modelos 0, 1, 2 e 3).

Quando os parâmetros são estimados usando o método de máxima verossimilhança e/ou máxima verossimilhança generalizada (presente caso) é possível estimar as incertezas por meio de métodos paramétricos como o método Delta, métodos não paramétricos como o método de *Bootstrap* e o método de verossimilhança de perfil (Coles, 2001; Obeysekera & Salas, 2014). No presente estudo, optou-se pelo método Delta. Método usado em análises de frequência de cheias não estacionárias para quantificar as incertezas de parâmetros e de quantis, como em Mondal & Daniel (2019), Serinaldi & Kilsby (2015) e Šraj et al. (2016). Essa escolha decorreu devido a esse método possibilitar uma estimativa rápida e eficaz da magnitude da incerteza sem recorrer às simulações de Monte Carlo, além de ser de fácil implementação mesmo em modelos com estruturas complexas (Serinaldi & Kilsby, 2015).

O método Delta tem como base as propriedades assintóticas das estimativas de máxima verossimilhança dos parâmetros do modelo e de sua matriz de covariância. Considera-se a normalidade assintótica dos estimadores da máxima verossimilhança, conforme a Equação (4.7), quando a amostra é suficientemente grande. Com essa consideração, os intervalos de confiança (IC) assintóticos dos parâmetros da distribuição podem ser calculados usando a Equação (4.8) (Coles, 2001)

$$\hat{\theta}_i \sim N(\theta_i, \tilde{\varphi}_{i,i}) \quad (4.7)$$

$$\hat{\theta}_i \pm z_{\alpha_R/2} \cdot \sqrt{\tilde{\varphi}_{i,i}} \quad (4.8)$$

em que, $\hat{\theta}_i$ é o estimador de máxima verossimilhança ou máxima verossimilhança generalizada (no presente caso) do parâmetro θ_i . Neste estudo, os parâmetros da distribuição GEV estimados foram: Modelo 0: ξ, α, κ ; Modelo 1: ϕ, ξ_0, r_1, κ ; Modelo 2: $\xi_0, r_1, \alpha, \kappa$; Modelo 3: $\xi_0, r_1, \beta_0, \beta_1, \kappa$. O $z_{1-\alpha_R/2}$ é o quantil $(1 - \alpha_R/2)$ da variável normal padrão; sendo o α_R o nível de significância, que neste trabalho foi adotado como $\alpha_R = 5\%$, ou seja, um nível de confiança de 95%. E $\tilde{\varphi}_{i,i}$ é o inverso da matriz de Informação de Fisher, $I_0(\hat{\theta})$, como definido na Equação (4.9):

$$I_0(\hat{\theta}) = \begin{bmatrix} -\frac{\partial^2}{\partial \theta_1^2} \ln[LG(\theta)] & \cdots & -\frac{\partial^2}{\partial \theta_d \partial \theta_1} \ln[LG(\theta)] \\ \vdots & \ddots & \vdots \\ -\frac{\partial^2}{\partial \theta_d \partial \theta_1} \ln[LG(\theta)] & \cdots & -\frac{\partial^2}{\partial \theta_d^2} \ln[LG(\theta)] \end{bmatrix} \quad (4.9)$$

Para os modelos não estacionários (Modelos 1, 2 e 3), realizou-se uma avaliação da estimativa do intervalo de confiança assintótico dos parâmetros r_1 (Modelos 1, 2 e 3) e β_1 (Modelo 3). Essa avaliação consistiu em verificar se tais parâmetros são estaticamente diferentes de zero. Séries modeladas pela não estacionariedade em que o intervalo de confiança do parâmetro r_1 e/ou β_1 cruzaram o eixo 0 foram realocadas para o modelo estacionário (Modelo 0).

Se o quantil de X_p é uma função de valor escalar de θ_i , então seu estimador de máxima verossimilhança ou de máxima verossimilhança generalizada (no presente estudo) \hat{X}_p é uma função de valor escalar de $\hat{\theta}_i$ e da Equação (4.10) (Coles, 2001):

$$\hat{X}_p \sim N(X_p, V_{X_p}) \quad (4.10)$$

em que V_{X_p} é a variância do quantil, como definido na Equação (4.11):

$$V_{X_p} = \nabla'_{X_p} V_{\theta} \nabla_{X_p} \quad (4.11)$$

em que V_{θ} é a matriz de variância e covariância, que é a inversa da matriz hessiana dos parâmetros; ∇'_{X_p} é a transposta de ∇_{X_p} ; e ∇_{X_p} pode ser calculado pela Equação (4.12):

$$\nabla_{X_p} = \left[\frac{\partial x_p}{\partial \theta_1}, \dots, \frac{\partial x_p}{\partial \theta_i} \right]' \quad (4.12)$$

V_{X_p} e ∇_{X_p} são avaliados em $\hat{\theta}$. Assim, o intervalo de confiança assintótico dos quantis de cheias obtidos a partir dos modelos (Modelo 0, 1, 2, 3) pode ser calculado pela Equação (4.13):

$$\hat{x}_p \pm \frac{z_{\alpha_L}}{2} \cdot \sqrt{V_{x_p}} \quad (4.13)$$

4.2.5 - Análise local

Dentre os três grandes grupos de abordagens para a seleção de modelos - teste de hipóteses, análise de erros preditivos e critérios de informação - no presente estudo, em análise e avaliação local entre os quatro modelos propostos, optou-se pelo grupo que envolve métodos de seleção baseados nos critérios de informação. A escolha desse grupo foi influenciada pelo fato de possibilitarem a avaliação entre modelos que podem ser submodelos uns dos outros (*nested*) ou não (*non-nested*). Além disso, quando se trata da avaliação do modelo que melhor representa a série entre vários modelos, o emprego de métodos de seleção baseados em critérios de informação se torna mais adequado do que o emprego de testes de hipóteses repetidos, pois, a repetição desses testes pode levar à perda de interpretabilidade dos resultados dos testes (AghaKouchak et al., 2013).

Nesse grupo, dois métodos de seleção baseados em critérios de informação foram escolhidos para este estudo: o critério de informação de Akaike (AIC) e o critério de informação Bayesiano (BIC). Ambos os critérios são populares, sendo usados em análises de não estacionariedade de eventos hidrológicos, como as cheias, como mencionado anteriormente na secção 4.2.5. Ademais, no presente projeto, em que o método GML foi empregado para a estimação dos parâmetros, o AIC e o BIC são hábeis para avaliar os modelos, uma vez que ambos são fundamentados na maximização das funções de verossimilhança (Burnham & Anderson, 2004; Serinaldi & Kilsby, 2015; Wilks, 2005).

Ambos os critérios aplicam uma penalização à verossimilhança para favorecer a seleção do modelo mais parcimonioso dentre um grupo de modelos. A avaliação dos modelos pelos dois critérios envolve um equilíbrio entre a qualidade do ajuste do modelo às observações, representada pelas probabilidades logarítmicas, como mostrado na primeira parte das Equações (4.14) e (4.15); e a penalidade que aumenta à medida que o número de parâmetros do modelo estudado cresce (nível de complexidade do modelo), como ilustrado na segunda parte das Equações (4.14) e (4.15). Essa penalidade tem o propósito de reduzir o excesso de complexidade, o que pode resultar em grandes incertezas quando o modelo é empregado para fazer previsões. A diferença entre o BIC, conforme a Equação (4.15), e o AIC, conforme

a Equação (4.14), consiste na maior penalização imposta pelo número de parâmetros no BIC em comparação ao AIC (AghaKouchak et al., 2013; Burnham & Anderson, 2004; Fabozzi et al., 2014; Raftery, 1995; Wit et al., 2012).

$$AIC(M) = -2 \cdot \ln[LG(\boldsymbol{\theta})] + k \cdot 2 \quad (4.14)$$

$$BIC(M) = -2 \cdot \ln[LG(\boldsymbol{\theta})] + k \cdot \ln m \quad (4.15)$$

em que, $AIC(M)$ e $BIC(M)$ são os valores de AIC e BIC de cada modelo analisado; $\ln[LG(\boldsymbol{\theta})]$ é o valor máximo do logaritmo da função de verossimilhança generalizada, obtido na estimativa dos parâmetros, conforme a Equação (4.6). O termo k é o número de parâmetros do modelo (Modelo 0: 3 parâmetros, Modelo 1 parâmetros: 4 parâmetros, Modelo 2: 4 parâmetros, Modelo 3: 5 parâmetros). E o termo $\ln m$ é o logaritmo do tamanho da série histórica. O modelo que apresentar o menor valor para o critério analisado (AIC ou BIC) entre todos os modelos avaliados pode ser considerado o modelo que melhor se adequa aos dados (AghaKouchak et al., 2013; Burnham & Anderson, 2004; Fabozzi et al., 2014; Raftery, 1995; Wit et al., 2012).

No atual trabalho, foram aplicados e analisados tanto o critério de AIC quanto o de BIC em todas as séries. Na maioria das séries, os modelos selecionados pelo AIC são os mesmos modelos selecionados pelo BIC. Situações divergentes podem ocorrer devido à penalização maior imposta pelo BIC em séries com pelo menos 8 observações ($\ln 8 \approx 2.08$). Portanto, o BIC tende a favorecer modelos mais simples ou com o mesmo grau de complexidade dos modelos selecionados pelo AIC (Blanchet et al., 2018; Wit et al., 2012). Diante das diversas possibilidades de modelagem dos parâmetros das distribuições de probabilidade em função de covariáveis relacionadas ao comportamento dos extremos, como as cheias, é importante considerar o princípio da parcimônia na seleção de modelos, optando por modelos mais simples que possam explicar o máximo possível da variação presente nos dados hidrológicos (Coles, 2001). Logo, optando pela parcimônia, no presente estudo a análise de frequência de cheias se sucedeu a partir da seleção dos modelos pelo BIC, considerado um modelo mais específico e consistente devido à sua base teórica (Burnham & Anderson, 2004; Dziak et al., 2020; Vrieze, 2012; Y. Yang, 2005).

4.2.6 - Análise regional

Na análise regional, para avaliar os modelos selecionados na análise local com base no critério de informação BIC, controlando o Erro Tipo I, dentre os dois mecanismos levantados na secção 3.3.2: *Family-Wise Type I Error* (FWER) e *False Discovery Rate* (FDR), utilizou-se no presente estudo o FDR. A escolha desse mecanismo foi influenciada devido ao fato de o FWER ser restritivo, quando a evidência amostral não é suficientemente forte, não há a rejeição da hipótese nula, o que pode acarretar baixo poder de detecção. Esse problema na restrição aumenta à medida em que o número de estações avaliadas cresce (Amorim, 2018). Além disso, a interpretação dos resultados obtidos com a aplicação do *False Discovery Rate* é mais fácil, uma vez que esse método não depende do número de séries na região. Outra vantagem do FDR é que essa taxa é pouco sensível à correlação espacial, o que significa que pode ser aplicado em regiões com a presença ou não da dependência espacial entre as séries (Souza et al., 2020; Ventura et al., 2004; Wilks, 2006).

Na análise regional, as séries selecionadas por modelos não estacionários com base no critério BIC são comparadas regionalmente, considerando todos os conjuntos de dados da região, com a hipótese de estacionariedade das séries. A comparação de modelos aninhados, no presente estudo, o modelo não estacionário (Modelo 1, 2 ou 3) como o modelo alternativo (M), versus o modelo estacionário (Modelo 0) como o modelo nulo (M_0), usando abordagens como o Teste de Razão de Verossimilhança (TRV), AIC ou BIC como procedimento de teste resultam em taxas de Erro Tipo I (falsos-positivos) e Tipo II (falsos-negativos) (Dziak et al., 2020; Frommlet et al., 2010; Lorah & Womack, 2019). Os falsos-positivos surgem quando se declara a não estacionariedade dos dados, mas, na verdade, a série é estacionária. Os falsos-negativos decorrem da consideração de estacionariedade das séries, quando, na realidade, as séries são não estacionárias. No caso do BIC, por exemplo, o valor de $\log n$ faz com que essas taxas diminuam à medida que o tamanho da amostra (n) aumenta (Dziak et al., 2020; Frommlet et al., 2010; Lorah & Womack, 2019; Raftery, 1995). Para resolver o problema do Erro Tipo I, alguns trabalhos na área de genética, como Dolejsi et al. (2014) e Xi et al. (2011), aplicam modificações do modelo de BIC combinado com o FDR para diminuir a taxa de falsos-positivos na análise de dados.

No presente caso, a conexão entre os resultados de BIC obtidos em análise local e a aplicação do FDR em nível regional para a comparação entre M (não estacionariedade) e M_0

(estacionariedade) foi estabelecida por meio de uma abordagem complementar baseada em testes de hipótese. O teste de hipótese escolhido foi o Teste de Razão de Verossimilhança (TRV), devido às suas boas propriedades estatísticas quando os modelos são aninhados (*nested*) (AghaKouchak et al., 2013; Wilks, 2005). O emprego da abordagem complementar TRV teve como propósito incorporar a cada série um valor de nível de significância local de teste ($\alpha_L=0.05$), que reflete o risco que se está disposto a correr ao cometer o Erro Tipo I; e ao um p-valor, que é a probabilidade específica de que o valor observado da estatística de teste ocorra conforme a distribuição nula (AghaKouchak et al., 2013; Coles, 2001; Wilks, 2005).

Para a aplicação do TRV, os modelos das séries temporais são os modelos selecionados via BIC, ou seja, séries em que o modelo não estacionário obteve o melhor ajuste na análise BIC corresponde ao modelo alternativo no TRV para essa mesma série, e o modelo nulo sempre corresponde ao modelo estacionário (ex. Lima et al. 2015). O Teste de Razão de Verossimilhança compara as funções da máxima verossimilhança obtidas pelos dois modelos por meio de uma função de estatística, a estatística de teste D (*deviance statistic*) (Wilks, 2005):

$$D = 2 \cdot \{\ln[LG_M(\boldsymbol{\theta})] - \ln[LG_{M_0}(\boldsymbol{\theta})]\} \quad (4.16)$$

em que, D é uma variável qui-quadrado com w graus de liberdade, sendo o valor de w dado pela diferença entre o número de parâmetros do modelo alternativo e nulo; $\ln[LG_M(\boldsymbol{\theta})]$ e $\ln[LG_{M_0}(\boldsymbol{\theta})]$ são os valores máximos dos logaritmos da função de verossimilhança generalizada dos modelos alternativo e nulo respectivamente, Equação (4.6). À medida que o valor da estatística D aumenta, as evidências a favor do uso do modelo alternativo e a rejeição do modelo nulo se tornam mais fortes, levando à rejeição da hipótese nula. A escolha do modelo M e a rejeição do modelo M_0 ocorre quando o valor amostral de D é maior do que o quantil da variável qui-quadrado associado a um nível de significância local α_L , conforme Equação (4.17).

$$D > \chi^2_{(1-\alpha_L),w} \quad (4.17)$$

em que, $\chi^2_{(1-\alpha_L);q}$ é o quantil da variável qui-quadrado, α_L é o nível de significância local adotado nesse trabalho como 0.05.

O objetivo da aplicação do *False Discovery Rate*, conforme sugerido por Benjamini & Hochberg (1995), é reduzir o número excessivo de resultados falso-positivos (Erro Tipo I) a partir da identificação de testes significativos no local através do controle da taxa do FDR, conforme definido na Equação (4.18). O FDR consiste na proporção esperada de hipóteses nulas falsamente rejeitadas entre todas as rejeições localmente.

$$FDR = \begin{cases} E \left[\frac{N_{FP}}{R} \right] & se R > 0 \\ 0 & se R = 0 \end{cases} \quad (4.18)$$

em que, N_{FP} representa o número de séries em que a hipótese nula foi rejeitada erroneamente; e R é o número total das hipóteses rejeitadas. A estratégia do *False Discovery Rate* se resume em um procedimento sequencial baseado na ordenação crescente dos p-valores, $p_1 \leq p_2 \leq \dots \leq p_m$, obtidos com o TRV aplicado a cada uma das m estações fluviométricas. Cada p-valor está associado a uma hipótese nula correspondente, $H_1 \leq H_2 \leq \dots \leq H_m$, e a um dado valor crítico específico, $d_1 \leq d_2 \leq \dots \leq d_m$, dado pela Equação (4.19) (Benjamini e Hockberg, 1995):

$$d_i = \frac{i \cdot \alpha_R}{m} \quad (4.19)$$

em que, i é a posição da série ordenada conforme o p-valor em relação ao conjunto de séries; α_R é o nível de significância regional adotado nesse trabalho como 5%; e m é o número de hipóteses nulas testadas. A decisão de rejeitar ou não a hipótese nula se inicia pela série com o maior p-valor (a evidência mais fraca). Se $p_m < \alpha_R$, então, para todas as séries da região em estudo, a hipótese nula (estacionariedade das séries) será rejeitada. Caso contrário, as hipóteses nulas restantes ($H_{i < j}$) serão rejeitadas e o modelo alternativo (não estacionário) será preferido somente quando for verificado que um dado p-valor tem valor inferior a um valor crítico correspondente ($p_j < d_j$).

4.3 - ESTUDO DE CASO: RH URUGUAI

No presente estudo, conduziu-se uma análise de frequência de cheias ao nível local e regional na Região Hidrográfica (RH) do Uruguai, que faz parte da bacia do Rio Uruguai, localizada no Brasil, na região Sul do país (Figura 4.2). O objetivo foi detectar, modelar e avaliar o comportamento não estacionário nessa RH. A bacia do Uruguai em conjunto com as do Paraná e do Paraguai formam a importante e grande bacia do Prata. A bacia internacional do Uruguai se situa em três países: Brasil, Argentina e Uruguai. A área total da bacia do rio Uruguai é de aproximadamente 349 844 km² considerando o seu exultório (coordenadas geodésicas: 33°53'0" S e 58°26'43"), com cerca de 174 300 km² situada no Brasil, formando a RH do Uruguai. Essa área de 174 300 km² corresponde a cerca de 3% do território brasileiro. A RH do Uruguai abrange parte dos estados do Rio Grande do Sul com 74% da área da RH e de Santa Catarina com os 26% restantes (ANA, 2015; Marcuzzo et al., 2016).




Figura 4.2 - Localização da RH do Uruguai (pontilhado verde) entre as 12 RH do Brasil (verde-escuro). A RH do Uruguai faz parte da Bacia do Uruguai (branco) na América do Sul (verde-claro).

A seleção da Região Hidrográfica (RH) do Uruguai como estudo de caso deste trabalho foi influenciada por essa RH ser uma área do Brasil com alto índice de inundações ao longo de todo o ano. Essas inundações afetam especialmente os ribeirinhos no decorrer do curso principal do rio Uruguai e de alguns de seus afluentes (ANA, 2015). Desde o início da operação do Sistema de Alerta do Rio Uruguai (SAH-Uruguai) em dezembro de 2018 até novembro de 2022, foram emitidos 307 boletins extraordinários de alerta de cheias na RH do Uruguai (Mattiuzi, 2023). O SAH-Uruguai é um sistema que monitora os níveis do rio Uruguai e afluentes, que é operado e mantido pelo Serviço Geológico do Brasil (SGB/CPRM) em parceria com a Agência Nacional de Águas (ANA). Além do alto índice de cheias na RH do Uruguai, a observação de tendências nas cheias dessa região (Anzolin & Chaffe, 2021; Bartiko et al., 2017; L. Slater et al., 2021) também auxiliou na escolha do local de aplicação da metodologia proposta neste trabalho. A importância do estudo de caso é apenas relativa, pois a metodologia proposta pode ser aplicada em qualquer localidade.

O rio Uruguai tem extensão de 2 200 km e é o principal rio da RH do Uruguai. Esse rio se origina da confluência dos rios Pelotas e do Peixe, localizados no Brasil. A partir desse ponto, o rio segue na direção Leste-Oeste, marcando a divisa entre os estados do Rio Grande do Sul e Santa Catarina. Após se encontrar com o rio Peperi-Guaçu, o rio Uruguai passa a seguir na direção sudoeste, servindo como fronteira entre o Brasil e a Argentina. Por fim, ao confluir com o rio Quaraí, que faz a fronteira entre o Brasil e o Uruguai, o rio Uruguai segue para o sul, dividindo a Argentina e o Uruguai, até sua foz no rio do Prata (ANA, 2015).

Segundo os critérios da classificação de Köppen-Geiger, o clima da RH Uruguai compreende dois tipos, Cfa e Cfb (Beck et al., 2018; Peel et al., 2007). O que significa para o Brasil: clima subtropical úmido sem estação seca, com verão quente (Cfa) ou verão temperado (Cfb) (Alvares et al., 2013). As chuvas são distribuídas ao longo do ano, com concentração média maior no inverno, entre maio e setembro. A precipitação média anual na RH do Uruguai é de aproximadamente 1 623 mm, índice abaixo da média nacional de 1 761 mm (ANA, 2015).

4.3.1 - Séries de vazões

No presente estudo foram analisadas as 70 estações fluviométricas da Região Hidrográfica do Uruguai. A partir dessas 70 estações, foram extraídas as séries de vazões máximas diárias

por meio do Sistema de Informações Hidrológicas (HidroWeb) da Agência Nacional de Águas (ANA) até o ano de 2019. Para realizar uma análise de frequência de cheias anuais mais eficiente, foi realizada uma filtragem entre as 70 séries hidrológicas com base nos critérios de seleção I, II e III.

No critério I, analisou-se quais estações estão potencialmente sob influência de reservatórios a montante por meio do *degree of regulation* (DoR), índice que representa a relação entre a vazão média anual de um rio que pode ser retido por um ou mais reservatórios na bacia hidrográfica (de Souza & Reis, 2021). O uso do DoR nesse estudo teve como propósito filtrar e excluir parte dos dados impactados por atividades antrópicas, na tentativa de melhor analisar a influência de mecanismos climáticos no comportamento das cheias na RH do Uruguai. O grau de regulação utilizado no presente estudo foi calculado para o Brasil por de Souza & Junior (2021). de Souza & Junior (2021) estimaram o DoR a partir da Equação (4.20):

$$DoR_j = \frac{1}{Q_{mtj}} \sum_{i=1}^{n_j} V_{ij} \quad (4.20)$$

em que V_{ij} é a capacidade do reservatório i a montante do trecho j da hidrografia, obtida por meio das informações da capacidade de reservação de cada massa d'água do Brasil que pode ser visto no catálogo de Metadados da ANA ; n_j é o número total de reservatórios a montante do trecho j ; e a Q_{mtj} é a vazão média anual em volume no trecho j obtida a partir dos dados de ANA (2020) (de Souza & Reis, 2021). Não existe na literatura um valor predefinido de DoR em que se possa dizer que as vazões são afetadas por reservatórios a montante. Nesse estudo, seguindo literaturas como Lehner et al. (2011), de Souza & Reis (2022) e Dynesius & Nilsson (1994) adotou-se $DoR > 0.02$ para indicar locais potencialmente afetados por reservatórios. Das 70 estações de dados da RH Uruguai, 25 séries históricas obtiveram $DoR > 0.02$ e foram descartadas da análise, totalizando em 45 séries restantes.

No critério II, verificou-se em quais estações há a ocorrência de falhas nas séries de dados. Hiatos longos nas séries podem levar a uma interpretação errônea do melhor modelo (estacionário ou não estacionário) para representar as séries de vazões máximas, devido a

inconsistências temporais. Séries com falhas maiores que 10% nos registros hidrológicos foram excluídas do estudo. A escolha dessa percentagem ocorreu após uma análise visual das séries de vazões máximas anuais de todas as estações da RH do Uruguai. Logo, das 45 estações com dados históricos selecionadas pelo critério I, 6 séries foram descartadas por possuírem menos de 90% de observações em relação ao total de dados da série histórica, o que resultou em 39 estações com séries históricas.

No último critério, III, verificou-se a extensão das séries históricas de cada estação. Optou-se por selecionar séries com pelo menos 40 anos de dados, seguindo a recomendação de Cunderlik et al. (2004) para uma melhor análise de longo prazo das cheias. Quanto maior o período dos dados, melhor é a análise do comportamento das cheias ao longo dos anos. Nessa última avaliação, 7 estações possuíam menos de 40 anos de dados e não foram incluídas no estudo. Logo, 33 estações foram selecionadas para a análise de frequências de cheias anuais na RH do Uruguai, com séries de comprimento variando entre 40 e 78 anos. As 33 estações distribuídas ao longo dessa RH podem ser vistas na Figura 4.3. Mais informações sobre as estações selecionadas estão no APÊNDICE A, conforme numeração da Figura 4.3.

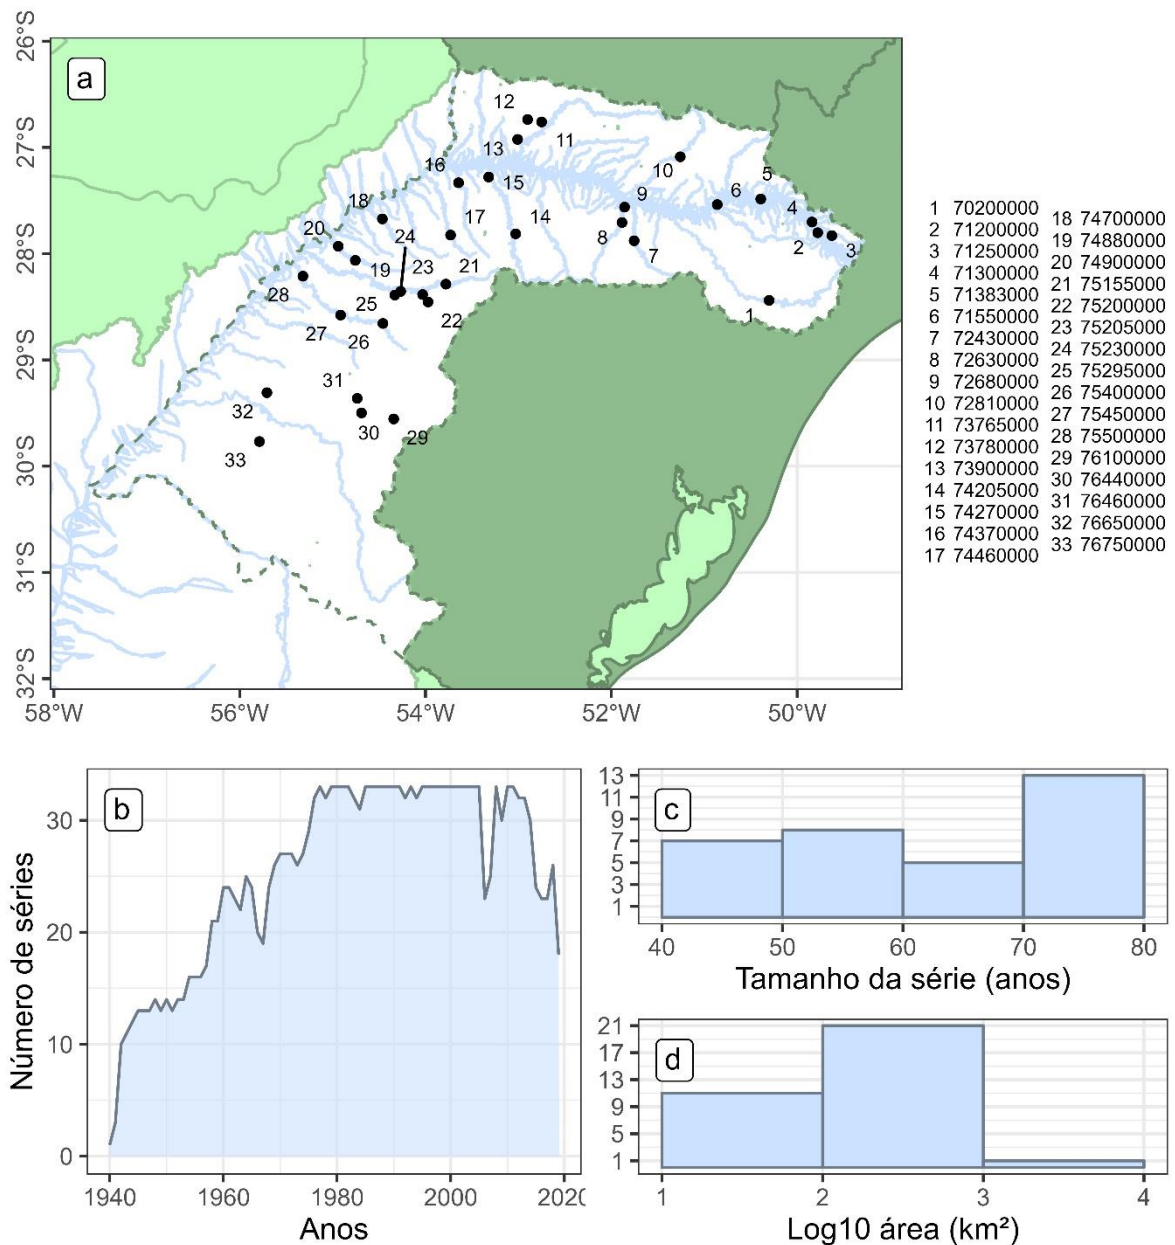


Figura 4.3 - a) Localização na RH do Uruguai das 33 estações com séries de cheias selecionadas para o estudo. Os rótulos indicam o código de oito dígitos atribuídos pela ANA para cada estação. b) Número de séries temporais estudadas disponíveis por ano. c) Histograma do tamanho das séries em anos para as séries consideradas neste estudo. d) Área em Log₁₀ das estações com as séries analisadas neste estudo.

4.3.2 - Covariáveis: Indicadores climáticos

A escolha das covariáveis, ou seja, dos potenciais mecanismos de mudanças no comportamento das vazões máximas anuais na RH do Uruguai se concentrou em indicadores climáticos que envolvem fenômenos atmosféricos e oceânicos de grande escala que afetam

a região, mais especificamente o El Niño Oscilação Sul (ENOS) e a Oscilação Decenal do Pacífico (ODP). Além de serem apontados como fatores influenciadores nas vazões da região pelas literaturas, literaturas que serão explicitadas nos próximos parágrafos, os indicadores climáticos são índices que possuem séries de dados com grandes comprimentos e compatíveis com as séries históricas das vazões máximas anuais da RH do Uruguai, auxiliando em uma análise de atribuição de mudanças de longo prazo nas cheias. Outros índices como Oscilação Multidecenal do Atlântico (OMA), Oscilação do Ártico (OA) e Oscilação do Atlântico Norte (OAN), também foram avaliados para a RH, porém, devido às baixas taxas de influência nas cheias da região ao nível local e nenhuma ao nível regional, seus resultados não foram considerados na seção 5 e foram anexados no APÊNDICE E. É importante salientar que para a metodologia apresentada no presente trabalho, as covariáveis variam conforme a área a ser estudada, podendo envolver mecanismos de mudanças nas cheias envolvendo a atmosfera e/ou bacia, e/ou rio (Merz et al., 2012).

O El Niño Oscilação Sul (ENOS) é um fenômeno climático caracterizado por flutuações de variabilidade periódicas na temperatura da superfície do mar (TSM) e na pressão ao nível do mar sobre o Oceano Pacífico na região equatorial e regiões vizinhas. É um fenômeno atmosférico-oceânico que afeta os padrões de circulação atmosférica globalmente em sua fase positiva (El Niño), associada a temperaturas mais altas do que a média no Oceano Pacífico Equatorial, e em sua fase negativa (La Niña), relacionada a temperaturas mais baixas nesse oceano. O ENOS é um fenômeno considerado como uma das fontes principais de variação interanual do tempo e clima em todo o planeta, e uma das maiores fontes da variabilidade interanual da precipitação no Brasil (Grimm, 2015; Grimm & Tedeschi, 2009; Kobiyama et al., 2006). Estudos anteriores apontam o ENOS como um fenômeno climático relevante nos regimes das precipitações e das vazões nos cursos d'água da bacia do Uruguai (Anzolin & Chaffe, 2021; Capozzoli et al., 2017; Dai et al., 2009; Doyle & Barros, 2011; Krepper et al., 2003). Cabe destacar que no estudo de Anzolin & Chaffe (2021) também houve a realização da análise de frequência hidrológica na região, com um dos focos nas vazões máximas anuais, porém, com uma abordagem diferente da proposta no presente estudo, o que permitiu comparações entre os resultados para a covariável ENOS na região.

A Oscilação Decenal do Pacífico (ODP), por sua vez, é caracterizada como a principal função ortogonal empírica das anomalias na TSM do Pacífico Norte e áreas vizinhas, com variabilidade decenal. A ODP tem similaridade com os padrões anômalos associados ao

ENOS, porém, com uma maior duração. A fase positiva (quente) dessa oscilação se relaciona a um forte sistema de baixa pressão das Aleutas, águas de superfície com temperaturas mais baixas do que a média no Pacífico Norte Central e Oeste; e águas mais quentes na costa oeste das Américas e no Pacífico Tropical Central e Leste. A fase negativa é ligada a padrões invertidos dos padrões encontrados na fase positiva (Grimm & Tedeschi, 2009; Newman et al., 2016; Schneider & Cornuelle, 2005). Um estudo de Molion (2008) destacou sobre como a ODP tem uma relação sensível com os processos hidrológicos de bacias do Norte-Centro, do Sul e do Sudeste do Brasil. Molion (2008) observou que nessas regiões, as precipitações e as vazões aumentaram durante a fase quente entre 1977-1998 e diminuíram na fase fria entre 1947-1976. Doyle & Barros (2011) detectaram que na Bacia do Prata a fase positiva da ODP foi acompanhada pelo fenômeno El Niño mais frequente e intenso. Em um estudo de Rebello (2006) focado no Rio Grande do Sul (parte da RH do Uruguai), observou-se anomalias positivas na precipitação relacionadas à fase positiva da ODP, e anomalias negativas durante a fase fria.

Para o estudo da covariável El Niño Oscilação Sul, foram analisados os índices nas regiões Niño 1+2, Niño 3, Niño 3.4, Niño 4 TSM. Para a análise da covariável Oscilação Decenal do Pacífico foi levantado o índice PDO (*Pacific Decadal Oscillation*). Os índices relacionados ao ENOS e ODP foram extraídos dos dados disponíveis no sítio Web do *Climate Prediction Center (CPC)* da *National Oceanic and Atmospheric Administration (NOAA)*. Os dados extraídos no site são séries históricas das anomalias mensais da temperatura da superfície do mar associadas aos índices climáticos em regiões específicas (Figura 4.4), as informações sobre esses índices são apresentados na Tabela 4.2. Além da análise do ENOS e da ODP como possíveis influenciadores no comportamento das cheias da RH, também se analisou como as vazões máximas anuais variam considerando o Tempo como covariável. Para todas covariáveis escolhidas foram estabelecidas séries anuais com disponibilidade de dados comum com as séries anuais de vazão máxima da RH do Uruguai. A partir do levantamento das séries dos índices das covariáveis foi possível a análise de frequência de cheias não estacionária da RH Uruguai.

Tabela 4.2 - Informações sobre os índices climáticos (covariáveis) da RH do Uruguai.

Índices climáticos	Origem dados	Região	Cobertura
	El Niño 1+2	HadISST	0-10S e 90E-80O
El Niño Oscilação Sul	El Niño 3	HadISST1	5S-5N e 150-90O
	El Niño 3.4	HadISST1	5S-5N e 170-120O
	El Niño 4	HadISST1	5S-5N e 160E-150O
Oscilação Decenal do Pacífico	ODP ou PDO	SST OI.v2	Direção aos polos de 20N na bacia do Pacífico

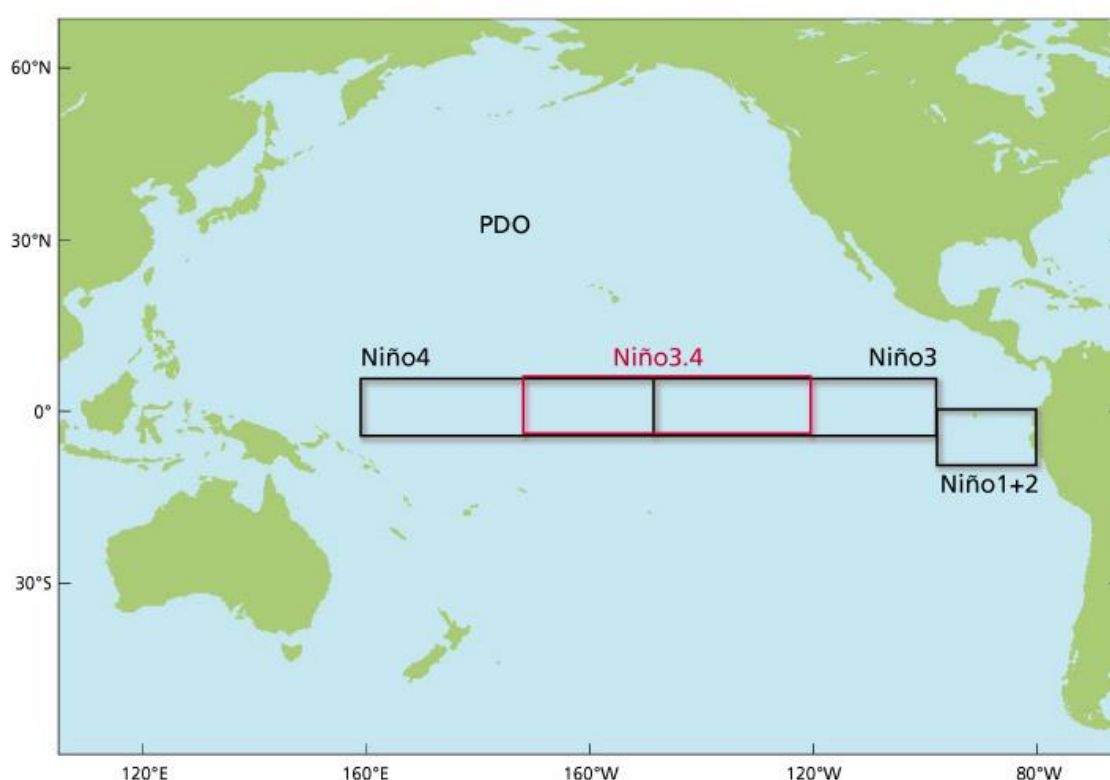


Figura 4.4 - Mapa indicando as regiões do oceano onde as médias de temperatura da superfície do mar (TSM) são medidas para calcular os índices Niño 1+2, Niño 3, Niño 3.4, Niño 4 e PDO.

As séries anuais dos índices El Niño Oscilação Sul (ENOS) e Oscilação Decenal do Pacífico (ODP) foram calculadas de diferentes formas, a fim de identificar o período com maior influência no comportamento das vazões máximas anuais. Foram testados os seguintes períodos: média anual (ano civil) e médias trimestrais: DJF (dezembro, janeiro, fevereiro), MAM (março, abril e maio), JJA (junho, julho e agosto), SON (setembro, outubro e

novembro), JFM (janeiro, fevereiro, março), AMJ (abril, maio e junho), JAS (julho, agosto e setembro) e OND (outubro, novembro e dezembro). Entre os 9 períodos testados, o período que apresentasse o menor valor de BIC para as séries temporais estudadas seria o período escolhido para uma análise mais detalhada do comportamento das cheias, que envolve a análise regional e o estudo do comportamento não estacionário dos quantis de cheias. O período em que houve a maior correlação entre as cheias na RH do Uruguai e cada índice da covariável pode ser visto na Tabela 4.3. As médias dos períodos por ano da TSM causada pelos índices climáticos podem ser observadas pela Figura 4.5.

Tabela 4.3 - Períodos com maior correlação entre os índices climáticos (Índice Niño 1+2, Niño 3, Niño 3.4, Niño 4 e ODP) e as cheias na RH do Uruguai.

	Índices climáticos	Período
El Niño Oscilação Sul	El Niño 1+2	Anual
	El Niño 3	AMJ
	El Niño 3.4	AMJ
	El Niño 4	AMJ
Oscilação Decenal do Pacífico	ODP	JAS

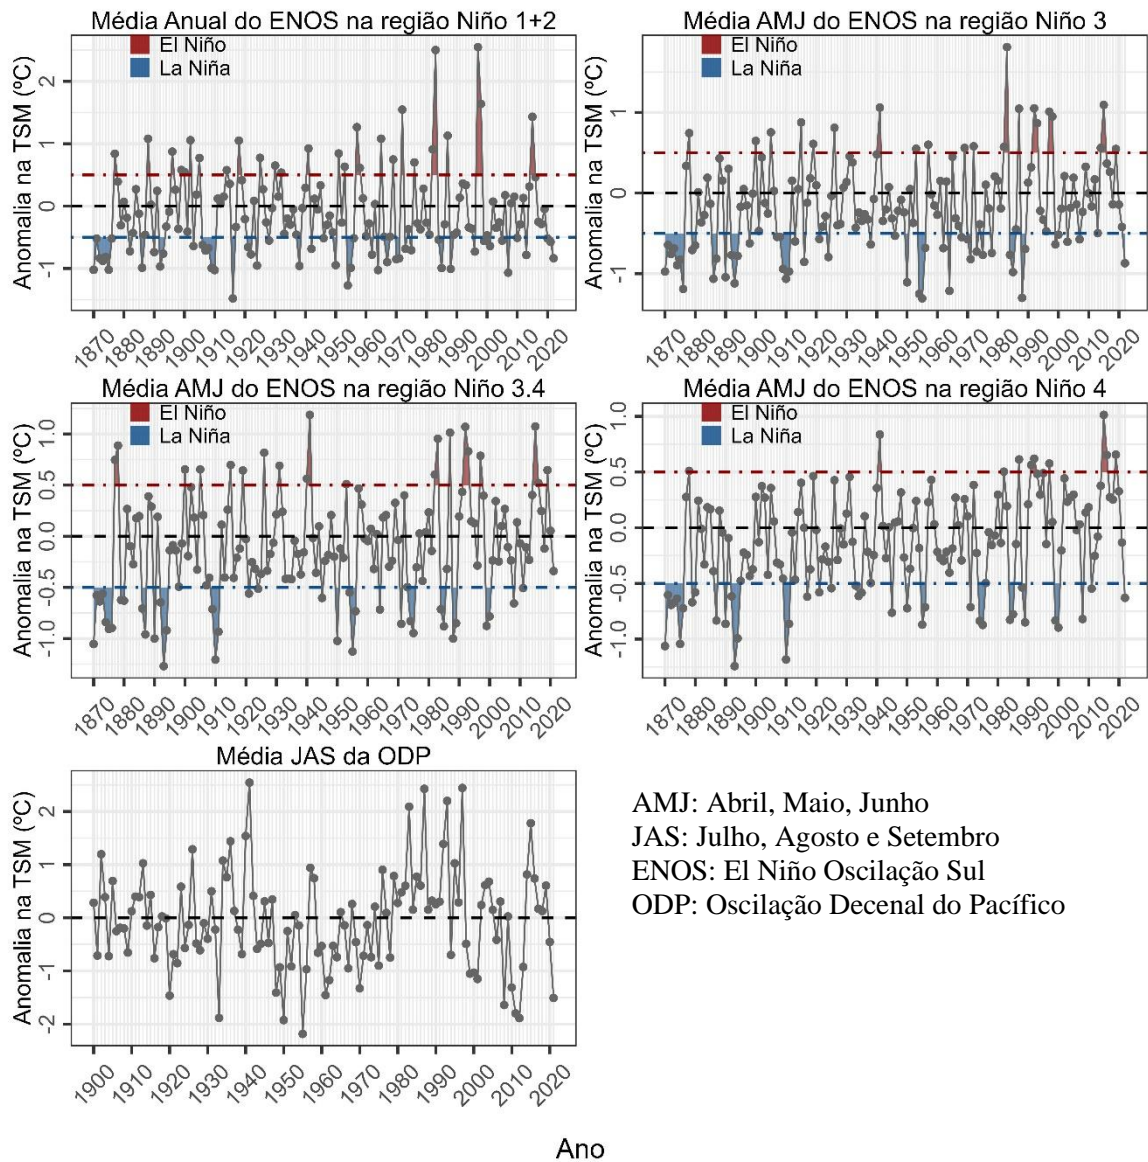


Figura 4.5 - Média dos períodos por ano da anomalia de temperatura da superfície do mar (TSM) em °C causada pelos índices climáticos (Índice Niño 1+2, Niño 3, Niño 3.4, Niño 4 e ODP) nos períodos com maior correlação entre as cheias na RH do Uruguai.

5 - RESULTADOS E DISCUSSÃO

5.1 - ANÁLISE LOCAL

Na abordagem metodológica proposta no presente estudo para a seleção local do modelo que melhor se adere aos dados optou-se pela aplicação de dois critérios de informação: Critério de Informação de Akaike (AIC) e Critério de Informação Bayesiano (BIC). A Figura 5.1 apresenta uma comparação dos resultados obtidos por ambos os critérios para as 33 estações da Região Hidrográfica (RH) do Uruguai quando os modelos não estacionários (Modelo 1, 2 e 3), Tabela 4.1, condicionados as covariáveis (Tempo; El Niño Oscilação Sul (ENOS) nas regiões El Niño 1+2, El Niño 3, El Niño 3.4 e El Niño 4 e Oscilação Decenal do Pacífico (ODP)) alcançam os menores valores para AIC ou BIC.

Como comentado na seção 4.2.2 os modelos não estacionários propostos no presente estudo (Modelo 1, 2 e 3) possuem em comum o parâmetro de forma (κ) constante ao longo do tempo e o parâmetro de posição (ξ) variando linearmente em função das covariáveis. A diferença entre os três modelos não estacionários consiste na modelagem do parâmetro de escala (α). No Modelo 1 α varia em função de ξ para que o coeficiente de variação (C_v) da distribuição GEV permaneça constante. No Modelo 2 o parâmetro de escala permanece constante ao decorrer do tempo. No Modelo 3 esse parâmetro varia exponencialmente em função das covariáveis.

É notável na Figura 5.1 a grande semelhança entre os modelos selecionados por cada série temporal considerando os dois critérios AIC e BIC. Quando há divergência entre os modelos selecionados por AIC e BIC, os modelos selecionados por AIC possuem mais parâmetros do que os modelos selecionados por BIC. Para a RH do Uruguai na grande maioria dos casos em que há divergência de modelos, enquanto o AIC opta por modelos não estacionários, o BIC seleciona o Modelo 0, modelo que considera a estacionariedade das cheias. Optando pela parcimônia, para dar continuidade ao estudo, o detalhamento dos resultados tanto em análise local quanto em regional dos modelos foi gerado pela aplicação do BIC, devido a penalização dessa complexidade adicional de parâmetros, tema abordado na seção 4.2.5.




Figura 5.1 - Séries da RH do Uruguai selecionadas por modelos não estacionários (Modelo 1, 2 ou 3) após aplicação local de pelo menos um dos critérios de informação, AIC ou BIC. Considera-se cada covariável analisada (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP). O Modelo 0 (estacionário) é representado pelas barras que alcançam a linha tracejada, e os modelos não estacionários são representados pelas barras que ultrapassam a linha tracejada. Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

A partir da aplicação da análise de frequência de cheias ao nível local considerando a abordagem metodológica escolhida no presente estudo, uso do BIC em 33 estações selecionadas na RH do Uruguai, foi possível identificar para cada série de vazões máximas anuais da RH quais modelos estatísticos obtiveram os menores valores de BIC (APÊNDICE B). Sendo os modelos estatísticos: estacionário (Modelo 0) ou não estacionários (Modelos 1, 2 ou 3) condicionados as covariáveis: Tempo; ENOS nas regiões El Niño 1+2, 3, 3.4 e 4; e ODP, Figura 5.2. É relevante observar que mesmo que o Critério de Informação Bayesiano penalize a complexidade adicional ocasionada pelo acréscimo de parâmetros nos modelos estatísticos, modelos não estacionários foram selecionados na RH do Uruguai (Figura 5.2) considerando todas as covariáveis.

É possível notar que quando a análise local de frequência de cheias considera a variação de parâmetros de GEV conforme o Tempo, há uma predominância na distribuição de modelos não estacionários selecionados mais a nordeste da RH do Uruguai. Quando se considera os índices El Niño 1+2, 3 e 3.4, não há um padrão distributivo, devido ao grande número de séries selecionadas por modelos não estacionários. Para o índice Niño 4, os modelos não estacionários se encontram predominantemente espalhados pelos afluentes localizados abaixo do rio Uruguai. Quando os parâmetros variam conforme o índice ODP, maior parte da não estacionariedade está situada a sudoeste da região.

Em relação aos modelos estatísticos levantados no presente estudo, é interessante observar que na modelagem de todas as covariáveis, o Modelo 2 foi aquele que alcançou os menores valores de BIC e foi selecionado dentre os quatro modelos analisados em diversas séries de cheias. O Modelo 1 também foi selecionado para todas as covariáveis em várias séries temporais. Nas modelagens das cheias com as covariável Tempo e ODP, o Modelo 1 é o modelo não estacionário que se mostra mais presente na região, como apresentado na Tabela 5.1. Para as outras covariáveis relacionadas ao fenômeno ENOS, o Modelo 2 foi selecionado com maior frequência. O Modelo 3, no qual o parâmetro de escala varia exponencialmente em função da covariável, é raramente visualizado na Figura 5.2, só alcançando o menor valor de BIC quando se considera as covariáveis El Niño 1+2, 3, 4 e ODP.

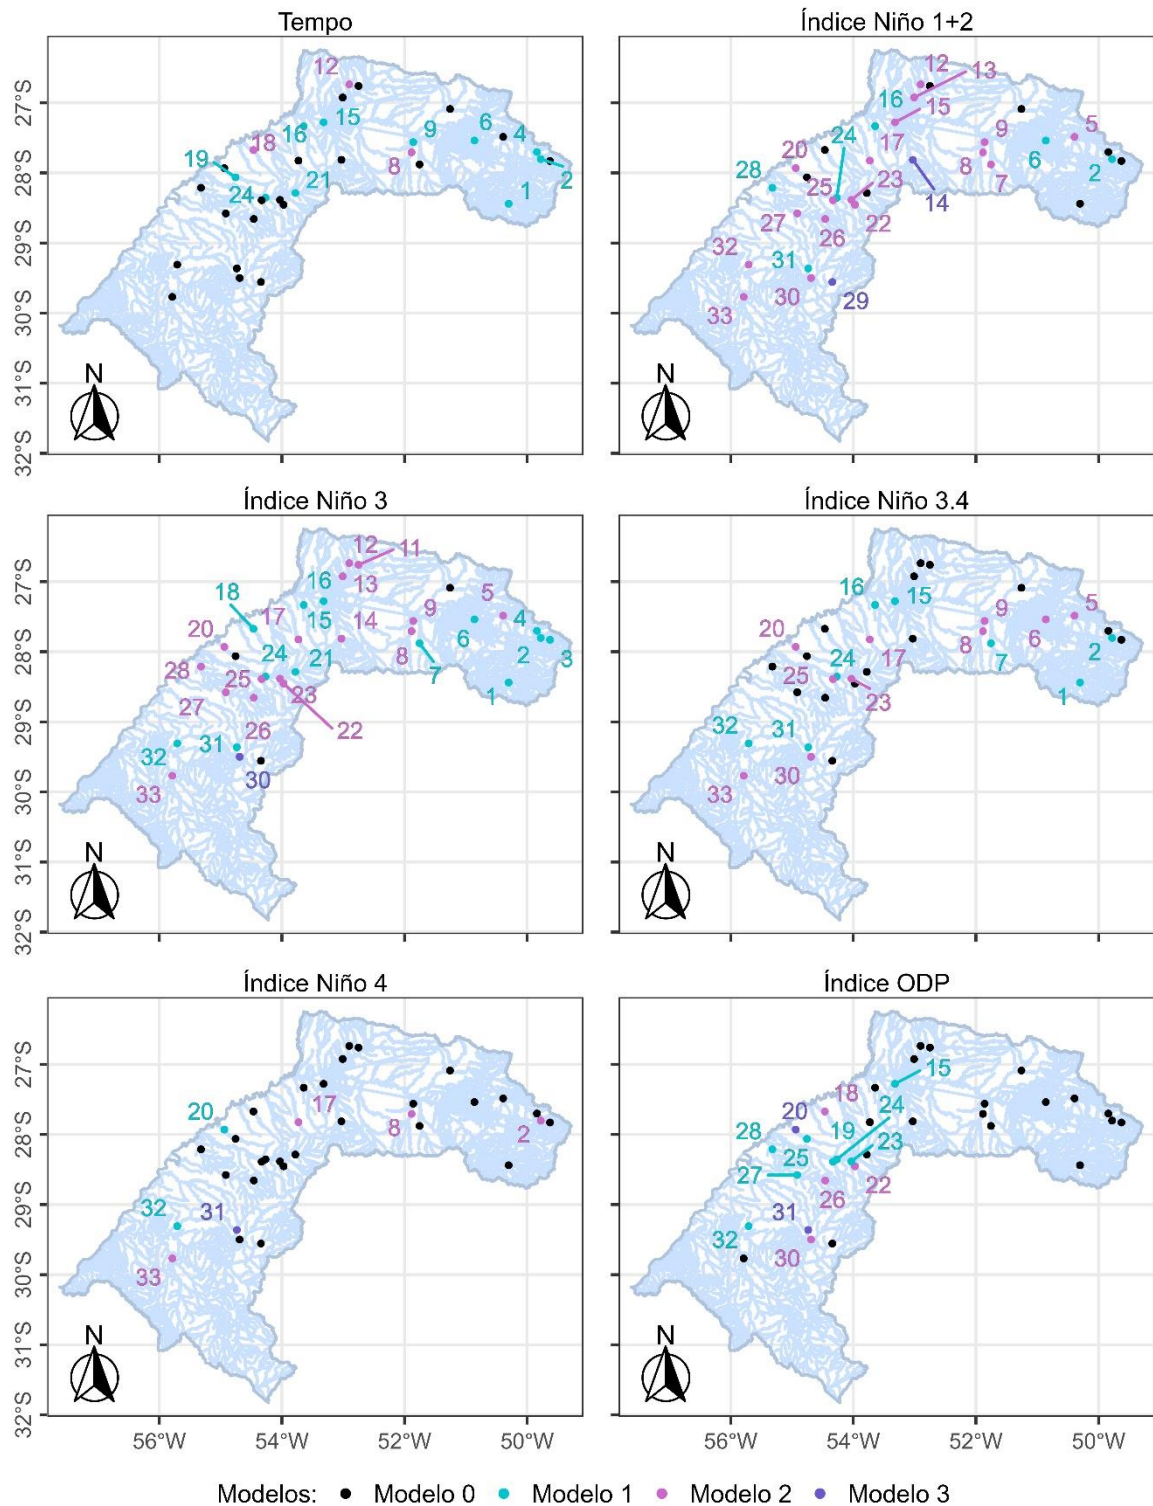


Figura 5.2 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise local (BIC). Considera-se cada índice da covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP) e o modelo escolhido na análise local (BIC): Modelo 0 (preto), Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

A Tabela 5.1 é uma tabela resumo em que há a quantificação e levantamento da proporção das séries históricas selecionadas por cada modelo, com foco na premissa da não estacionariedade, em relação a cada covariável levantada na Região Hidrográfica do Uruguai. Na maior parte das covariáveis (4 de 6), para mais de 50% das séries, as covariáveis analisadas não são consideradas mecanismos de grande influência nas cheias, com preferência pelo Modelo 0 (estacionário). Mas, a presença da não estacionariedade no comportamento das cheias relacionadas às covariáveis levantadas também alcançou valores consideráveis, com taxas variando de 21% a 91% em relação ao total das séries analisadas.

Tabela 5.1 - Número e proporção de estações com séries de cheias da RH do Uruguai selecionadas por cada um dos modelos estatísticos propostos (Modelo 0, 1, 2 ou 3) em análise local (BIC). Considera-se cada covariável analisada (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP).

Covariável	Modelo				Modelos não estacionários
	0	1	2	3	
Tempo	20	10	3	0	13
%	60.61	30.30	9.09	0.00	39.39
El Niño 1+2	8	6	17	2	25
%	24.24	18.18	51.52	6.06	75.76
El Niño 3	3	13	16	1	30
%	9.09	39.39	48.48	3.03	90.91
El Niño 3.4	15	8	10	0	18
%	45.45	24.24	30.30	0.00	54.55
El Niño 4	26	2	4	1	7
%	78.79	6.06	12.12	3.03	21.21
ODP	19	8	4	2	14
%	57.58	24.24	12.12	6.06	42.42

5.2 - ANÁLISE REGIONAL

Seguindo a abordagem metodológica proposta, a partir dos modelos (Modelo 0, 1, 2 ou 3, mais detalhes na Tabela 4.1 da seção 4.2.2) selecionados por BIC na análise local para cada

uma das 33 estações com séries de cheias da RH do Uruguai, considerando as covariáveis levantadas (Tempo, ENOS e ODP), realizou-se a análise regional dos modelos por meio do *False Discovery Rate* (FDR) com um nível de significância regional de 5%. Essa análise considera o grau de consistência regional e controla a probabilidade de cometer o Erro Tipo I em escala regional. Para a aplicação do FDR, os modelos precisam estar associados a p-valores relacionados a hipótese nula (estacionariedade). Os p-valores foram obtidos pela aplicação do teste de razão de verossimilhança (TRV), no qual há comparação entre o modelo não estacionário (Modelo 1, 2 ou 3) escolhido em BIC e o modelo estacionário (Modelo 0). Na Figura 5.3, pode-se observar a aplicação da taxa do FDR relacionada aos p-valores obtidos pelo TRV nas séries que melhor se adequaram aos modelos não estacionários condicionadas às covariáveis em análise local (BIC).

A taxa do FDR pode ser observada na Figura 5.3 pela linha pontilhada, que representa a linha crítica do FDR. Todas as estações com séries hidrológicas que ficam fora da taxa (acima da linha) têm o p-valor superior à taxa de controle ($p_i > d_i$), o que representa evidências mais fortes a favor da hipótese nula (estacionariedade), ou seja, a estacionariedade das séries foi aceita. Com a aplicação da taxa do FDR, pode-se observar que houve redução no número de séries que apresentaram comportamento não estacionário quando se consideram todas as covariáveis levantadas na RH Uruguai.

Ao observar a covariável Tempo, quase metade, 6 das 13 séries selecionadas por modelos não estacionários em análise local, ultrapassaram a linha crítica e foram consideradas estacionárias. Para o índice Niño 1+2, o resultado da análise regional é o mesmo da análise local. Quando os índices climáticos analisados são o El Niño 3 e o El Niño 3.4, a redução do número de modelos não estacionários é bem baixa. O contrário ocorre para o índice Niño 4, em que essa redução ultrapassa 70%, restando somente duas séries que apresentem indícios de não estacionariedade. No caso da anomalia ODP, todas as séries consideradas anteriormente não estacionárias estão acima da linha crítica. Portanto, a hipótese da estacionariedade não foi rejeitada para essas séries de cheias, e todas as séries foram declaradas estacionárias. Esse último resultado apresentado mostra que em avaliação regional a ODP é uma covariável que não possui índices fortes o suficiente para influenciar a não estacionariedade das séries de cheias na RH do Uruguai.

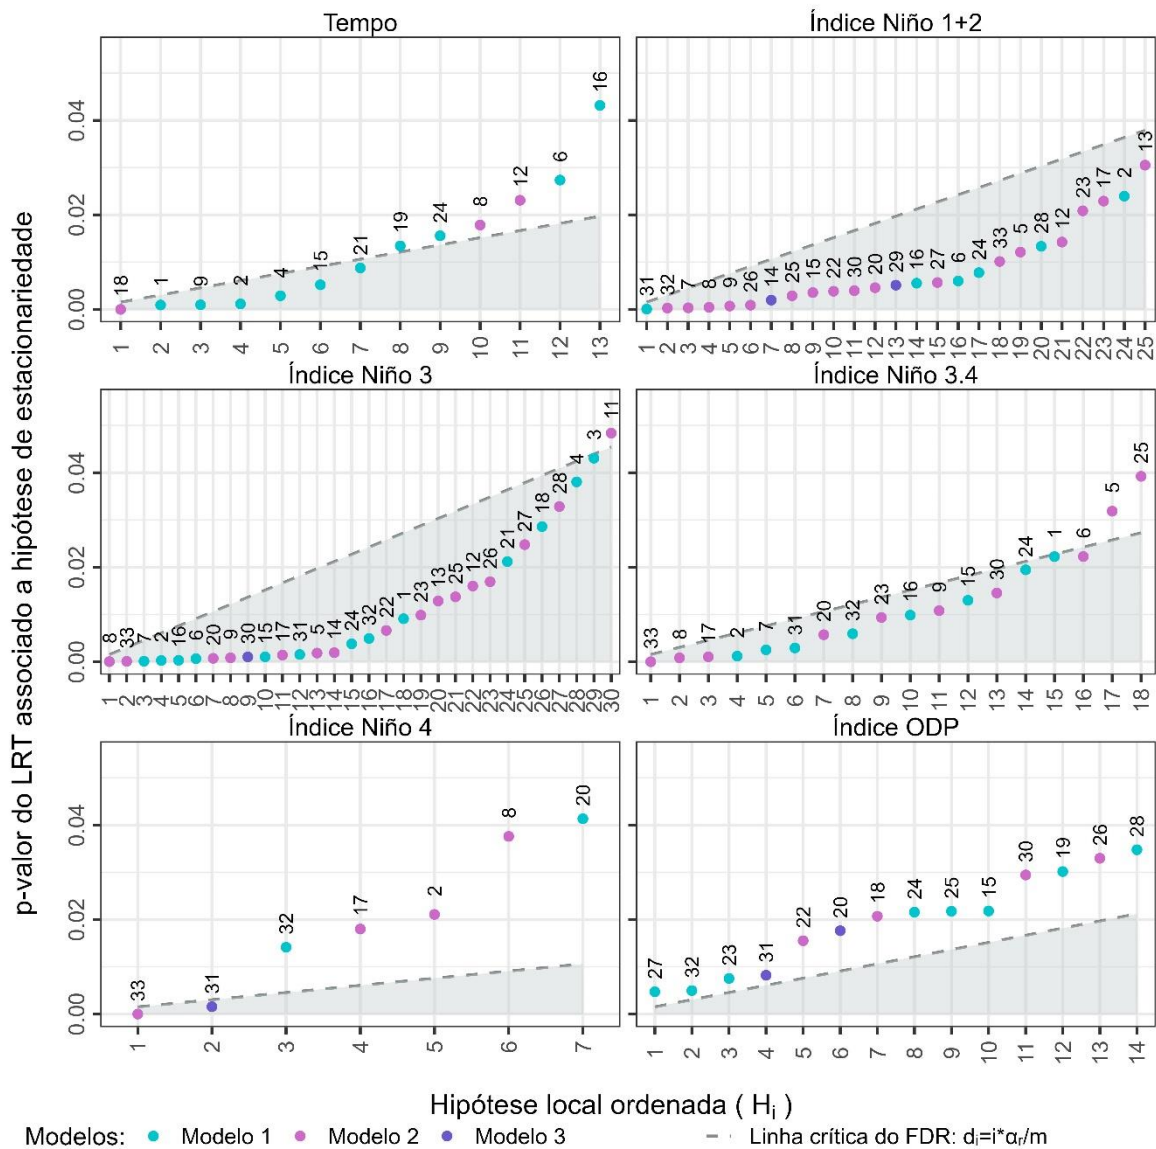


Figura 5.3 - Análise regional empregando o *False Discovery Rate* (linha crítica em pontilhado), com $\alpha_R=5\%$ e $m=33$. Considera-se para cada índice da covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP) as séries temporais que tiveram o modelo não estacionário escolhido na análise local (BIC): Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

Na presente abordagem metodológica, também se propôs a analisar as incertezas associadas às estimativas do parâmetro $r_1 = \xi_1/\xi_0$ (Modelo 1, 2, 3), que está associado à função do parâmetro de posição (ξ) variando linearmente segundo a covariável, e do parâmetro β_1 (Modelo 3), associado ao parâmetro de escala (α) que varia de forma exponencial conforme a covariável, por meio dos intervalos de confiança (IC) de 95% obtidos pelo método Delta.

Essa análise auxilia na identificação das séries de cheias que apresentem comportamento não estacionário com maior grau de confiança. A Figura 5.4 e a Figura 5.5 apresentam, respectivamente, as análises dos IC dos parâmetros de r_1 e β_1 para as séries com indícios de não estacionariedade das cheias após análise local (BIC) e regional (FDR).

Pode-se observar na Figura 5.4 que somente no cenário em que a covariável analisada é o índice Niño 4, o IC de r_1 de uma das séries (Estação 31, Modelo 3) cruza o eixo zero. Quando se visualiza na Figura 5.5 o IC de β_1 , nenhuma das séries de cheias selecionadas pelo Modelo 3 considerando os índices Niño 1+2, 3 e 4 cruzam o eixo zero. Esses resultados expressam que somente o parâmetro não estacionário r_1 para a série da estação 31 não é estatisticamente diferente de zero, acarretando a alteração do Modelo 3 (não estacionário) para o Modelo 0 (estacionário). É interessante notar que embora o r_1 do Modelo 3 selecionado pelas vazões máximas anuais da Estação 31 da RH do Uruguai cruze o eixo 0, o β_1 calculado para essa mesma estação não cruza o eixo zero.

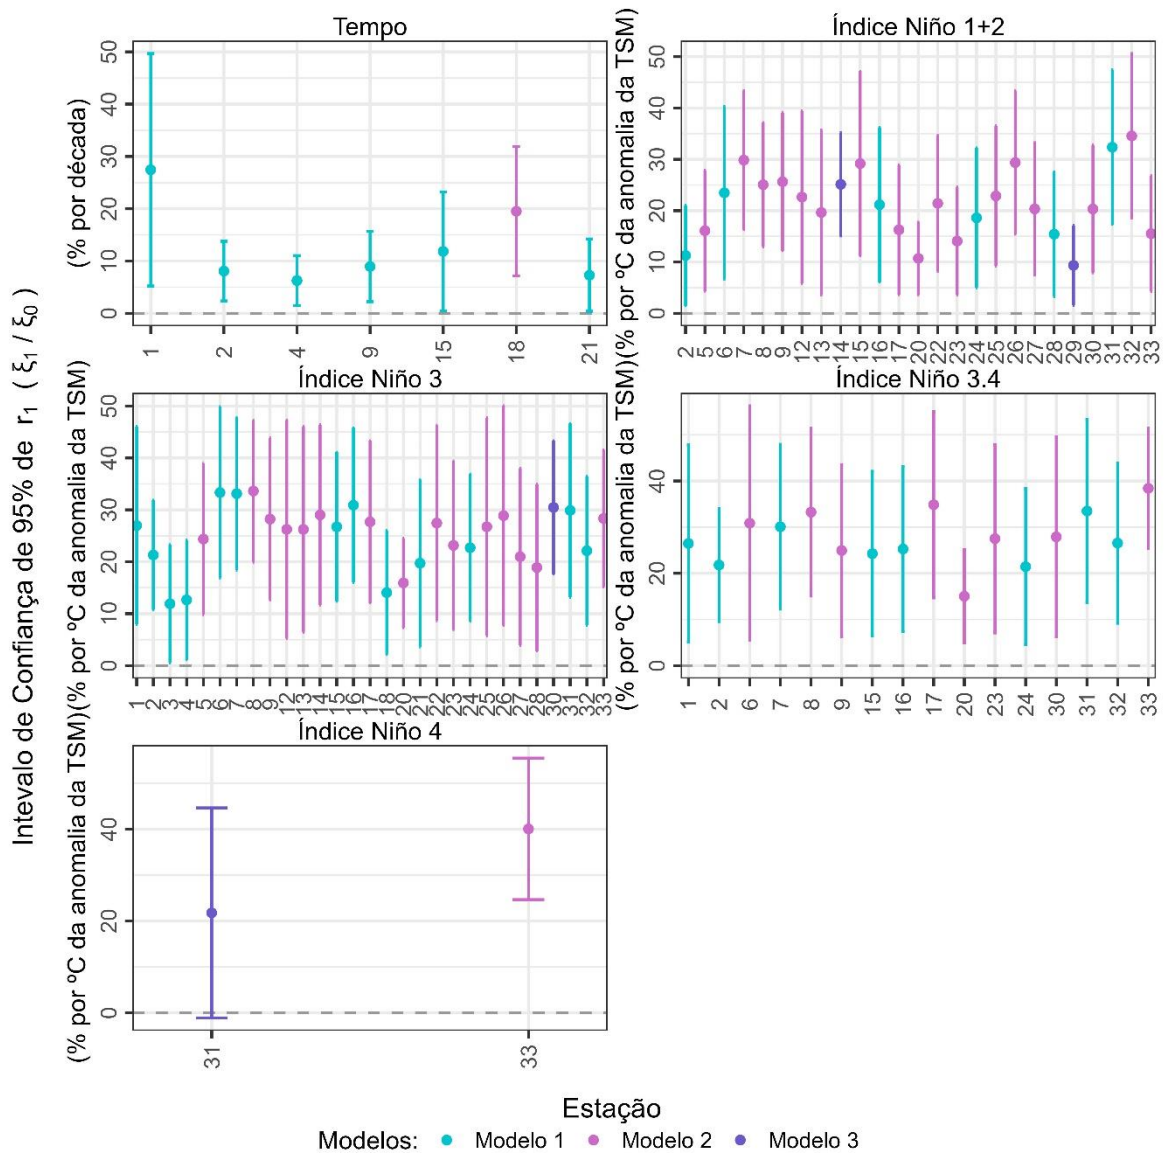


Figura 5.4 - Intervalos de confiança de 95% de r_1 . Considera-se para cada covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4 e El Niño 4) séries temporais que tiveram o modelo não estacionário como escolhido após análise regional (FDR): Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

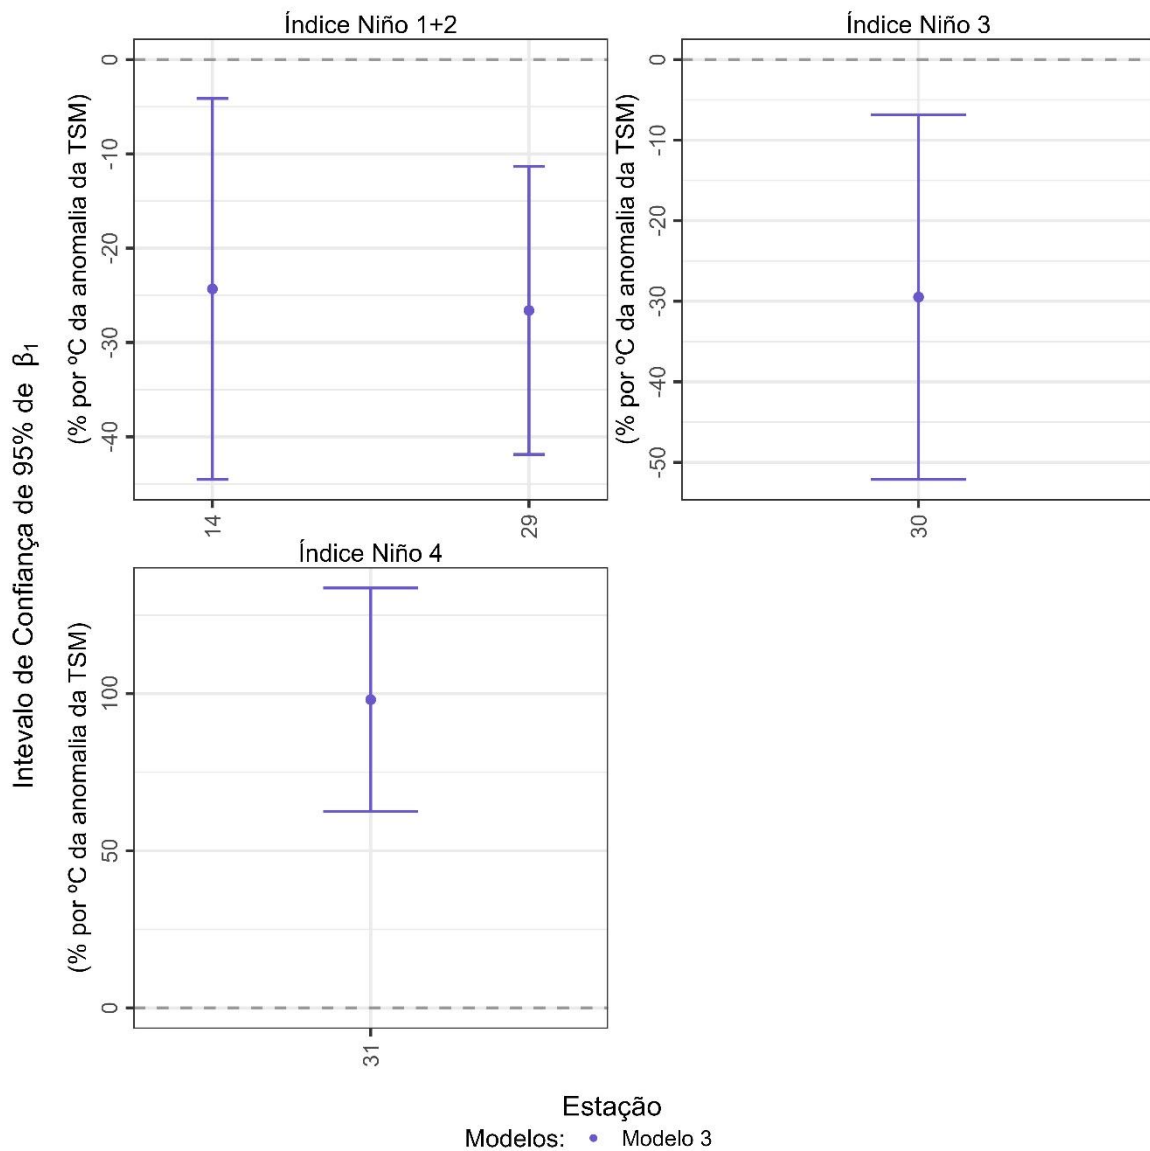


Figura 5.5 - Intervalos de confiança de 95% de β_1 . Considera-se para cada covariável (El Niño 1+2, El Niño 3, El Niño 4) séries temporais que tiveram o Modelo 3 (roxo), modelo não estacionário, como escolhido após análise regional (FDR). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

Após a combinação entre a avaliação local (BIC), regional (FDR) e dos IC (r_1 e β_1) é possível obter uma análise mais precisa e com maior grau de confiança do comportamento das séries de cheias anuais que apresentem indícios de não estacionariedade na RH do Uruguai. Na Figura 5.6, pode-se observar a distribuição espacial das 33 estações associadas às séries de vazões máximas anuais estudadas na RH do Uruguai e dos modelos que melhor representaram cada uma dessas séries, tanto em análise local (BIC) quanto em regional

(FDR), após avaliação dos IC de r_1 e β_1 , considerando as possíveis covariáveis de influência (Tempo, ENOS e ODP) na região.

Ao analisar a covariável Tempo na Figura 5.6 e comparar com a Figura 5.2 (análise local), observa-se ainda a presença de séries que se adaptaram melhor aos modelos não estacionários mais ao nordeste da RH do Uruguai, mais especificamente a leste do rio Uruguai. Em um estudo de Bartiko et al. (2017), houve a investigação da não estacionariedade ao longo do tempo em séries de máximas anuais no Sul do Brasil, e das 157 estações com séries hidrológicas estudadas, 47 foram identificadas como não estacionárias. Essas 47 séries estão localizadas principalmente nas bacias do Uruguai, Iguazu e Paranapanema. Sendo que as séries de vazões máximas localizadas na RH do Uruguai também se encontram em sua maioria no leste do rio Uruguai.

Krepper et al. (2003) ao analisarem a variabilidade interanual na bacia do rio Uruguai observaram que os picos de descarga fluvial do rio com escalas de 3.5 e 6 anos são influenciados pelo evento El Niño Oscilação Sul (ENOS). Dai et al. (2009) também citam a influência do El Niño no aumento da vazão em muitos rios ao redor do mundo, incluindo o rio Uruguai. Capozzoli et al. (2017) caracterizaram padrões de variabilidade espaço-temporal de vazões e os relacionaram com padrões climáticos que podem afetar as vazões, sendo o ENOS na região El Niño 3.4 um índice climático com correlação significativa e positiva na RH Uruguai. Um estudo na estimação da atribuição do crescimento nos fluxos dos rios da Bacia do Prata durante 1960 e 1999 feito por Doyle & Barros (2011) observaram que a mudança da vazão média do rio Uruguai ocorreu basicamente devido ao aumento da precipitação observada não somente durante o El Niño e La Niña (índice El Niño 3.4), mas também fora desse período (período neutro do ENOS). Nas vazões máximas anuais da RH do Uruguai, Figura 5.6, também se observa a influência do ENOS na geração das cheias. Sendo relevante salientar que essa influência nas cheias ocorre não só quando se considera a região do El Niño 3.4, que foi considerado nos estudos acima, mas, em todas as regiões analisadas (El Niño 1+2, 3, 3.4 e 4), com influência em mais de 48% das séries temporais para todas as regiões do ENOS, com exceção do El Niño 4, em que só uma série mostra indícios de não estacionariedade (Modelo 2) ao sul da RH do Uruguai.

O índice ODP não apresenta indícios suficientes para influenciar a não estacionariedade nas vazões máximas anuais da RH do Uruguai após avaliação regional com controle do Erro

Tipo I, como já comentado anteriormente. Resultado que pode ser diferente caso ocorra a associação de mais covariáveis junto a esse índice climático nos modelos estatísticos, covariáveis interagindo entre si, em vez de seu estudo isolado como propostos pelos Modelos 1, 2 e 3. Na Figura 5.6, é possível observar que na maior parte das estações com séries de cheias selecionadas em análise local por modelos não estacionários, considerando o índice ODP, apresentam indícios de não estacionariedade na modelagem de outras covariáveis, principalmente ao analisar o El Niño 3. Ou seja, é possível que a análise da interação do El Niño junto a ODP possa, por exemplo, alcançar evidências mais fortes contra a estacionariedade do que quando analisados de forma isolada. Como exemplo de associação, tem-se o estudo de Doyle & Barros (2011), que interligou o ENOS a ODP e observou que a fase positiva da ODP foi acompanhada pelo fenômeno El Niño mais frequente e intenso na Bacia do Prata.

É interessante observar na Figura 5.6 que, para quase todas as séries temporais selecionadas por modelos não estacionários, nos quais os parâmetros são funções do Tempo ou dos índices associados ao ENOS que variam ao longo do tempo, os modelos escolhidos foram o Modelo 1 e 2. Esse resultado mostra que o parâmetro de posição (ξ) pode não ser sempre constante na RH do Uruguai, como proposto pelo pressuposto da estacionariedade. Sendo a diferença entre esses dois modelos o parâmetro de escala (α): no Modelo 1, α varia em função de ξ para que o coeficiente de variação (C_V) da distribuição GEV permaneça constante, e no Modelo 2, o parâmetro de escala permanece constante. Anzolin & Chaffe (2021), ao realizarem uma análise de frequência de cheias não estacionária no Brasil com o modelo não estacionário em que o parâmetro de posição de GEV é função de covariáveis (ex. Tempo e El Niño 3), variando linearmente no tempo, como o Modelo 2 aqui proposto, no Sul do Brasil, os autores observaram que esse modelo não estacionário melhor se aderiu a diversas séries temporais.

Pela Figura 5.6, também é possível observar que quando o cenário de mudanças das cheias envolve a covariável Tempo, o Modelo 1 continua sendo o modelo mais presente, e ainda com mais força do que na análise local, Figura 5.2, alcançando em análise regional 6 das 7 séries. Esse resultado mostra a preferência nas séries de cheias pelo C_V da distribuição de GEV constante quando os modelos não estacionários variam com o Tempo na RH. Ou seja, nas séries selecionadas pelo Modelo 1, há a variabilidade das séries de cheias históricas. Vogel et al. (2011) também observaram que esse modelo não estacionário em função do

Tempo na análise de frequência de cheias nos Estados Unidos (EUA) foi o modelo escolhido para cerca de 90% das milhares de séries temporais dos EUA.

Quando o índice El Niño 1+2 é modelado, o número de séries em que o Modelo 2 é selecionado é quase três vezes maior que o número de séries com o Modelo 1, Tabela 5.2. Na modelagem das covariáveis El Niño 3 e 3.4, a proporção entre o Modelo 1 e Modelo 2 é semelhante, sem uma predominância na forma em que o coeficiente de variação se comporta ao decorrer do tempo, diferente do encontrado quando se considera a covariável Tempo. Para os índices Niño 1+2, 3 e 3.4, como na análise local, não houve grandes alterações na seleção de modelos, a distribuição espacial dos modelos não estacionários continua não sendo clara, sem um padrão de localização, por exemplo, do Modelo 1 ou 2. Essa não predominância pode ocorrer, pois tanto o Modelo 1 quanto o Modelo 2 são modelados de forma parecida, linearmente ao longo do tempo, com a divergência entre como o C_V varia ao longo do tempo. A presença do Modelo 3 continua presente, porém, diferente da análise local, é selecionado somente para os índices climáticos El Niño 1+2 e 3. A baixa taxa de seleção do Modelo 3 mostra que na RH do Uruguai o parâmetro de escala (α) se ajusta melhor às séries temporais de cheias quando não varia de forma exponencial ao longo do tempo em função de uma covariável.

Ao analisar em conjunto as covariáveis levantadas (Tempo e ENOS) para a RH do Uruguai com os modelos não estacionários selecionados pelas séries, observa-se uma taxa relativamente alta entre a seleção de um modelo não estacionário para uma série considerando uma covariável, corresponder ao mesmo modelo não estacionário quando se considera outra covariável (ex. estação 2 com a covariável Tempo e ENOS), principalmente quando se foca nas regiões do ENOS (ex. 33, 31 e 24). Também se observa séries em que há a seleção de um modelo não estacionário considerando uma covariável, sendo selecionada por outro modelo não estacionário ao analisar outra covariável.

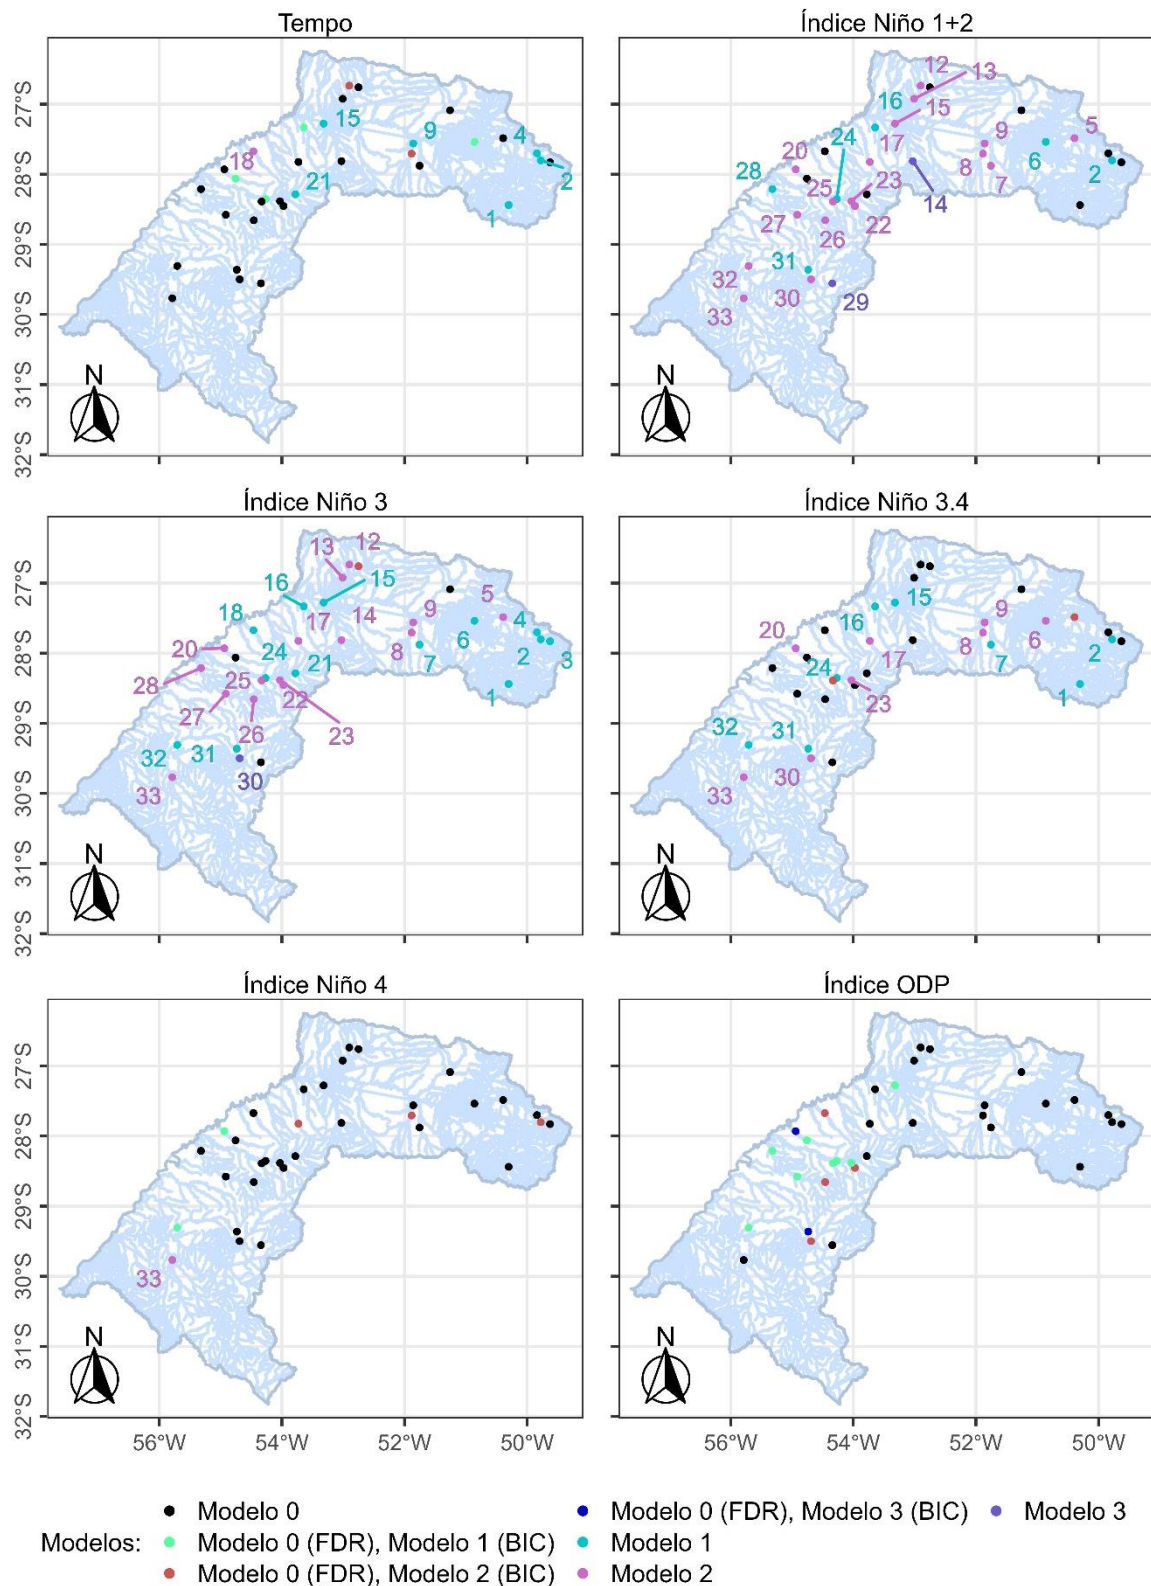


Figura 5.6 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise regional (FDR + IC). Considera-se cada índice da covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP) e o modelo escolhido em análise local (BIC) e regional (FDR + IC). O modelo estacionário escolhido na análise local: Modelo 0 (preto); e o modelo não estacionário escolhido na análise local que mudou para

um modelo estacionário após a análise regional: de Modelo 1 para 0 (verde), de Modelo 2 para 0 (vermelho) ou de Modelo 3 para 0 (azul-escuro). O modelo não estacionário escolhido após análise regional: Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

Na Tabela 5.2, pode-se observar uma tabela resumo sobre a quantificação e o levantamento da proporção das séries históricas selecionadas por cada modelo após a combinação de análise local, regional e dos intervalos de confiança dos parâmetros não estacionários, com foco na premissa da não estacionariedade, em relação a cada covariável levantada na Região Hidrográfica do Uruguai. Com a exceção da covariável ODP, para todas as outras covariáveis, houve respostas positivas sobre mudanças no comportamento das cheias, com a presença de pelo menos 3% (El Niño 4) de modelos não estacionários na RH do Uruguai, chegando até 88% (El Niño 3). Ao considerar a proporção entre a estacionariedade e a não estacionariedade, o modelo estacionário está presente com a maior proporção em 4 das 6 covariáveis levantadas.

Tabela 5.2 - Número de estações com séries hidrológicas selecionadas por cada um dos modelos estatísticos propostos (Modelo 0, 1, 2 ou 3) após análise local (BIC) e regional (FDR+IC). Considera-se cada covariável analisada (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP).

Covariável	Modelo				Modelos não estacionários
	0	1	2	3	
Tempo	26	6	1	0	7
%	78.79	18.18	3.03	0.00	21.21
El Niño 1+2	8	6	17	2	25
%	24.24	18.18	51.52	6.06	75.76
El Niño 3	4	13	15	1	29
%	12.12	39.39	45.45	3.03	87.88
El Niño 3.4	17	8	8	0	16
%	51.52	24.24	24.24	0.00	48.48
El Niño 4	32	0	1	0	1
%	96.97	0.00	3.03	0.00	3.03

Covariável	Modelo				Modelos não estacionários
	0	1	2	3	
ODP	33	0	0	0	0
%	100.00	0.00	0.00	0.00	0.00

Para corroborar com a abordagem metodológica proposta no presente estudo, foi realizado uma comparação entre os modelos finais da RH do Uruguai (após BIC, FDR e IC) e o suporte relativo de BIC ao uso do modelo estacionário (Modelo 0), conforme mostrado na Figura 5.7. O levantamento do suporte relativo para cada série analisada baseou-se nos modelos selecionados para cada série da RH em análise local (BIC), anterior a análise regional. O suporte relativo de BIC consiste na diferença (ΔBIC) entre o valor do critério de informação para o modelo estacionário (BIC_E), Modelo 0, e o valor mínimo do critério de informação (BIC_{\min}) entre os modelos propostos (Modelo 0, 1, 2 ou 3). O BIC_{\min} é o valor que representa o modelo que melhor se ajustou às séries temporais na análise local. O ΔBIC foi dividido em quatro faixas conforme realizado por Raftery (1995) (ex. Bauldry, 2015; Fabozzi et al., 2014; Lorah & Womack, 2019; Shen & González, 2021), valores entre 0 e 2 são interpretados como um bom suporte para o modelo estacionário. À medida que a diferença começa a aumentar entre 2 e 6, o suporte para modelos não estacionários começa a ser considerável, e em um intervalo de 6 a 10 o suporte de torna bem considerável. No último intervalo, quando o ΔBIC é superior a 10, o suporte a favor do modelo estacionário é muito fraco e a favor do modelo não estacionário é bem forte.

É relevante salientar como os intervalos de ΔBIC , que representam o suporte relativo de BIC ao uso do modelo estacionário, estão em sua maior parte em consonância com os modelos finais obtidos após aplicação do FDR com os intervalos de confiança de r_1 e β_1 . Tal afirmação pode ser averiguada ao observar que, com exceção de poucas séries modeladas por Niño 1+2, 3 e 3.4, todas as outras séries declaradas não estacionárias após todas as avaliações relacionadas à análise de frequência de cheias têm a diferença de ΔBIC superior a 2, o que significa maior suporte à não estacionariedade no local. Além disso, séries selecionadas como não estacionárias e posteriormente como estacionárias após a análise regional, em sua grande maioria, possuem ΔBIC inferiores a 2, valor que transmite o baixo suporte a não estacionariedade, e em nenhum caso superior a 6, valor em que o suporte a não estacionariedade se torna considerável.

Anzolin & Chaffe (2021) ao realizarem a análise de frequência de não estacionariedade de cheias no Brasil, baseadas em covariáveis (ex. Tempo e El Niño 3), selecionaram os modelos (modelo não estacionário parecido com o Modelo 2 ou modelo estacionário como o Modelo 0) que melhor se adequaram as séries de cheias por meio da aplicação dos critérios de informação de AIC e BIC. É interessante observar que o Δ BIC encontrado por Anzolin & Chaffe (2021), mesmo suporte aplicado no presente trabalho, quando a covariável analisada era o Tempo tem uma variação pequena para o Sul do Brasil com intervalos em sua maioria inferiores a 2. Na Figura 5.7, quando a covariável modelada é o Tempo, o modelo predominante é o Modelo 1, com intervalos em sua maioria entre 2 e 10, e a única série selecionada pelo Modelo 2 (similar ao modelo de Anzolin & Chaffe) possui Δ BIC superior a 10. Quando a covariável modelada é o índice do El Niño 3, o estudo de Anzolin & Chaffe (2021) mostra para a região do Sul um aumento das séries com intervalos entre 2 e 10 em relação à covariável Tempo. No presente trabalho, é notável também o aumento do número de séries selecionadas pelo Modelo 2, com intervalos em sua maioria entre 2 e 10, além disso, também há um aumento nas séries selecionadas pelo Modelo 1.

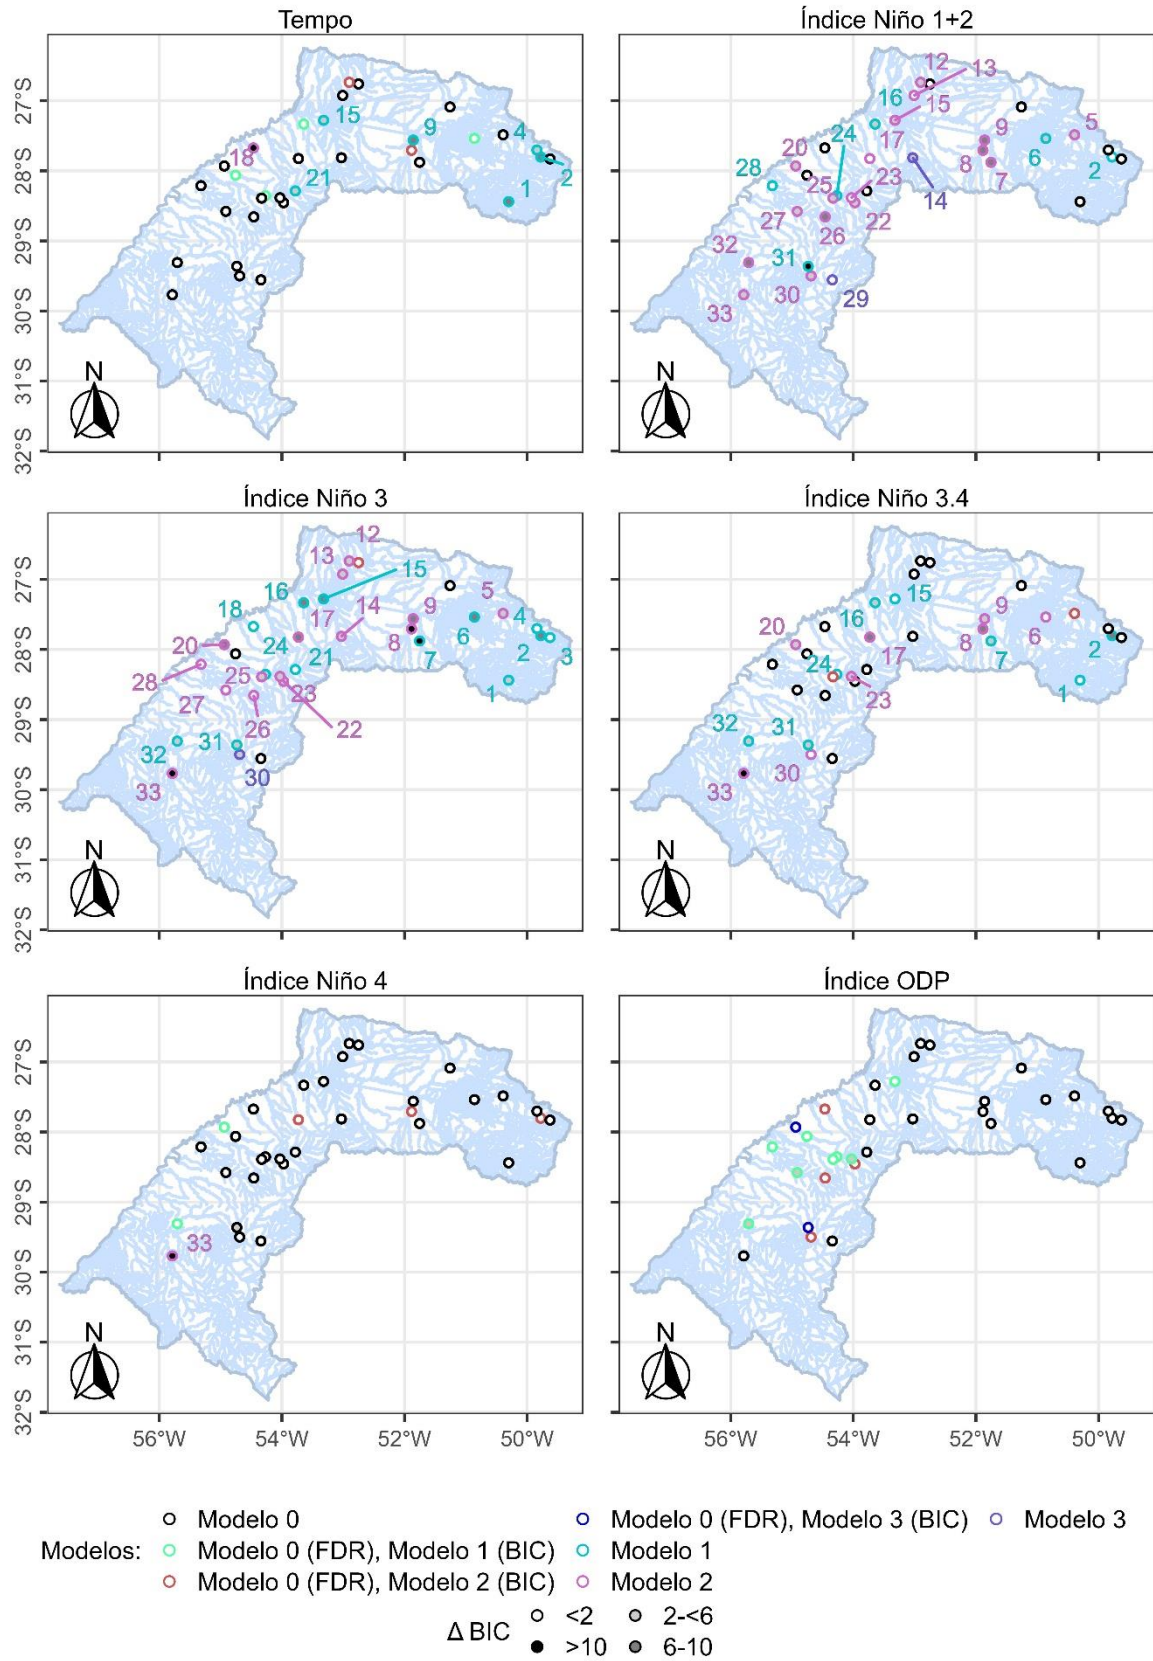


Figura 5.7 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise regional (FDR + IC) associadas com o suporte relativo (ΔBIC) após

análise local. Considera-se cada índice da covariável (Tempo, El Niño 1+2, El Niño 3, El Niño 3.4, El Niño 4 e ODP) e o modelo escolhido em análise local (BIC) e regional (FDR + IC). O modelo estacionário escolhido na análise local: Modelo 0 (círculo preto); e o modelo não estacionário escolhido na análise local que mudou para um modelo estacionário após a análise regional: de Modelo 1 para 0 (círculo verde), de Modelo 2 para 0 (círculo vermelho) ou de Modelo 3 para 0 (círculo azul-escuro). O modelo não estacionário escolhido após análise regional: Modelo 1 (círculo verde-claro), Modelo 2 (círculo rosa) ou Modelo 3 (círculo roxo). O preenchimento dos círculos representa o suporte relativo ao uso do Modelo 0 para o BIC, quanto maior o Δ BIC, maior é o suporte contra a estacionariedade: 0 a 2 (branco), 2 a 6 (cinza-claro), 6 a 10 (cinza-escuro), > 10 (preto). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

É interessante observar e relacionar algumas semelhanças entre a Figura 5.7 e a Figura 5.10. Inicialmente, quando se compara os valores de Δ BIC e os p-valores obtidos com a aplicação do TRV para as séries em que Δ BIC inferior a 2 (Covariáveis: El Niño 1+2, 3, 3.4 e 4), conforme mostrado na Figura 5.7, é evidente que o menor suporte à não estacionariedade também ocorre com os p-valores dessas séries, para os mesmos mecanismos de mudanças das cheias, que em sua maioria alcançam os maiores valores considerando as séries com indícios não estacionários (<0,01%), evidências mais fracas a favor da não estacionariedade. Em todas as covariáveis que são consideradas mecanismos de mudanças das cheias importantes na RH do Uruguai, o suporte relativo de BIC alcançou valores superiores a 10 para algumas das séries, e assim são as que possuem o maior suporte para a não estacionariedade. Essas mesmas séries na Figura 5.10 são as que possuem os menores p-valores para as correspondentes covariáveis e as maiores evidências significativas contra a estacionariedade. No geral, o Δ BIC e o p-valor possuem relações inversamente proporcionais.

Como pode ser observado na Tabela 5.2 e na Figura 5.6 quando se modela as cheias considerando os índices de ENOS com foco principalmente no El Niño 1+2, 3 e 3.4, observa-se que os Modelos 1 e 2 têm grande presença na região. Além disso, o ENOS considerando esses mesmos índices (El Niño 1+2, 3 e 3.4), possui taxas relativamente altas como mecanismos de mudanças de cheias influentes na RH do Uruguai, quando se considera todas as séries. Assim, com os resultados obtidos após análise local e regional de modelos, realizou-se uma comparação entre todos os modelos (Modelo 0, 1, 2 e 3) considerando todos

os índices do ENOS (El Niño 1+2, 3, 3.4 e 4), resultando em 12 hipóteses, na busca de alguma covariável e modelo que prevaleça como responsável pelas mudanças de cheias na região, como mostrado na Figura 5.8. A comparação entre as 12 hipóteses ocorreu por meio dos valores de BIC obtidos em análise local, com a restrição nas séries em que modelos não estacionários que em determinadas regiões do ENOS após avaliação do FDR e dos IC foram declaradas estacionárias.

Na Figura 5.8, é possível notar que não há um modelo e covariável predominante em toda a região. Mais ao sul da RH do Uruguai, o Modelo 2 na região do El Niño 1+2 é selecionado em mais séries do que quando comparado com outros modelos nas regiões do ENOS. O Modelo 2 na região do El Niño 3.4 e o Modelo 1 na região do El Niño 1+2 também se mostram presentes no sul da RH com mais de uma série selecionada. No restante da região hidrográfica, o Modelo 1 na região do El Niño 3 se sobressai. O Modelo 2 na região do El Niño 3 também se mostra presente com algumas séries no restante da RH. Pode-se observar então que, com a exclusão do sul da RH, o índice El Niño 3 alcançou os menores valores de BIC e mostrou-se como a covariável com maior influência em grande parte da RH do Uruguai. É interessante observar que todos os modelos não estacionários propostos (Modelo 1, 2 e 3) obtiveram os menores valores de BIC e foram selecionados, e que todas as regiões do ENOS com exceção do El Niño 4, também foram selecionadas como possíveis mecanismos de mudanças das cheias.

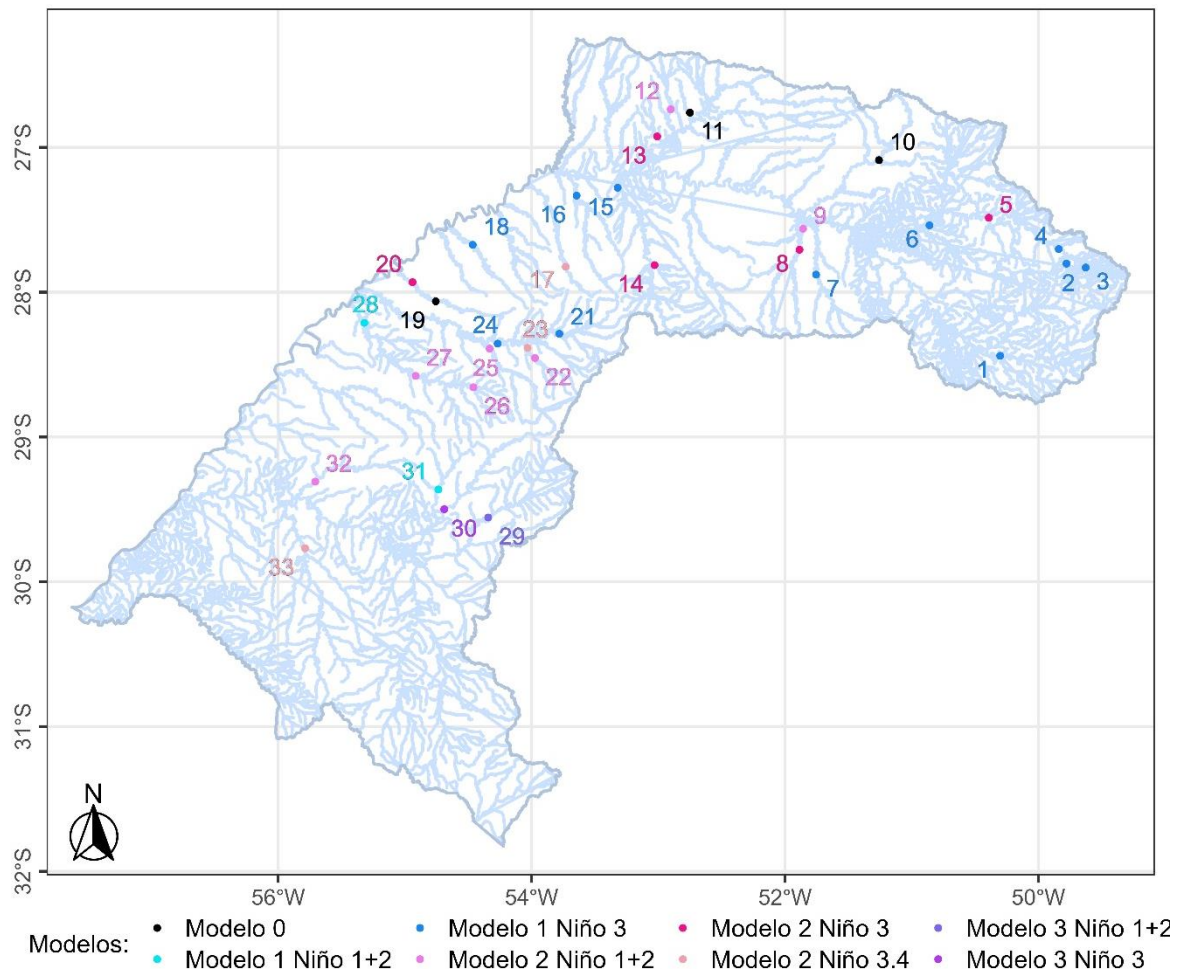


Figura 5.8 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise local (BIC), regional (FDR + IC) e comparação entre os BIC.

Considera-se o índice da covariável (El Niño 1+2, El Niño 3, El Niño 3.4 ou El Niño 4) e o modelo (Modelo 1, 2 ou 3) escolhido quando há a comparação entre BIC. O modelo estacionário escolhido na análise local: Modelo 0 (preto); Modelo 1 Niño 1+2 (azul-claro); Modelo 2 Niño 1+2 (rosa-claro); Modelo 3 Niño 1+2 (roxo-claro); Modelo 1 Niño 3 (azul), Modelo 2 Niño 3 (rosa); Modelo 3 Niño 3 (lilás); Modelo 2 Niño 3.4 (bege). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

Comparou-se também, para cada série, o modelo estatístico com menor valor de BIC entre as 12 hipóteses com o modelo com o segundo menor valor de BIC, como mostrado na Figura 5.9. É válido salientar que para os modelos em segundo lugar também houve a avaliação regional, como ocorreu para os modelos em primeiro lugar. Essa análise se deu por meio do suporte relativo de BIC, que consistiu na diferença (Δ BIC) entre o segundo valor mínimo do critério de informação e o valor mínimo do critério de informação entre as 12 hipóteses. O Δ BIC foi dividido em quatro faixas, conforme realizado anteriormente na Figura 5.7, com

valores entre 0 e 2 sendo interpretados como uma baixa diferença entre a influência da primeira e da segunda hipótese nas cheias. À medida que a diferença começa a aumentar entre 2 e 6, a influência para o primeiro modelo considerando a região do ENOS em relação ao segundo colocado começa a ser considerável, e em um intervalo de 6 a 10 essa diferença nas influências é bem considerável. No último intervalo, quando o ΔBIC é superior a 10, a influência da primeira hipótese em relação a segunda é bem mais forte.

Na Figura 5.9, é possível notar inicialmente, para as hipóteses que são a segunda opção que melhor se adequou as séries de cheias, um aumento de séries em que o Modelo 0 (estacionário) foi escolhido, em grande parte essa escolha ocorreu após aplicação do FDR. No sul da RH, é possível observar uma maior presença em relação às outras hipóteses do Modelo 1 Niño 1+2 e depois do Modelo 2 Niño 3 como hipóteses que alcançaram o segundo menor valor de BIC. Para o restante da região, não é possível observar um modelo tão predominante como encontrado na Figura 5.8 (Modelo 1 Niño 3). Com a segunda hipótese mais presente sendo o Modelo 2 Niño 3 e depois o Modelo 0 e o Modelo 2 Niño 1+2. É interessante observar que os ΔBIC na maior parte possuem intervalos entre 0 e 2, ou seja, o grau de interferência da primeira e da segunda hipótese nas cheias é parecido, e que o maior intervalo de ΔBIC é entre 2 e 6. Ambos resultados mostram a similaridade na modelagem das cheias para a RH do Uruguai entre os modelos propostos e as regiões do ENOS levantadas que alcançaram os menores e os segundos menores valores.

É de grande relevância notar algumas conexões entre as primeiras e segundas hipóteses, séries selecionadas pelo Modelo 1 Niño 1+2 também são selecionadas pelo Modelo 2 Niño 1+2, o que mostra a influência do Niño 1+2 nessas séries. Séries em que o Modelo 1 Niño 3 é escolhido, em grande parte, também é escolhido pelo Modelo 2 Niño 3, mostrando também a influência do Niño 3 nessas séries. Sendo interessante observar a conexão nessas séries em que os Modelos selecionados simultaneamente são o 1 e o 2, e que alcançam ΔBIC baixos. Essa conexão entre os dois modelos pode ocorrer devido à similaridade entre as estruturas, em que o parâmetro de forma (κ) é constante, o parâmetro de posição (ξ) varia linearmente em função das covariáveis, e a diferença entre os dois consiste na modelagem do parâmetro de escala (α). No Modelo 1, α varia em função de ξ para que o coeficiente de variação (C_v) seja constante, e no Modelo 2, α permanece constante. É possível observar também na Figura 5.9, a presença em uma mesma série do Modelo 2 Niño 3 e Modelo 2 Niño 1+2, bem como em uma mesma série ter o Modelo 1 Niño 3 e o Modelo 0 sendo optados.

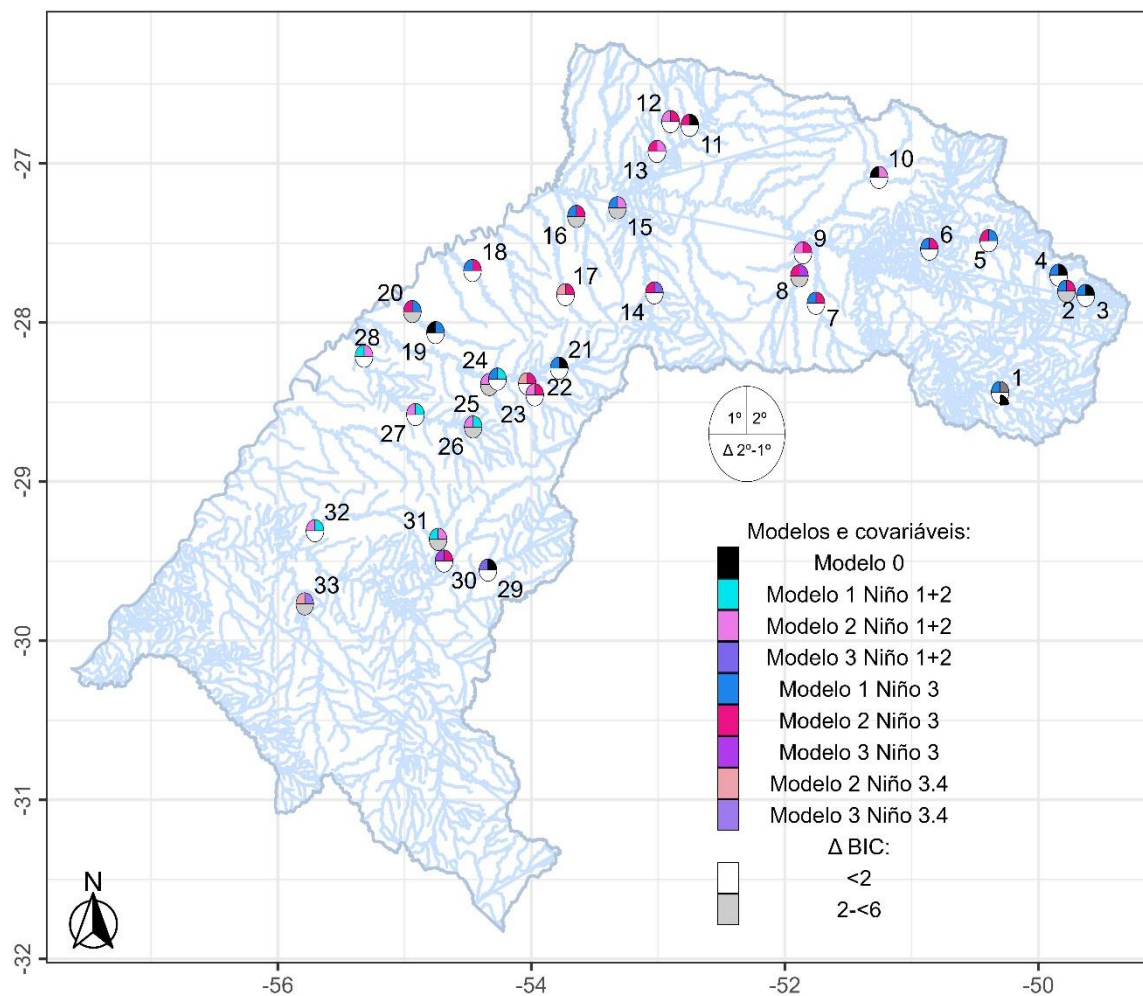


Figura 5.9 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai após análise local (BIC), regional (FDR + IC) e comparação entre os BIC associadas com o suporte relativo (ΔBIC). Considera-se o índice da covariável (El Niño 1+2, El Niño 3, El Niño 3.4 ou El Niño 4) e o modelo (Modelo 1, 2 ou 3) escolhido quando há a comparação entre BIC. A cor representada no segundo quadrante se refere a hipótese com menor valor de BIC, e no primeiro quadrante a hipótese com o segundo menor BIC. O modelo estacionário escolhido na análise local: Modelo 0 (preto); Modelo 1 Niño 1+2 (azul-claro); Modelo 2 Niño 1+2 (rosa-claro); Modelo 3 Niño 1+2 (roxo-claro); Modelo 1 Niño 3 (azul), Modelo 2 Niño 3 (rosa); Modelo 3 Niño 3 (lilás); Modelo 2 Niño 3.4 (bege). Os rótulos indicam o número da estação com a série de dados (Figura 4.3). O preenchimento dos círculos representa a diferença entre o grau de influência entre as hipóteses nas cheias, quanto maior o ΔBIC , maior é a diferença: 0 a 2 (branco), 2 a 6 (cinza-claro), 6 a 10 (cinza-escuro), > 10 (preto). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

5.3 - ANÁLISE DO COMPORTAMENTO NÃO ESTACIONÁRIO

Como não houve a preferência de um único melhor modelo para uma determinada região do ENOS para toda a RH do Uruguai, como visto na Figura 5.8 e na Figura 5.9, optou-se por analisar o comportamento não estacionário da RH considerando os modelos não estacionários (Modelos 1, 2 e 3) que melhor se ajustaram às séries temporais de vazões máximas anuais na RH do Uruguai após análise local (BIC) e regional (FDR e IC), nos quais os parâmetros do modelo são funções das covariáveis que possuem certa influência na região (Tempo, El Niño 1+2, 3, 3.4 e 4). Para essa análise do comportamento de não estacionariedade, é de grande valia quantificar a taxa de mudanças nos quantis de cheia obtidos pelos modelos não estacionários ao longo do tempo e o grau de evidência estatística contida na amostra analisada. A quantificação da taxa permite uma avaliação da significância prática do comportamento não estacionário nessas séries temporais, enquanto o grau de evidência indica o quão confiável é a seleção de modelos não estacionários para as séries estudadas (AghaKouchak et al., 2013).

A Figura 5.10 mostra, para as covariáveis (*c*) Tempo, El Niño 1+2, 3, 3.4 e 4, a taxa percentual nas estimativas da cheia de 50 anos, vazão igualada ou superada em 2% do tempo ($Q_{0.98}$), ao longo do período histórico versus os p-valores obtidos por meio do TRV quando se compara os modelos não estacionários (Modelo 1, 2 ou 3) após análise local, regional e dos IC versus o modelo estacionário (Modelo 0). Quanto menor o p-valor (eixo x), mais forte será a evidência estatística de rejeição à hipótese de estacionariedade. As taxas de mudança (eixo y) foram elaboradas com base na variação relativa máxima dos quantis de cheias ($\Delta_{rel}Q_{0.98}$) considerando os valores extremos das covariáveis, comparando o menor valor do índice com o maior valor do índice disponível na série temporal da covariável. Para a covariável Tempo, a taxa foi calculada por década, e o termo *n* representa o número de anos da série de cheias. É importante citar que os valores extremos não estão necessariamente relacionados de um ano para outro, mas ao longo da série da covariável.

É interessante notar que, para todos os cenários de mecanismos de influência nas cheias, o Modelo 1 geralmente apresenta a maior variação percentual nas estimativas de $Q_{0.98}$ em relação ao Modelo 2. Também é possível notar que em várias séries selecionadas pelo Modelo 1, quanto maior a evidência contra a estacionariedade, menor o p-valor, e mais altas são as taxas de mudanças dos quantis de cheias de 50 anos. Quando se olha somente as taxas

provocadas pelo ENOS em todas as regiões (1+2, 3, 3.4 e 4), observa-se a presença de altas variações nessas taxas, o que mostra como os eventos opostos de El Niño e La Niña afetam drasticamente os quantis de cheias.

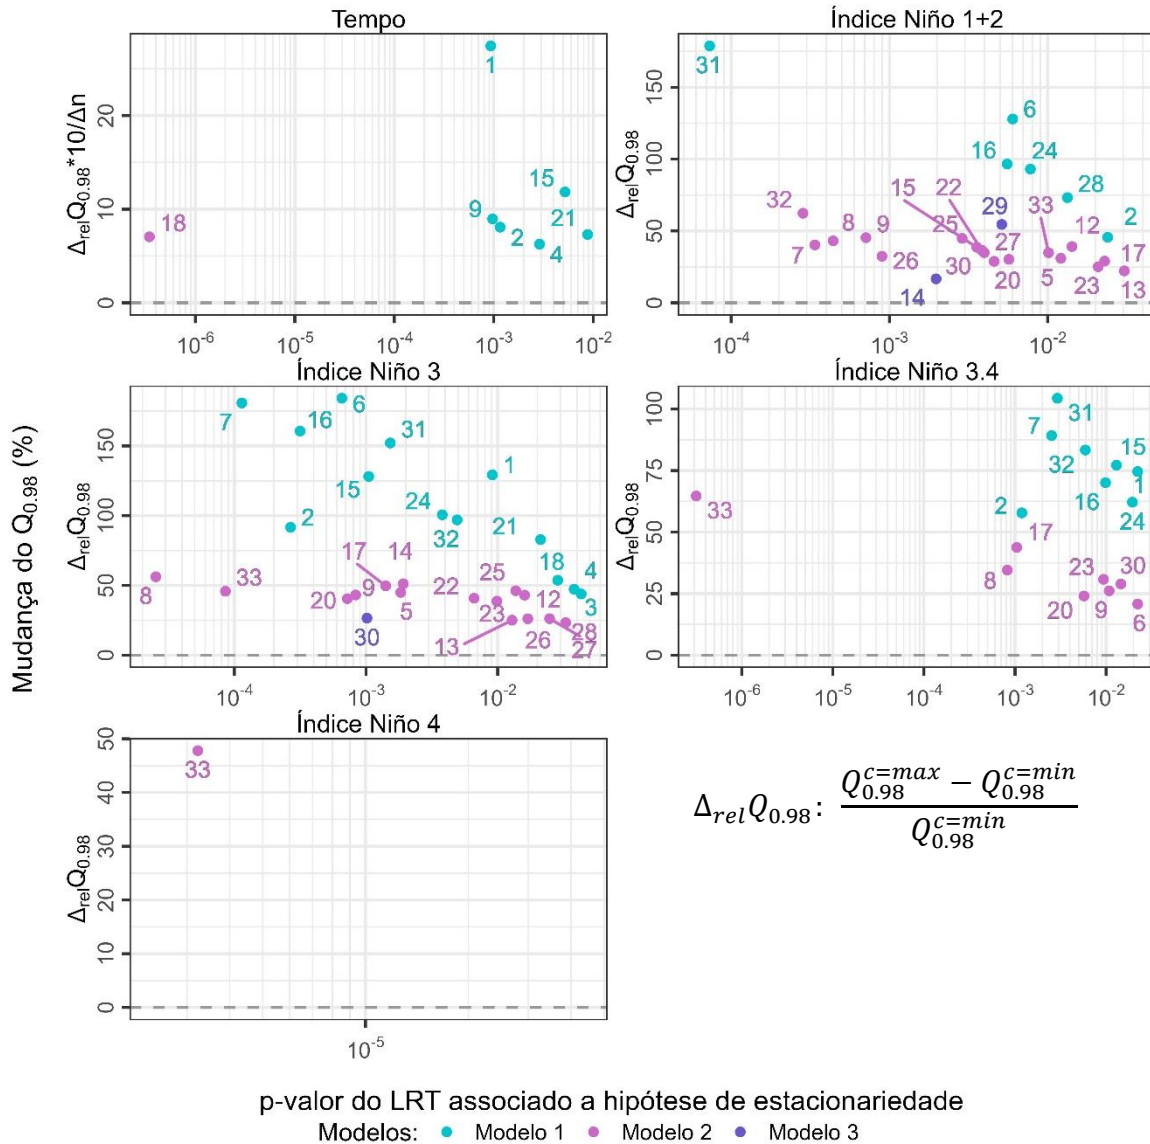


Figura 5.10 - Taxas percentuais de mudanças da cheia de 50 anos versus os p-valores associados ao TRV. Considera-se cada covariável (Tempo, El Niño 1+2, 3, 3.4 e 4) e o modelo não estacionário escolhido após análise regional (FDR + IC): Modelo 1 (verde-claro), Modelo 2 (rosa) ou Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

Para todas as séries temporais selecionadas por modelos não estacionários, cujos parâmetros são funções do Tempo, há uma elevação por década nas cheias de 50 anos, tendências positivas, durante o período histórico. Com valores variando entre 6 e 28% por década, com

5 séries temporais tendo taxas de aumento relativamente suaves (5 a 10%), a estação 15 com taxas maiores entre 10 e 15%, e a estação 1 com aumento nas cheias de 50 anos considerado alto (28%). Tais resultados corroboram com a análise Slater et al. (2021) que, ao analisarem as mudanças globais nas cheias de 20, 50 e 100 anos com a covariável Tempo, observaram um aumento das cheias de 50 anos no Sul do Brasil, chegando a mais de 50% em algumas localidades. É de grande valia também observar na Figura 5.10 que, para a modelagem do Tempo, a evidência estatística é relativamente forte para a rejeição da hipótese estacionária em todas as séries temporais, com p-valores inferiores a 1%. Com grande parte das séries possuindo p-valores próximos a 1% e 0.1%, com a estação 18 (Modelo 2) chegando até a um p-valor inferior a 10^{-6} , maior evidência estatística contra o Modelo 0.

Quando a análise da taxa do $Q_{0.98}$ relacionada aos extremos ocorre pela covariável ENOS na região do El Niño 1+2, a variação é entre 17% (Modelo 3, estação 14) e 178% (Modelo 1, estação 31). Com a maioria das taxas próximas a 25 até 50%, principalmente considerando o Modelo 2. Para o Modelo 1 as variações nas mudanças do $Q_{0.98}$ são mais altas e se encontram majoritariamente entre próximo a 75 até 125%. Em relação à evidência estatística contra a hipótese da estacionariedade, quase 50% das séries possuem evidências significativas de rejeição ao Modelo 0, com p-valores superiores a 0.1%, e inferiores a 1%, e com o menor p-valor sendo inferior a 10^{-4} (Modelo 1, estação 31). Outros dois aglomerados de séries se encontram ou com p-valores de 0.1 a 0.01% (evidências ainda mais fortes contra a estacionariedade), ou com evidências mais fracas com p-valores sendo superiores a 1%.

Na região do El Niño 3, as taxas do $Q_{0.98}$ relacionadas aos extremos se encontram entre 23% (Modelo 2, estação 28) e 184% (Modelo 1, estação 6). Com todas as séries selecionadas pelo Modelo 2 e 3, e algumas pelo Modelo 1, com taxas entre aproximadamente de 25 até 50%. Já para o restante das séries de cheias em que o Modelo 1 foi o que melhor se adequou, as variações nas mudanças do $Q_{0.98}$ são espalhadas de 75% até um pouco acima dos 175%, taxas mais altas. Em relação aos p-valores, não há um intervalo em que se vê grande parte das séries, as séries são espalhadas de forma similar no intervalo superior a 1%, entre 0.1 e 1%, e no intervalo inferior a 10^{-4} até 0.1%, representando respectivamente o aumento das evidências significativas contra o Modelo 0.

Para o ENOS na região do El Niño 3.4, a variação ocorre entre 24% (Modelo 2, estação 6) e 105% (Modelo 1, estação 31). Com a maior parte das taxas próximas a 25 até 50%, taxas

mais suaves, para o Modelo 2. Séries selecionadas pelo Modelo 1 possuem variações nos quantis de cheias maiores que 50 até próximo a 100%. Mais de 50% das séries possuem evidências significativas de rejeição ao Modelo 0, com p-valores entre 0.1% até 1%. Outra grande parte possui evidências mais fracas com p-valores superiores a 1%. E a estação 33 (Modelo 2) alcança o menor p-valor entre todas as regiões do El Niño com o valor de 10^{-6} . Na última região do ENOS levantada, a região El Niño 4, a estação 33 (Modelo 2) possui variação na taxa do quantil de 50 anos de 48%, com p-valor inferior a 10^{-6} , evidência bem forte contra a hipótese de estacionariedade.

Para todas as séries temporais em que o modelo não estacionário (Modelo 1, 2 ou 3) foi o que melhor se adequou, o quantil da cheia de 50 anos ($Q_{0.98}$) com seu intervalo de confiança (IC) de 95% (método Delta) foi estimado tanto para a hipótese de estacionariedade quanto para a não estacionariedade quando se considera os valores extremos das covariáveis (Tempo, El Niño 1+2, 3, 3.4 e 4), APÊNDICE C. Para exemplificar, é possível ver na Figura 5.11 o $Q_{0.98}$ com seus IC de uma série por covariável. As escolhas das séries foram baseadas nas maiores variações das taxas percentuais da cheia de 50 anos (Figura 5.10) dos Modelos 1, 2 e 3, considerando as covariáveis Tempo, El Niño 1+2, El Niño 3, El Niño 3.4 e El Niño 4 respectivamente.

O quantil não estacionário máximo, quando a covariável alcança seu maior índice, para todas as séries alcança valores superiores aos valores obtidos quando comparados com o quantil estacionário, e em muitos casos o quantil máximo chega até a ultrapassar o IC do quantil estacionário, como pode-se notar na Figura 5.11. Ou seja, caso o quantil não estacionário de 50 anos ocorresse, em vez do calculado considerando a estacionariedade das cheias, técnica usual, as vazões que atingiram a região poderiam alcançar valores bem superiores do que as previstas, podendo assim haver uma subestimação das cheias. Nos casos em que os $Q_{0.98}$ não estacionários são mínimos, esses quantis são inferiores aos quantis estacionários, Figura 5.11 e APÊNDICE C. Em uma situação de ocorrência do quantil mínimo, ocorreria a superestimação das cheias. Ambos os cenários de subestimação e superestimação continuam sendo uma grande questão no tema de não estacionariedade. Pois, por exemplo, pode depender gastos excessivos em infraestruturas em casos de superestimação, mas também, pode acarretar desastres que afetam diretamente a sociedade em casos de subestimação (Luke et al., 2017; Salas et al., 2018; Salas & Obeysekera, 2014; Šraj et al., 2016).




Figura 5.11 - Quantis da cheia de 50 anos. Considera-se os índices extremos para cada covariável (Tempo, El Niño 1+2, 3, 3.4 e 4) para séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade (Modelo 0) para essas séries. Menor índice da covariável: Modelo 1 (verde-claro), Modelo 2 (rosa-claro) e Modelo 3 (roxo-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro), Modelo 2 (rosa-escuro) e Modelo 3 (roxo-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

Na análise de frequência de cheias não estacionárias correlacionadas às covariáveis na RH do Uruguai, também se realizou um estudo mais detalhado sobre o comportamento de cada série de vazões máximas anuais de cada estação em que o modelo não estacionário foi o que melhor se adequou, APÊNDICE D. Para essas séries temporais, o quantil da cheia de 50

anos ($Q_{0,98}$) foi estimado tanto para a hipótese de estacionariedade quanto para o modelo não estacionário, ambos quantis com seus respectivos intervalos de confiança, não apenas para os extremos, como na Figura 5.11, mas também, ao longo de toda a série de vazões anuais, com um nível de confiança de 95%, obtido pelo método Delta (Figura 5.12a, Figura 5.13a, Figura 5.14a, Figura 5.15a e Figura 5.16a). Além disso, foi estimado também as vazões medianas ($Q_{0,5}$) tanto para o modelo estacionário quanto para o não estacionário ao longo de toda a série de vazões anuais (Figura 5.12c, Figura 5.13c, Figura 5.14c, Figura 5.15c e Figura 5.16c).

Para todas as séries temporais, as funções de densidade de probabilidade (PDF) (Figura 5.12b, Figura 5.13b, Figura 5.14b, Figura 5.15b e Figura 5.16b) foram estimadas para a hipótese estacionária, bem como para o modelo não estacionário considerando os dois extremos das covariáveis. Portanto, quando o modelo não estacionário melhor se adequa à série analisada, houve a plotagem de três PDF (1 estacionária, 2 não estacionárias). A plotagem das três PDF permite a visualização da transformação da PDF de um extremo a outro extremo da covariável e sua relação com a hipótese de estacionariedade.

As probabilidades de excedência (q) das três PDF foram estimadas com base no quantil estacionário de referência de 50 anos ($Z_{Q_{0,98}}^{\text{Mod.0}}$) (Figura 5.12d, Figura 5.13d, Figura 5.14d, Figura 5.15d e Figura 5.16d). É de extrema relevância entender melhor como as séries temporais em que há indícios de não estacionariedade podem afetar os processos hídricos e, conseqüentemente o gerenciamento hídrico. Estimar as probabilidades de excedência auxilia nesse entendimento, pois assim é possível ter uma estimativa de quando esta vazão de referência, utilizada em projetos e operação de estruturas hidráulicas, pode ser igualada ou superada num ano qualquer, considerando o cenário não estacionário. Para todos os modelos não estacionários propostos no presente estudo, os valores do parâmetro de posição (ξ) mudam em função da covariável, variando conforme a tendência observada entre a covariável e as cheias, o que provoca a alteração da PDF ao longo do tempo. A variação de ξ nos extremos de séries com modelos não estacionários e sua relação com a estacionariedade conectada às respectivas PDF podem ser observadas na Figura 5.12d, Figura 5.13d, Figura 5.14d, Figura 5.15d e Figura 5.16d.

No presente estudo, foram escolhidas algumas séries temporais da RH do Uruguai selecionadas pelos modelos não estacionários (Modelo 1, 2 e 3), nas quais os parâmetros são funções das covariáveis: Tempo, El Niño 1+2, El Niño 3, El Niño 3.4 e El Niño 4, que evoluem ao longo do tempo, para discussão e demonstração do estudo mais detalhado. Todos os outros painéis que abordam sobre as relações dos quantis e das PDF das séries históricas das estações restantes se encontram no APÊNDICE D. Essa escolha foi feita para ilustrar de forma geral os padrões de variação observados nas vazões máximas anuais ao longo do tempo para os diferentes modelos considerando as diferentes covariáveis (Figura 5.12, Figura 5.13, Figura 5.14, Figura 5.15 e Figura 5.16). As escolhas das séries foram baseadas na mesma lógica da Figura 5.11, na qual optou-se pelas séries com maiores variações das taxas percentuais da cheia de 50 anos (Figura 5.10) dos Modelos 1, 2 e 3, considerando as covariáveis analisadas.

A Figura 5.12 representa a série de vazões anuais máximas da estação 1 (70200000) com 45 anos de dados modelada pelo Modelo 1, no qual os parâmetros $\xi(c)$ e $\alpha(c)$ (C_V constante) variam em função do Tempo, variando de 1 até 45. Esta série temporal apresenta o maior aumento por década no $Q_{0.98}$ (28%), com um p-valor próximo a 0.1%, Figura 5.10. Na Figura 5.12a e c, é possível observar tanto $Q_{0.98}$ quanto $Q_{0.5}$ crescendo e variando linearmente no tempo, padrão que se repete para todas as séries temporais que variam no Tempo, mostrando o aumento nas cheias de 50 anos ao longo do tempo. Em todas essas séries temporais, o $Q_{0.98}$ não estacionário com seu IC alcança valores inferiores e/ou superiores ao IC calculado para a hipótese estacionária, resultado de interesse no planejamento e gestão hídrica, como comentado anteriormente com a Figura 5.11.

Na Figura 5.12b e Figura 5.13b pode-se visualizar a variação no comportamento da PDF não estacionária quando o Modelo 1 é selecionado. De maneira geral, para todas as covariáveis analisadas na RH do Uruguai nas séries selecionadas pelo Modelo 1, a PDF do menor índice da covariável possui a curva de densidade com pico mais alto e mais estreito, abrangendo vazões máximas anuais menores. Já para a PDF correspondente ao maior valor da covariável na série, a curva de densidade é mais suave e extensa, atingindo vazões máximas maiores.

Na Figura 5.12d é de grande relevância observar como as probabilidades de excedências (q) associadas ao modelo não estacionário mudam quando comparados ao quantil de referência de 50 anos estacionário. Considerando a covariável Tempo, para todas as séries temporais,

q varia de $\pm 2\%$, valor da probabilidade quando se considera $Z_{Q_{0.98}}^{Mod.0}$. A série de cheias da estação 1 alcança a probabilidade de 0.14 a 6.57%. Ou seja, se em 2012 fosse estimado a cheia de 50 anos considerando a hipótese estacionária, a probabilidade de 2% se considerasse o modelo não estacionário (Modelo 1), seria de 6.57% para alcançar ou ultrapassar um quantil de cheias de 3 005 m^3/s . Para o Modelo 1, as probabilidades de excedência na modelagem de todas as covariáveis (Tempo e ENOS) atingem as maiores taxas quando as covariáveis analisadas alcançam seus valores mais altos e as menores taxas quando as covariáveis são as menores.

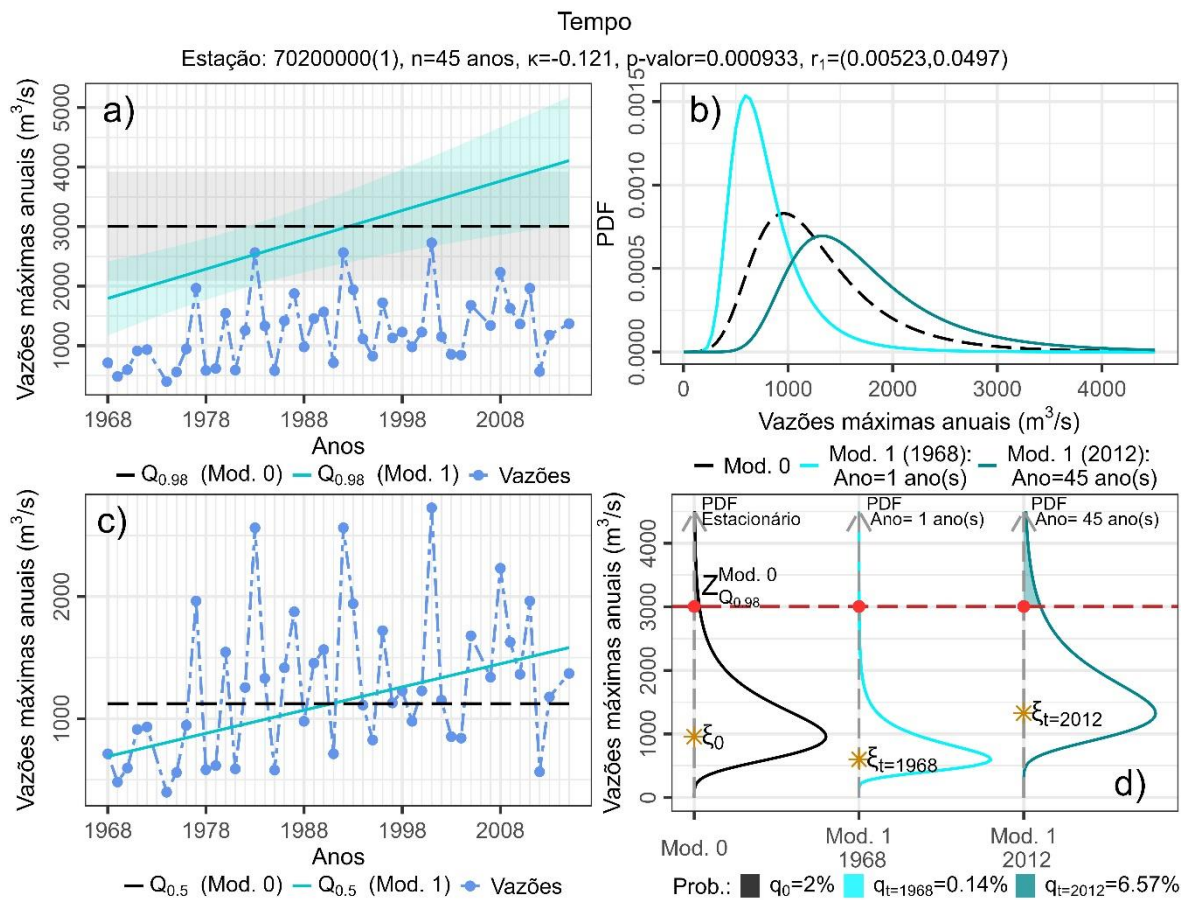


Figura 5.12 - Resultados para séries temporais da estação 1 (70200000) para a covariável Tempo. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em verde-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 1 no ano inicial (verde-claro) e no ano final (verde-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (verde-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}^{Modelo0}}$, e o ξ de cada PDF.

Na Figura 5.13 é possível ver a série de cheias da estação 6 (71550000) com 59 anos de dados selecionada pelo Modelo 1, no qual o parâmetro $\xi(c)$ e o $\alpha(c)$ (C_V constante) variam em função do ENOS na região do El Niño 3. Como a anomalia na TSM provocada pelo ENOS tem um valor não linear por ano, então o parâmetro $\xi(c)$ não varia linearmente igual na covariável Tempo. Esta série apresenta a maior taxa de variação na cheia de 50 anos (184%) e com p-valor próximo a 0.1%, Figura 5.10. A Figura 5.13a e c mostram o $Q_{0.98}$ e o $Q_{0.5}$ variando não linearmente ao longo do tempo conforme o valor da covariável muda. Quando se observa todas as séries não estacionárias modeladas pelo ENOS em todas as regiões analisadas (El Niño 1+2, 3, 3.4 e 4) e todos os modelos propostos (Modelo 1, 2 e 3), os $Q_{0.98}$ não estacionários e seu respectivos IC também conseguem ultrapassar inferiormente e/ou superiormente o IC do Modelo 0, como pode ser visto na Figura 5.13a, Figura 5.14a, Figura 5.15a e Figura 5.16a, resultado similar ao encontrado para a covariável Tempo.

A Figura 5.13d fornece as variações de probabilidades de excedências associadas ao modelo não estacionário em função do El Niño 3. Similar a covariável Tempo, para todas covariáveis ENOS (El Niño 1+2, 3, 3.4 e 4), as probabilidades de excedência também variam de $\pm 2\%$, mas, com taxas que chegam alcançar valores ainda mais altos do que na covariável Tempo. Na região do El Niño 3 as cheias da estação 6 alcançam probabilidades entre 0.14% quando a anomalia na TSM é de -1.31 °C (menor valor do índice) até 11.05% quando a anomalia de TSM é de 1.81 °C (maior valor do índice). Resultado que mostra na prática como os fenômenos opostos El Niño e La Niña influenciam as cheias de 50 anos.

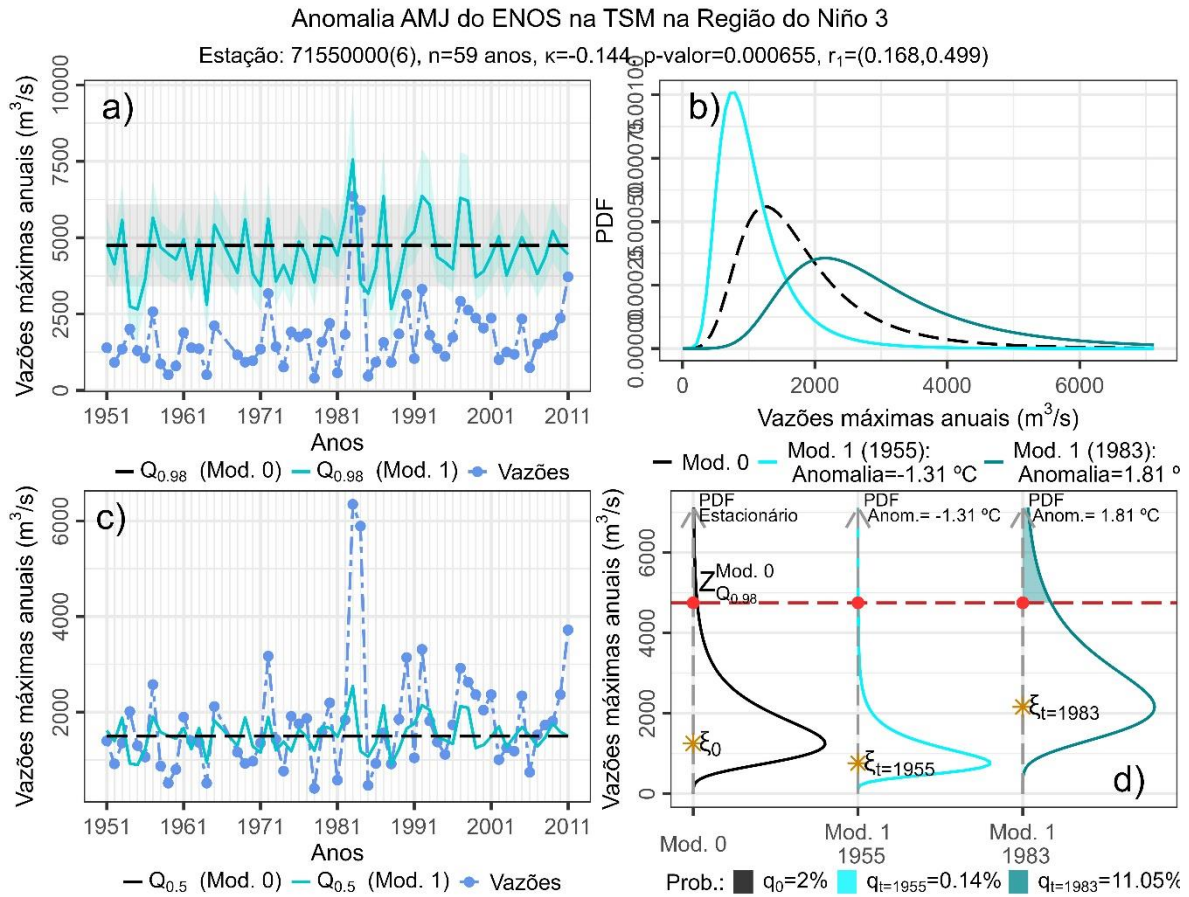


Figura 5.13 - Resultados para séries temporais da estação 6 (71550000) para a covariável de El Niño 3. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em verde-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 1 considerando a menor anomalia (verde-claro) e a maior anomalia (verde-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (verde-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.

As Figura 5.14 e a Figura 5.15 abordam sobre a série de cheias da estação 33 (76750000) que possuem 72 anos de dados e que o Modelo 2 foi o modelo escolhido após todas as análises tanto considerando a covariável El Niño 3.4 quanto a El Niño 4. Nesse modelo, os parâmetros $\xi(c)$ e $\alpha(c)$ variam em função do ENOS na região do El Niño 3.4 e 4. Esta série é a única selecionada por um modelo não estacionário para a covariável El Niño 4, com taxa de variação no $Q_{0.98}$ de 48% e p-valor inferior a 10^{-5} %. Para a covariável El Niño 3.4, é nessa estação que há a maior variação na cheia de 50 anos (63%) para o Modelo 2 e com o menor p-valor (10^{-6} %) para a covariável, Figura 5.10. Comparando ambas covariáveis para a

mesma estação, observa-se que os p-valores possuem a rejeição à estacionariedade bem fortes e ambas as variações dos $Q_{0,98}$ são divergentes, porém, não muito distantes.

As Figura 5.14b e Figura 5.15b mostram a variação no comportamento da PDF não estacionária quando o Modelo 2 é escolhido. Geralmente, em todas as covariáveis analisadas na RH do Uruguai (Tempo e ENOS) com séries selecionadas pelo Modelo 2, as PDF do menor índice e maior índice da covariável possuem curvas de densidade em formas semelhantes, com a curva da menor covariável cobrindo uma faixa com vazões máximas anuais inferiores do que a curva da maior covariável.

Na região do El Niño 3.4 (Figura 5.14d) as cheias da estação 33 alcançam probabilidades entre 0.02% (anomalia na TSM de $-1,13\text{ }^{\circ}\text{C}$) até uma probabilidade alta de 20.01% (anomalia na TSM de 2.55), porcentagem 10 vezes maior do que a encontrada para a hipótese da estacionariedade. Já na região do El Niño 4 (Figura 5.14d) as cheias dessa mesma estação alcançam probabilidades entre 0.04% (anomalia na TSM de $-1,13\text{ }^{\circ}\text{C}$) até uma probabilidade alta de 11.7% (anomalia na TSM de 2.55), porcentagem menor do que a encontrada para a covariável El Niño 3.4. Assim como no Modelo 1, para o Modelo 2, as probabilidades de excedência considerando todas as covariáveis (Tempo e ENOS) alcançam os maiores valores quando as covariáveis atingem seus valores máximos e os menores valores para os índices mais baixos.

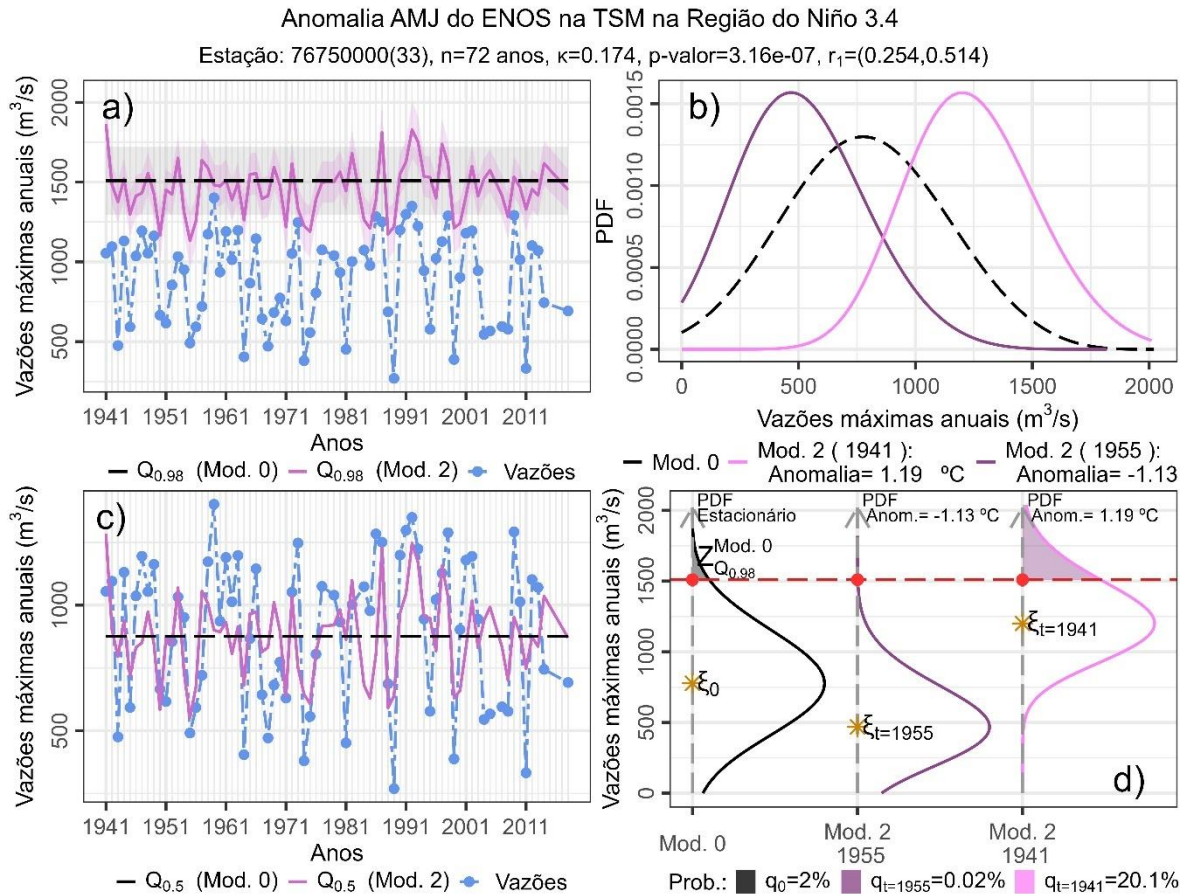


Figura 5.14 - Resultados para séries temporais da estação 33 (76750000) para a covariável El Niño 3.4. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 2 considerando a menor anomalia (rosa-claro) e a maior anomalia (rosa-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 2 (rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.

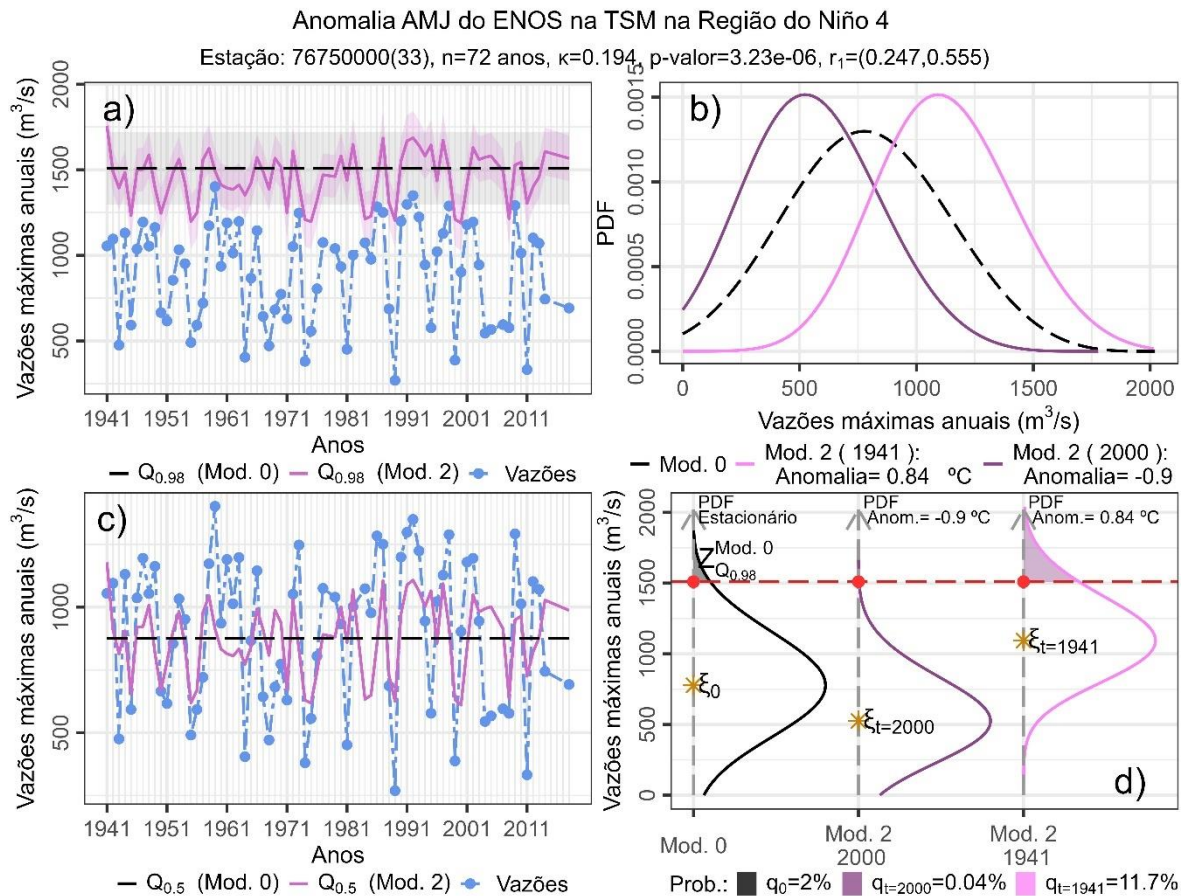


Figura 5.15 - Resultados para séries temporais da estação 33 (76750000) para a covariável El Niño 4. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 2 considerando a menor anomalia (rosa-claro) e a maior anomalia (rosa-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 2 (rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.

Para o Modelo 3 a estação 29 (76100000) com 78 anos (Figura 5.16) foi a escolhida para maior detalhamento no presente estudo. Para essa série, os parâmetros $\xi(c)$ e $\alpha(c)$ variam em função do ENOS na região do El Niño 1+2. $\xi(c)$ variando linearmente e $\alpha(c)$ variando de forma exponencial ao longo do tempo. Essa série apresenta o maior aumento na cheia de 50 anos (52%) em relação às séries selecionadas pelo Modelo 3 e com p-valor inferior a 0.1% (Figura 5.10).

A Figura 5.16b mostra a mudança no comportamento da PDF não estacionária quando se seleciona o Modelo 3. Para as três séries que melhor se adequaram ao Modelo 3 (El Niño 1+2 e 3), a PDF do maior índice da covariável na série possui a curva de densidade com pico bem mais alto e estreito, abrangendo valores de cheias anuais maiores. Para a PDF de menor índice da covariável, a curva de densidade é bem mais suave, achatada e de maior extensão, alcançando vazões máximas desde inferiores até superiores às encontradas pela PDF do maior índice. As formas das PDF do Modelo 3 são similares com às do Modelo 1, com a diferença de que, para as PDF mais estreitas e altas, os picos no Modelo 3 são mais altos e, para as curvas mais suaves, o Modelo 3 apresenta curvas mais achatadas e extensas do que as encontradas para o Modelo 1. O detalhe que chama maior a atenção é que, enquanto no Modelo 1, a curva mais estreita representava o menor índice e a mais suave o maior índice, no Modelo 3, a mais estreita representa o maior índice e a mais suave o menor índice. Como a curva mais suave que representa o menor valor da covariável no Modelo 3 é mais extensa, essa curva consegue alcançar um grande grupo de vazões (mais altas ou baixas), diferentemente do Modelo 1, em que a curva mais suave (maior valor da covariável) alcança geralmente somente valores mais altos.

A Figura 5.14d fornece as variações de probabilidades de excedências associadas ao modelo não estacionário em função do El Niño 1+2, que alcançam probabilidades entre 0.01% quando a anomalia na TSM é de 2.55 °C (maior índice da covariável) até 6.81% quando a anomalia na TSM é de -1.27 °C (menor índice). Ou seja, diferentemente do Modelo 1 e 2, no Modelo 3 as maiores probabilidades ocorrem quando o fenômeno La Niña acontece, devido ao formato da curva do PDF para as menores anomalias serem bastantes extensas.

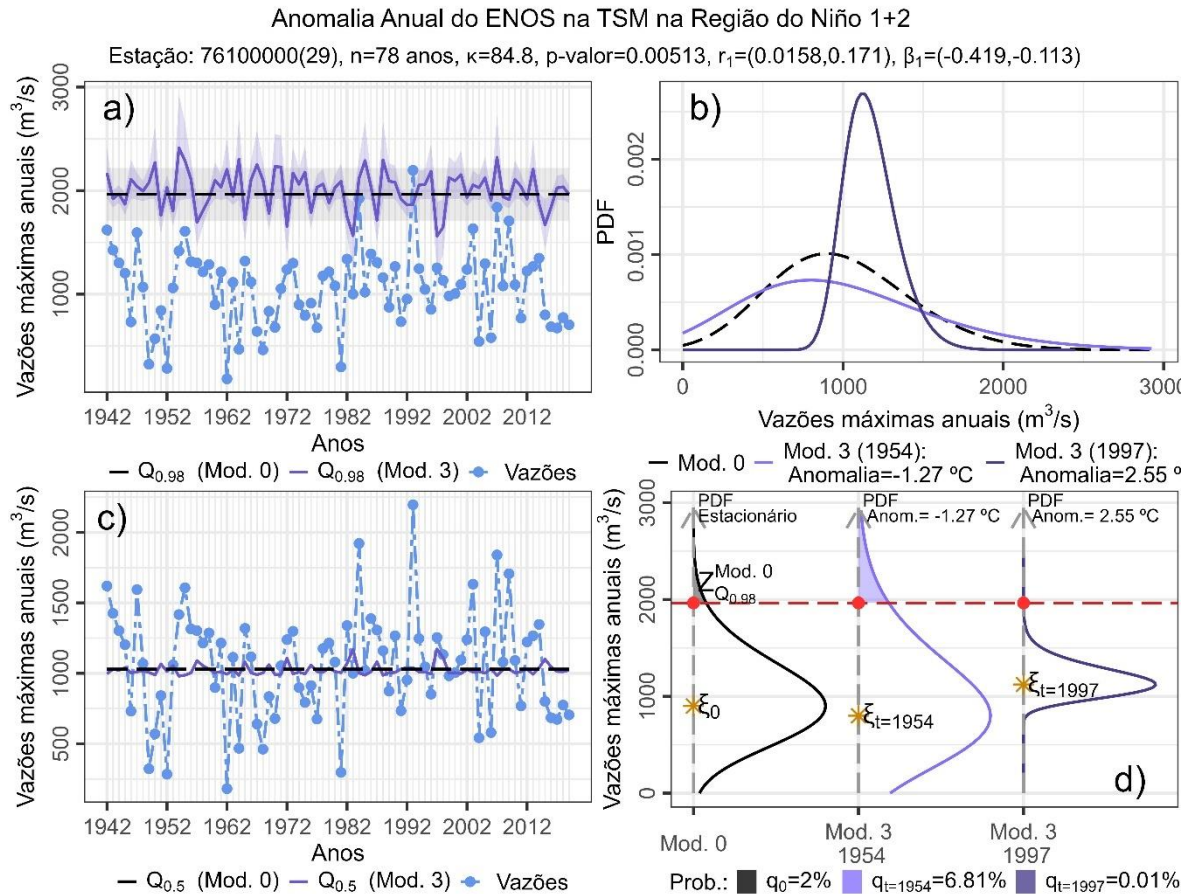


Figura 5.16 - Resultados para séries temporais da estação 29 (76100000) para a covariável El Niño 1+2. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 3 (não estacionário, em roxo-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do Modelo 3 considerando a menor anomalia (roxo-claro) e a maior anomalia (roxo-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 3 (roxo-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.

6 - CONCLUSÃO

Este trabalho apresenta uma abordagem metodológica para detectar, modelar e avaliar o comportamento não estacionário das cheias a níveis local e regional. A abordagem consiste na análise de frequência dos quantis das cheias com o emprego da distribuição GEV aplicada a quatro modelos estatísticos: um estacionário (Modelo 0) e três não estacionários (Modelos 1, 2 e 3). Nos modelos não estacionários o parâmetro de posição varia de forma linear em função das covariáveis influentes na área de interesse. A diferença entre os modelos não estacionários é o parâmetro de escala: no Modelo 1 varia de forma que o coeficiente de variação seja constante ao longo do tempo; no Modelo 2 é constante; e no Modelo 3 varia de forma exponencial em função da covariável. Se avalia pelo método Delta as incertezas associadas aos quantis das cheias e aos parâmetros dos modelos não estacionários por meio de intervalos de confiança de 95%. Na análise local, a seleção entre os quatro modelos propostos ocorre por meio de critérios de informação BIC. Para controlar a taxa do Erro Tipo I (falsos-positivos) ao nível regional, aplica-se a taxa FDR sobre as séries selecionadas por modelos não estacionários via BIC.

A Região Hidrográfica (RH) do Uruguai, localizada no Brasil, foi o exemplo de área de estudo escolhida para a aplicação dessa abordagem metodológica. Modelou-se os quantis de cheias das 33 séries de vazões máximas anuais da RH associadas aos potenciais mecanismos de mudanças nessa RH além do Tempo, com foco nos mecanismos climáticos de larga escala (ENOS na região El Niño 1+2, 3, 3.4 e 4; e ODP). Os resultados da análise ao nível local mostraram altas taxas de séries que melhor se adequaram aos modelos não estacionários, principalmente o Modelo 1 e 2, com as maiores taxas associadas às covariáveis climáticas e mais especificamente ligadas ao ENOS na região 1+2 e na região 3. Ao nível regional, as taxas de séries não estacionárias continuaram presentes, porém, em menores proporções com predominância de seleção ainda do modelo 1 e 2, mostrando uma boa resposta a variação do parâmetro de posição na RH. Para a covariável ODP em nível regional, não houve evidências fortes os suficientes para influenciar a não estacionariedade das cheias na RH. As maiores taxas de não estacionariedade continuaram ocorrendo quando as cheias foram modeladas pelo ENOS na região 1+2 e 3, regiões que mostraram influência considerável na RH quando se comparada as outras regiões do ENOS. Na modelagem dos ENOS também foram observadas grandes mudanças nas taxas dos quantis de cheias de 50 anos, que podem ser provocadas pelos fenômenos opostos de El Niño e La Niña. Para a covariável Tempo, o

Modelo 1 foi selecionado em 85% das séries modeladas por modelos não estacionários, e foram observados aumentos por década nos quantis de cheias de 50 anos. Para as covariáveis com indícios de não estacionariedade, foram observadas grandes variações nas probabilidades de excedência em relação ao quantil de referência estacionário das cheias de 50 anos ($Q_{0.98}$), com a diminuição e o aumento da probabilidade do quantil de cheia alcançar ou superar o quantil de 50 anos.

Os resultados obtidos na RH do Uruguai, exemplificando a aplicação da abordagem metodológica apresentada no presente estudo, mostram a relevância em levantar-se a não estacionariedade diante dos aumentos/diminuições de probabilidades da ocorrência de quantis de cheias, como o $Q_{0.98}$, no decorrer do tempo quando se observa tendências nas séries. Essas mudanças nas séries podem acarretar subestimações/superestimações de cheias quando se considera somente a hipótese de estacionariedade no planejamento e gerenciamento hídrico, o que pode impactar diretamente a sociedade e causar sérios problemas. A modelagem das cheias por diferentes modelos estatísticos também se mostra de grande importância, pois há a busca o modelo que melhor represente cada série de dados da área de interesse para uma análise mais fidedigna. Essa modelagem, porém, não deve ser realizada somente com seleção de modelos a nível local, mas também a nível regional como mostrado na abordagem metodológica aplicada a RH do Uruguai, para que não haja o inflacionamento do número de séries com tendências significativas, etapa crucial para uma análise com maior confiabilidade e precisão de resultados.

Para trabalhos futuros, recomenda-se: a variação da estrutura dos modelos estatísticos não estacionários - na presente abordagem apresentada empregou-se nos modelos não estacionários: uma relação linear para o parâmetro de posição para relacionar as covariáveis, e para o parâmetro de escala uma relação exponencial ou variando conforme o parâmetro de posição para se manter o coeficiente de variação constante; e a modelagem de covariáveis simultâneas nas funções de regressão dos parâmetros - na presente abordagem apresentada avaliou-se somente o efeito individual das covariáveis nas cheias.

REFERÊNCIAS BIBLIOGRÁFICAS

- AghaKouchak, A., Easterling, D., Hsu, K., Schubert, S., & Sorooshian, S. (Eds.). (2013). *Extremes in a Changing Climate* (Vol. 65). Springer Netherlands. <https://doi.org/10.1007/978-94-007-4479-0>
- Akaike, H. (1969). Fitting autoregressive models for prediction. *Annals of the Institute of Statistical Mathematics*, 21(1), 243–247. <https://doi.org/10.1007/BF02532251>
- Akaike, H. (1992). *Information Theory and an Extension of the Maximum Likelihood Principle* (pp. 610–624). Akademiai Kiado. https://doi.org/10.1007/978-1-4612-0919-5_38
- Alexandre, A., Junior, D., & Martins, E. (2008). Uso de Informação Regional na Estimativa de Quantis de Cheia GEV. *Revista Brasileira de Recursos Hídricos*, 13(2), 127–139. <https://doi.org/10.21168/rbrh.v13n2.p127-139>
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., De Moraes Gonçalves, J. L., & Sparovek, G. (2013). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, 22(6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>
- Amorim, R. S. (2018). *Detecção de Tendências em Séries de Extremos Hidrológicos Considerando Efeitos de Autocorrelação Temporal e Multiplicidade de Testes* [Dissertação de Mestrado em Tecnologia Ambiental e Recursos Hídricos, Publicação PTARH.DMXXX/ 18,]. Universidade de Brasília.
- ANA. (2015). *Conjuntura dos recursos hídricos no Brasil: regiões hidrográficas brasileiras – Edição Especial*. ANA. www.ana.gov.br
- ANA. (2016). *Mudanças Climáticas e Recursos Hídricos: avaliações e diretrizes para adaptação*. ANA.
- ANA. (2020). *Atualização da Base de Dados Nacional de Referência de Massas d'Água. Nota Técnica nº 52/2020/SPR. Documento nº: 02500.025402/2020-63*.
- Anjos, S. L. dos, Silva, C. S. B. da, & Lima, C. H. R. (2013). MODELAGEM ESTATÍSTICA NÃO ESTACIONÁRIA DE CHEIAS SAZONAIS NO SUDESTE BRASILEIRO. *XX Simpósio Brasileiro de Recursos Hídricos*.
- Anzolin, G., & Chaffe, P. L. B. (2021). Não estacionariedade de cheias no Brasil: análise de frequência com covariáveis climáticas. *XXIV Simpósio Brasileiro de Recursos Hídricos*.
- ASCE. (2018). *Climate-Resilient Infrastructure: Adaptive Design and Risk Management* (Ayyub & Bilal M., Eds.). American Society of Civil Engineers. <https://doi.org/10.1061/9780784415191>
- Bader, B., Yan, J., & Zhang, X. (2017). Automated selection of r for the r largest order statistics approach with adjustment for sequential testing. *Statistics and Computing*, 27(6), 1435–1451. <https://doi.org/10.1007/s11222-016-9697-3>
- Ball, J., Babister, M., Nathan, R., Weeks, W., Weinmann, E., Retallick, M., & Testoni, I. (2019). *Australian Rainfall and Runoff A Guide To Flood Estimation*. Commonwealth of Australia (Geoscience Australia).
- Bartiko, D., Chaffe, P. L. B., & Bonumá, N. B. (2017). Não-estacionariedade em séries de vazões máximas diárias do Sul do Brasil. *Revista Brasileira de Recursos Hidricos*, 22. <https://doi.org/10.1590/2318-0331.0217170054>
- Bartiko, D., Oliveira, D. Y., Bonumá, N. B., & Chaffe, P. L. B. (2019). Spatial and seasonal patterns of flood change across Brazil. *Hydrological Sciences Journal*, 64(9), 1071–1079. <https://doi.org/10.1080/02626667.2019.1619081>
- Bauldry, S. (2015). Structural Equation Modeling. In *International Encyclopedia of the Social & Behavioral Sciences: Second Edition* (pp. 615–620). Elsevier Inc. <https://doi.org/10.1016/B978-0-08-097086-8.44055-9>

- Beck, H. E., Zimmermann, N. E., McVicar, T. R., Vergopolan, N., Berg, A., & Wood, E. F. (2018). Present and future köppen-geiger climate classification maps at 1-km resolution. *Scientific Data*, 5. <https://doi.org/10.1038/sdata.2018.214>
- Benjamini, Y., & Hochberg, Y. (1995). Controlling the False Discovery Rate: A Practical and Powerful Approach to Multiple Testing. *Journal of the Royal Statistical Society: Series B (Methodological)*, 57(1), 289–300. <https://doi.org/10.1111/j.2517-6161.1995.tb02031.x>
- Blanchet, J., Molinié, G., & Touati, J. (2018). Spatial analysis of trend in extreme daily rainfall in southern France. *Climate Dynamics*, 51(3), 799–812. <https://doi.org/10.1007/s00382-016-3122-7>
- Blöschl, G., Bierkens, M. F. P., Chambel, A., Cudennec, C., Destouni, G., Fiori, A., Kirchner, J. W., McDonnell, J. J., Savenije, H. H. G., Sivapalan, M., Stumpff, C., Toth, E., Volpi, E., Carr, G., Lupton, C., Salinas, J., Széles, B., Viglione, A., Aksoy, H., ... Zhang, Y. (2019). Twenty-three unsolved problems in hydrology (UPH)—a community perspective. *Hydrological Sciences Journal*, 64(10), 1141–1158. <https://doi.org/10.1080/02626667.2019.1620507>
- Blöschl, G., Gaál, L., Hall, J., Kiss, A., Komma, J., Nester, T., Parajka, J., Perdigão, R. A. P., Plavcová, L., Rogger, M., Salinas, J. L., & Viglione, A. (2015). Increasing river floods: fiction or reality? *Wiley Interdisciplinary Reviews: Water*, 2(4), 329–344. <https://doi.org/10.1002/WAT2.1079>
- Blöschl, G., Hall, J., Parajka, J., Perdigão, R. A. P., Merz, B., Arheimer, B., Aronica, G. T., Bilibashi, A., Bonacci, O., Borga, M., Čanjevac, I., Castellarin, A., Chirico, G. B., Claps, P., Fiala, K., Frolova, N., Gorbachova, L., Gül, A., Hannaford, J., ... Živković, N. (2017). Changing climate shifts timing of European floods. *Science*, 357(6351), 588–590. <https://doi.org/10.1126/science.aan2506>
- Brenning, A. (2005). Spatial prediction models for landslide hazards: review, comparison and evaluation. In *Natural Hazards and Earth System Sciences* (Vol. 5).
- Burnham, K. P., & Anderson, D. (2004). *Model Selection and Multimodel Inference* (K. P. Burnham & D. R. Anderson, Eds.). Springer New York. <https://doi.org/10.1007/b97636>
- Cammalleri, C., Micale, F., & Vogt, J. (2016). Recent temporal trend in modelled soil water deficit over Europe driven by meteorological observations. *International Journal of Climatology*, 36(15), 4903–4912. <https://doi.org/10.1002/joc.4677>
- Capozzoli, C. R., de Oliveira Cardoso, A., & Ferraz, S. E. T. (2017). Padrões de variabilidade de vazão de rios nas principais bacias Brasileiras e associação com índices climáticos. *Revista Brasileira de Meteorologia*, 32(2), 243–254. <https://doi.org/10.1590/0102-77863220006>
- Chagas, V. B. P., & Chaffe, P. L. B. (2019). Não-estacionariedade é inevitável! Causas das recentes mudanças de vazão no Brasil. *XXIII Simpósio Brasileiro de Recursos Hídricos*.
- Chow, V. Te, Maidment, D. R., & Mays, L. W. (1988). *Applied hydrology*. McGraw-Hill.
- Coles, S. (2001). *An Introduction to Statistical Modeling of Extreme Values*. Springer London. <https://doi.org/10.1007/978-1-4471-3675-0>
- Collischonn, W., & Tassi, R. (2008). *Introduzindo hidrologia* (5th ed.). IPH UFRGS.
- CRED. (2023). *Disasters in numbers 2022*.
- Cunderlik, J. M., Ouarda, T. B. M. J., & Bobee, B. (2004). Determination of flood seasonality from hydrological records. *Hydrological Sciences Journal*, 49(3), 511–526. <https://doi.org/10.1623/hysj.49.3.511.54351>

- Dai, A., Qian, T., Trenberth, K. E., & Milliman, J. D. (2009). Changes in continental freshwater discharge from 1948 to 2004. *Journal of Climate*, 22(10), 2773–2792. <https://doi.org/10.1175/2008JCLI2592.1>
- de Souza, S. A., Araujo, A. A., & Troger, F. H. (2013). Análise de estacionaridade das séries hidrometeorológicas localizadas na bacia do rio São Francisco. *XX Simpósio Brasileiro de Recursos Hídricos*.
- de Souza, S. A., & Reis, D. S. (2021). Avaliação do “Degee of Regulation” (DoR) na hidrografia do Brasil. *XXIV Simpósio Brasileiro de Recursos Hídricos*.
- de Souza, S. A., & Reis, D. S. (2022). Trend Detection in Annual Streamflow Extremes in Brazil. *Water (Switzerland)*, 14(11). <https://doi.org/10.3390/w14111805>
- Dolejsi, E., Bodenstorfer, B., & Frommlet, F. (2014). Analyzing genome-wide association studies with an FDR controlling modification of the Bayesian information criterion. *PLoS ONE*, 9(7). <https://doi.org/10.1371/journal.pone.0103322>
- Douglas, E. M., Vogel, R. M., & Kroll, C. N. (2000). Trends in floods and low flows in the United States: impact of spatial correlation. *Journal of Hydrology*, 240(1–2), 90–105. [https://doi.org/10.1016/S0022-1694\(00\)00336-X](https://doi.org/10.1016/S0022-1694(00)00336-X)
- Doyle, M. E., & Barros, V. R. (2011). Attribution of the river flow growth in the Plata Basin. *International Journal of Climatology*, 31(15), 2234–2248. <https://doi.org/10.1002/joc.2228>
- Dynesius, M., & Nilsson, C. (1994). Fragmentation and flow regulation of river systems in the northern third of the world. *Science*, 266(5186), 753–762. <https://doi.org/10.1126/science.266.5186.753>
- Dziak, J. J., Coffman, D. L., Lanza, S. T., Li, R., & Jermiin, L. S. (2020). Sensitivity and specificity of information criteria. *Briefings in Bioinformatics*, 21(2), 553–565. <https://doi.org/10.1093/bib/bbz016>
- El Adlouni, S., Ouarda, T. B. M. J., Zhang, X., Roy, R., & Bobée, B. (2007). Generalized maximum likelihood estimators for the nonstationary generalized extreme value model. *Water Resources Research*, 43(3). <https://doi.org/10.1029/2005WR004545>
- England, J. F. Jr., Cohn, T. A., Faber, B. A., Stedinger, J. R., Thomas, W. O. Jr., Veilleux, A. G., Kiang, J. E., & Mason, R. R. Jr. (2018). *Guidelines for determining flood flow frequency—Bulletin 17C* (Version 1.1, Vols. 4-B5). U.S. Geological Survey Techniques and Methods. <https://doi.org/10.3133/tm4B5>
- Fabozzi, F. J., Focardi, S. M., Rachev, S. T., & Arshanapalli, B. G. (2014). *The Basics of Financial Econometrics*. John Wiley & Sons, Inc. <https://doi.org/10.1002/9781118856406>
- Frommlet, F., Chakrabarti, A., Murawska, M., & Bogdan, M. (2010). *Asymptotic Bayes optimality under sparsity for generally distributed effect sizes under the alternative*. <http://arxiv.org/abs/1005.4753>
- Grimm, A. M. (2015). El niño, novamente! In *Revista Brasileira de Meteorologia* (Vol. 30, Issue 4, pp. 351–352). Sociedade Brasileira de Meteorologia. <https://doi.org/10.1590/0102-778620152000>
- Grimm, A. M., & Tedeschi, R. G. (2009). ENSO and extreme rainfall events in South America. *Journal of Climate*, 22(7), 1589–1609. <https://doi.org/10.1175/2008JCLI2429.1>
- Hall, J., Arheimer, B., Borga, M., Brázdil, R., Claps, P., Kiss, A., Kjeldsen, T. R., Kriaučiūnienė, J., Kundzewicz, Z. W., Lang, M., Llasat, M. C., Macdonald, N., McIntyre, N., Mediero, L., Merz, B., Merz, R., Molnar, P., Montanari, A., Neuhold, C., ... Blöschl, G. (2014). Understanding flood regime changes in Europe: A state-of-the-art assessment. *Hydrology and Earth System Sciences*, 18(7), 2735–2772. <https://doi.org/10.5194/hess-18-2735-2014>

- Harrigan, S., Murphy, C., Hall, J., Wilby, R. L., & Sweeney, J. (2014). Attribution of detected changes in streamflow using multiple working hypotheses. *Hydrology and Earth System Sciences*, 18(5), 1935–1952. <https://doi.org/10.5194/hess-18-1935-2014>
- Hesarkazzazi, S., Arabzadeh, R., Hajibabaei, M., Rauch, W., Kjeldsen, T. R., Prosdocimi, I., Castellarin, A., & Sitzenfrei, R. (2021). Stationary vs non-stationary modelling of flood frequency distribution across northwest England. *Hydrological Sciences Journal*, 66(4), 729–744. <https://doi.org/10.1080/02626667.2021.1884685>
- Hodgkins, G. A., Whitfield, P. H., Burn, D. H., Hannaford, J., Renard, B., Stahl, K., Fleig, A. K., Madsen, H., Mediero, L., Korhonen, J., Murphy, C., & Wilson, D. (2017). Climate-driven variability in the occurrence of major floods across North America and Europe. *Journal of Hydrology*, 552, 704–717. <https://doi.org/10.1016/j.jhydrol.2017.07.027>
- IPCC. (2007). *Climate Change 2007: Impacts, Adaptation and Vulnerability. Contribution of Working Group II to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change* (M. L. Parry, O. F. Canziani, J. P. Palutikof, P. J. Van der Linden, & C. E. Hanson, Eds.). Cambridge University Press.
- IPCC. (2012). *Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation. A Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change* (C. B. , Field, V. Barros, T.F. Stocker, D. Qin, D.J. Dokken, K.L. Ebi, M.D. Mastrandrea, K.J. Mach, G.-K. Plattner, S.K. Allen, M. Tignor, & P.M. Midgley, Eds.). Cambridge University Press.
- IPCC. (2014). *Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* (Core Writing Team, R.K. Pachauri, & L.A. Meyer, Eds.). IPCC.
- IPCC. (2021). *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* (V. Masson-Delmotte, P. Zhai, A. Pirani, S. L. Connors, C. Péan, S. Berger, N. Caud, Y. Chen, L. Goldfarb, M. I. Gomis, M. Huang, K. Leitzell, E. Lonnoy, J. B. R. Matthews, T. K. Maycock, T. Waterfield, O. Yelekçi, R. Yu, & B. Zhou, Eds.). Cambridge University Press. <https://doi.org/10.1017/9781009157896>
- Ishak, E. H., Rahman, A., Westra, S., Sharma, A., & Kuczera, G. (2013). Evaluating the non-stationarity of australian annual maximum flood. *Journal of Hydrology*, 494, 134–145. <https://doi.org/10.1016/j.jhydrol.2013.04.021>
- Jenkinson, A. F. (1955). The frequency distribution of the annual maximum (or minimum) values of meteorological elements. *Quarterly Journal of the Royal Meteorological Society*, 81(348), 158–171. <https://doi.org/10.1002/qj.49708134804>
- Katz, R. W., Parlange, M. B., & Naveau, P. (2002). Statistics of extremes in hydrology. *Advances in Water Resources*, 25(8–12), 1287–1304. [https://doi.org/10.1016/S0309-1708\(02\)00056-8](https://doi.org/10.1016/S0309-1708(02)00056-8)
- Khaliq, M. N., Ouarda, T. B. M. J., Ondo, J. C., Gachon, P., & Bobée, B. (2006). Frequency analysis of a sequence of dependent and/or non-stationary hydro-meteorological observations: A review. *Journal of Hydrology*, 329(3–4), 534–552. <https://doi.org/10.1016/j.jhydrol.2006.03.004>
- Khouakhi, A., Villarini, G., & Vecchi, G. A. (2017). Contribution of Tropical Cyclones to Rainfall at the Global Scale. *Journal of Climate*, 30(1), 359–372. <https://doi.org/10.1175/JCLI-D-16-0298.1>
- Kiang, J. E., Olsen, J. R., & Waskom, R. M. (2011). Introduction to the featured collection on “nonstationarity, hydrologic frequency analysis, and water management.” *Journal of the American Water Resources Association*, 47(3), 433–435. <https://doi.org/10.1111/j.1752-1688.2011.00551.x>

- Kobiyama, M., Mendonça, M., Moreno, D. A., Marcelino, I. P. V. de O., Marcelino, E. V., Gonçalves, E. F., Brazetti, L. L. P., Goerl, R. F., Moller, G. S. F., & Rudorff, F. de M. (2006). *Prevenção de desastres naturais conceitos básicos*. Organic Trading.
- Koutsoyiannis, D. (2011). Hurst-Kolmogorov Dynamics and Uncertainty. *Journal of the American Water Resources Association*, 47(3), 481–495. <https://doi.org/10.1111/j.1752-1688.2011.00543.x>
- Koutsoyiannis, D., & Montanari, A. (2015). Meurtre par imprudence de concepts scientifiques: le cas de la stationnarité. *Hydrological Sciences Journal*, 60(7–8), 1174–1183. <https://doi.org/10.1080/02626667.2014.959959>
- Krepper, C. M., García, N. O., & Jones, P. D. (2003). Interannual variability in the Uruguay river basin. *International Journal of Climatology*, 23(1), 103–115. <https://doi.org/10.1002/joc.853>
- Lehner, B., Liermann, C. R., Revenga, C., Vörösmarty, C., Fekete, B., Crouzet, P., Döll, P., Endejan, M., Frenken, K., Magome, J., Nilsson, C., Robertson, J. C., Rödel, R., Sindorf, N., & Wisser, D. (2011). High-resolution mapping of the world's reservoirs and dams for sustainable river-flow management. In *Frontiers in Ecology and the Environment* (Vol. 9, Issue 9, pp. 494–502). <https://doi.org/10.1890/100125>
- Lima, C. H. R., Lall, U., Troy, T. J., & Devineni, N. (2015). A climate informed model for nonstationary flood risk prediction: Application to Negro River at Manaus, Amazonia. *Journal of Hydrology*, 522, 594–602. <https://doi.org/10.1016/j.jhydrol.2015.01.009>
- Liu, C., Chai, Y., Zhu, B., Yang, Y., Deng, J., & Hu, Y. (2021). River regulation and resilience: An approach for the Yangtze watershed. *Water Science and Technology: Water Supply*, 21(4), 1817–1833. <https://doi.org/10.2166/WS.2021.035>
- Lorah, J., & Womack, A. (2019). Value of sample size for computation of the Bayesian information criterion (BIC) in multilevel modeling. *Behavior Research Methods*, 51(1), 440–450. <https://doi.org/10.3758/s13428-018-1188-3>
- Luke, A., Vrugt, J. A., AghaKouchak, A., Matthew, R., & Sanders, B. F. (2017). Predicting nonstationary flood frequencies: Evidence supports an updated stationarity thesis in the United States. *Water Resources Research*, 53(7), 5469–5494. <https://doi.org/10.1002/2016WR019676>
- Mailhot, A., Talbot, G., Ricard, S., Turcotte, R., & Guinard, K. (2018). Assessing the potential impacts of dam operation on daily flow at ungauged river reaches. *Journal of Hydrology: Regional Studies*, 18, 156–167. <https://doi.org/10.1016/j.ejrh.2018.06.006>
- Mallows, C. L. (1973). Some Comments on C P. *Technometrics*, 15(4), 661. <https://doi.org/10.2307/1267380>
- Mallya, G., Mishra, V., Niyogi, D., Tripathi, S., & Govindaraju, R. S. (2015). Trends and variability of droughts over the Indian monsoon region. *Weather and Climate Extremes*, 12, 43–68. <https://doi.org/10.1016/j.wace.2016.01.002>
- Marcuzzo, F. F. N., Almeida, D. B., & Souza, C. J. R. (2016). *BACIA HIDROGRÁFICA INTERNACIONAL DO RIO URUGUAI E CONSISTÊNCIA DOS SEUS DIVISORES DE ÁGUA NA ESCALA 1:3.000*. <https://onedrive.live.com/redir?resid=E3D6F8F0983B5001!8074&authkey=!AK8TkZeGIWzKZYA&ithint=file%2cpdf>
- Marengo, J., Schaeffer, R., Zee, D., & Pinto, H. S. (2009). *Mudanças Climáticas e Eventos Extremos no Brasil*. FBDS.
- Martins, E. S., & Stedinger, J. R. (2000). Generalized maximum-likelihood generalized extreme-value quantile estimators for hydrologic data. *Water Resources Research*, 36(3), 737–744. <https://doi.org/10.1029/1999WR900330>

- Mattiuzi, C. D. P. (2023). *Relatório de operação do Sistema de Alerta Hidrológico da bacia do Rio Uruguai 2023* (C. D. P. Mattiuzi & A. J. S. Matos, Eds.). Serviço Geológico do Brasil - CPRM. www.cprm.gov.br
- MCID, & IPT. (2007). *Mapeamento de riscos em encostas e margens de rios* (C. S. Carvalho, E. S. Macedo, & A. T. Ogura, Eds.). Ministério das Cidades; Instituto de Pesquisas Tecnológicas.
- McPhillips, L. E., Chang, H., Chester, M. V., Depietri, Y., Friedman, E., Grimm, N. B., Kominoski, J. S., McPhearson, T., Méndez-Lázaro, P., Rosi, E. J., & Shafiei Shiva, J. (2018). Defining Extreme Events: A Cross-Disciplinary Review. *Earth's Future*, 6(3), 441–455. <https://doi.org/10.1002/2017EF000686>
- Mediero, L., Santillán, D., Garrote, L., & Granados, A. (2014). Detection and attribution of trends in magnitude, frequency and timing of floods in Spain. *Journal of Hydrology*, 517, 1072–1088. <https://doi.org/10.1016/j.jhydrol.2014.06.040>
- Merz, B., Vorogushyn, S., Uhlemann, S., Delgado, J., & Hündecha, Y. (2012). HESS Opinions: “More efforts and scientific rigour are needed to attribute trends in flood time series.” *Hydrology and Earth System Sciences*, 16(5), 1379–1387. <https://doi.org/10.5194/hess-16-1379-2012>
- Milly, P. C. D., Betancourt, J., Falkenmark, M., Hirsch, R. M., Kundzewicz, Z. W., Lettenmaier, D. P., & Stouffer, R. J. (2008). Climate change: Stationarity is dead: Whither water management? In *Science* (Vol. 319, Issue 5863, pp. 573–574). <https://doi.org/10.1126/science.1151915>
- Molion, L. C. B. (2008). PERSPECTIVAS CLIMÁTICAS PARA OS PRÓXIMOS 20 ANOS. *Revista Brasileira de Climatologia*, 3. <https://doi.org/10.5380/abclima.v3i0.25438>
- Mondal, A., & Daniel, D. (2019). Return Levels under Nonstationarity: The Need to Update Infrastructure Design Strategies. *Journal of Hydrologic Engineering*, 24(1). [https://doi.org/10.1061/\(asce\)he.1943-5584.0001738](https://doi.org/10.1061/(asce)he.1943-5584.0001738)
- Montanari, A., & Koutsoyiannis, D. (2014). Modeling and mitigating natural hazards: Stationarity is immortal! In *Water Resources Research* (Vol. 50, Issue 12, pp. 9748–9756). Blackwell Publishing Ltd. <https://doi.org/10.1002/2014WR016092>
- Montgomery, J. M., & Nyhan, B. (2010). Bayesian Model Averaging: Theoretical Developments and Practical Applications. *Political Analysis*, 18(2), 245–270. <https://doi.org/10.1093/pan/mpq001>
- Naghattini, M., & Pinto, É. J. de A. (2007). *Hidrologia estatística*. CPRM.
- Newman, M., Alexander, M. A., Ault, T. R., Cobb, K. M., Deser, C., Di Lorenzo, E., Mantua, N. J., Miller, A. J., Minobe, S., Nakamura, H., Schneider, N., Vimont, D. J., Phillips, A. S., Scott, J. D., & Smith, C. A. (2016). The Pacific decadal oscillation, revisited. *Journal of Climate*, 29(12), 4399–4427. <https://doi.org/10.1175/JCLI-D-15-0508.1>
- Nilsson, C., Reidy, C. A., Dynesius, M., & Revenga, C. (2005). Fragmentation and flow regulation of the world's large river systems. In *Science* (Vol. 308, Issue 5720, pp. 405–408). <https://doi.org/10.1126/science.1107887>
- Obeyssekera, J., & Salas, J. D. (2014). Quantifying the Uncertainty of Design Floods under Nonstationary Conditions. *Journal of Hydrologic Engineering*, 19(7), 1438–1446. [https://doi.org/10.1061/\(asce\)he.1943-5584.0000931](https://doi.org/10.1061/(asce)he.1943-5584.0000931)
- OCHA. (2020). *Natural Disasters in Latin America and the Caribbean 2000-2019*.
- Ouarda, T. B. M. J., & Charron, C. (2019). Changes in the distribution of hydro-climatic extremes in a non-stationary framework. *Scientific Reports*, 9(1). <https://doi.org/10.1038/s41598-019-44603-7>

- Peel, M. C., Finlayson, B. L., & McMahon, T. A. (2007). Hydrology and Earth System Sciences Updated world map of the Köppen-Geiger climate classification. In *Hydrol. Earth Syst. Sci* (Vol. 11). www.hydrol-earth-syst-sci.net/11/1633/2007/
- Peñas, F. J., Barquín, J., & Álvarez, C. (2016). Assessing hydrologic alteration: Evaluation of different alternatives according to data availability. *Ecological Indicators*, *60*, 470–482. <https://doi.org/10.1016/j.ecolind.2015.07.021>
- Petrow, T., & Merz, B. (2009). Trends in flood magnitude, frequency and seasonality in Germany in the period 1951–2002. *Journal of Hydrology*, *371*(1–4), 129–141. <https://doi.org/10.1016/j.jhydrol.2009.03.024>
- Prosdocimi, I., & Kjeldsen, T. (2021). Parametrisation of change-permitting extreme value models and its impact on the description of change. *Stochastic Environmental Research and Risk Assessment*, *35*(2), 307–324. <https://doi.org/10.1007/s00477-020-01940-8>
- Prosdocimi, I., Kjeldsen, T. R., & Svensson, C. (2014). Non-stationarity in annual and seasonal series of peak flow and precipitation in the UK. *Natural Hazards and Earth System Sciences*, *14*(5), 1125–1144. <https://doi.org/10.5194/nhess-14-1125-2014>
- Raftery, A. E. (1995). Bayesian Model Selection in Social Research. *Sociological Methodology*, *25*, 111–163. <https://doi.org/10.2307/271063>
- Read, L. K., & Vogel, R. M. (2015). Reliability, return periods, and risk under nonstationarity. *Water Resources Research*, *51*(8), 6381–6398. <https://doi.org/10.1002/2015WR017089>
- Rebello, E. R. G. (2006). A OSCILAÇÃO DECADAL DO PACÍFICO E SUA POSSÍVEL INFLUÊNCIA NO REGIME DE PRECIPITAÇÃO DO RIO GRANDE DO SUL. *XIII Congresso Brasileiro de Meteorologia (CBMET)*. <https://doi.org/10.13140/RG.2.1.2745.6724>
- Renard, B., Lang, M., Bois, P., Dupeyrat, A., Mestre, O., Niel, H., Sauquet, E., Prudhomme, C., Parey, S., Paquet, E., Neppel, L., & Gailhard, J. (2008). Regional methods for trend detection: Assessing field significance and regional consistency. *Water Resources Research*, *44*(8). <https://doi.org/10.1029/2007WR006268>
- Salas, J. D., & Obeysekera, J. (2014). Revisiting the Concepts of Return Period and Risk for Nonstationary Hydrologic Extreme Events. *Journal of Hydrologic Engineering*, *19*(3), 554–568. [https://doi.org/10.1061/\(asce\)he.1943-5584.0000820](https://doi.org/10.1061/(asce)he.1943-5584.0000820)
- Salas, J. D., Obeysekera, J., & Vogel, R. M. (2018). Techniques for assessing water infrastructure for nonstationary extreme events: a review. *Hydrological Sciences Journal*, *63*(3), 325–352. <https://doi.org/10.1080/02626667.2018.1426858>
- Schneider, N., & Cornuelle, B. D. (2005). *The Forcing of the Pacific Decadal Oscillation**. <http://www.cgd.ucar.edu/cdeser/Data/>
- Schwarz, G. (1978). Estimating the Dimension of a Model. *The Annals of Statistics*, *6*(2), 461–464.
- Serago, J. M., & Vogel, R. M. (2018). Parsimonious nonstationary flood frequency analysis. *Advances in Water Resources*, *112*, 1–16. <https://doi.org/10.1016/j.advwatres.2017.11.026>
- Serinaldi, F., & Kilsby, C. G. (2015). Stationarity is undead: Uncertainty dominates the distribution of extremes. *Advances in Water Resources*, *77*, 17–36. <https://doi.org/10.1016/j.advwatres.2014.12.013>
- Shaffer, J. P. (1995). Multiple Hypothesis Testing. *Annual Review of Psychology*, *46*(1), 561–584. <https://doi.org/10.1146/annurev.ps.46.020195.003021>
- Shen, N., & González, B. (2021). *Bayesian Information Criterion for Linear Mixed-effects Models*. <https://doi.org/https://doi.org/10.48550/arXiv.2104.14725>

- Sheng, J., Han, X., & Zhou, H. (2017). Spatially varying patterns of afforestation/reforestation and socio-economic factors in China: a geographically weighted regression approach. *Journal of Cleaner Production*, 153, 362–371. <https://doi.org/10.1016/j.jclepro.2016.06.055>
- Silva, A. T., Portela, M. M., & Naghettini, M. (2012). Nonstationarities in the occurrence rates of flood events in Portuguese watersheds. *Hydrology and Earth System Sciences*, 16(1), 241–254. <https://doi.org/10.5194/hess-16-241-2012>
- Silva, C. S. B. da, Anjos, S. L. dos, & Lima, C. H. R. (2011). ANÁLISE E MODELAGEM ESTATÍSTICA NÃO-ESTACIONÁRIA DE CHEIAS SAZONAIS. *XIX Simpósio Brasileiro de Recursos Hídricos*.
- Slater, L. J., Singer, M. B., & Kirchner, J. W. (2015). Hydrologic versus geomorphic drivers of trends in flood hazard. *Geophysical Research Letters*, 42(2), 370–376. <https://doi.org/10.1002/2014GL062482>
- Slater, L., & Villarini, G. (2017). Evaluating the drivers of seasonal streamflow in the U.S. Midwest. *Water (Switzerland)*, 9(9). <https://doi.org/10.3390/w9090695>
- Slater, L., Villarini, G., Archfield, S., Faulkner, D., Lamb, R., Khouakhi, A., & Yin, J. (2021). Global Changes in 20-Year, 50-Year, and 100-Year River Floods. *Geophysical Research Letters*, 48(6). <https://doi.org/10.1029/2020GL091824>
- Souza, S. A. de, Amorim, R. S., & Reis, D. S. (2020). INFLUÊNCIA DA CORRELAÇÃO TEMPORAL E DA MULTIPLICIDADE DE TESTES NA DETECÇÃO DE TENDÊNCIAS DE ÍNDICES DE CHUVA NO TERRITÓRIO BRASILEIRO. *Revista Brasileira de Climatologia*, 26. <https://doi.org/10.5380/abclima.v26i0.68124>
- Šraj, M., Viglione, A., Parajka, J., & Blöschl, G. (2016). The influence of non-stationarity in extreme hydrological events on flood frequency estimation. *Journal of Hydrology and Hydromechanics*, 64(4), 426–437. <https://doi.org/10.1515/johh-2016-0032>
- Stedinger, J. R. (1980). Fitting Log Normal Distributions to Hydrologic Data. In *WATER RESOURCES RESEARCH* (Vol. 16, Issue 3).
- Stephenson, D. B. (2008). Definition, diagnosis, and origin of extreme weather and climate events. In *Climate Extremes and Society* (pp. 11–23). Cambridge University Press. <https://doi.org/10.1017/CBO9780511535840.004>
- Sun, X., Renard, B., Thyer, M., Westra, S., & Lang, M. (2015). A global analysis of the asymmetric effect of ENSO on extreme precipitation. *Journal of Hydrology*, 530, 51–65. <https://doi.org/10.1016/j.jhydrol.2015.09.016>
- Svensson, C., Hannaford, J., Kundzewicz, Z. W., & Marsh, T. J. (2006). Trends in river floods: why is there no clear signal in observations? In *Frontiers in Flood Research* (Vol. 305, pp. 1–18). IAHS Publication.
- Teegavarapu, R. S. V., Salas, J. D., & Stedinger, J. R. (2019). Statistical Analysis of Hydrologic Variables: Methods and Applications. In *Statistical Analysis of Hydrologic Variables: Methods and Applications*. American Society of Civil Engineers (ASCE). <https://doi.org/10.1061/9780784415177>
- Tominaga, L. K., Santoro, J., & Amaral, R. (2009). *Desastres Naturais: Conhecer para prevenir* (1st ed.). Instituto Geológico.
- Tramblay, Y., El Adlouni, S., & Servat, E. (2013). Trends and variability in extreme precipitation indices over maghreb countries. *Natural Hazards and Earth System Sciences*, 13(12), 3235–3248. <https://doi.org/10.5194/nhess-13-3235-2013>
- Tramblay, Y., & Hertig, E. (2018). Modelling extreme dry spells in the Mediterranean region in connection with atmospheric circulation. *Atmospheric Research*, 202, 40–48. <https://doi.org/10.1016/j.atmosres.2017.11.015>
- Tucci, C. E. M. (2001). *Hidrologia: Ciência e Aplicação* (Universidade/UFRGS, Ed.; 2nd ed.). ABRH.

- Ventura, V., Paciorek, C. J., & Risbey, J. S. (2004). Controlling the Proportion of Falsely Rejected Hypotheses when Conducting Multiple Tests with Climatological Data. *Journal of Climate*, *17*(22), 4343–4356. <https://doi.org/10.1175/3199.1>
- Vogel, R. M., Yaindl, C., & Walter, M. (2011). Nonstationarity: Flood magnification and recurrence reduction factors in the united states. *Journal of the American Water Resources Association*, *47*(3), 464–474. <https://doi.org/10.1111/j.1752-1688.2011.00541.x>
- Vörösmarty, C. J., Sharma, K. P., Fekete, B. M., Copeland, A. H., Holden, J., Marble, J., & Lough, J. A. (1997). The Storage and Aging of Continental Runoff in Large Reservoir Systems of the World. In *Source* (Vol. 26, Issue 4).
- Vrieze, S. I. (2012). Model selection and psychological theory: A discussion of the differences between the Akaike information criterion (AIC) and the Bayesian information criterion (BIC). *Psychological Methods*, *17*(2), 228–243. <https://doi.org/10.1037/a0027127>
- Wallemacq, P., House, R., UNISDR, & CRED. (2018). *Economic Losses, Poverty and Disasters 1998-2017*. www.unisdr.org
- WHO, & WMO. (2012). *Atlas of health and climate*. World Health Organization.
- Wilks, D. S. (2005). *Statistical Methods in the Atmospheric Sciences Second Edition* (2nd ed., Vol. 100). Academic Press.
- Wilks, D. S. (2006). On “Field Significance” and the False Discovery Rate. *Journal of Applied Meteorology and Climatology*, *45*(9), 1181–1189. <https://doi.org/10.1175/JAM2404.1>
- Wit, E., van den Heuvel, E., & Romeijn, J. W. (2012). ‘All models are wrong.’: An introduction to model uncertainty. *Statistica Neerlandica*, *66*(3), 217–236. <https://doi.org/10.1111/j.1467-9574.2012.00530.x>
- WMO. (2023). *State of the Global Climate 2022* (Vol. 1316). World Meteorological Organization.
- Xi, R., Hadjipanayis, A. G., Luquette, L. J., Kim, T.-M., Lee, E., Zhang, J., Johnson, M. D., Muzny, D. M., Wheeler, D. A., Gibbs, R. A., Kucherlapati, R., & Park, P. J. (2011). Copy number variation detection in whole-genome sequencing data using the Bayesian information criterion. *Proceedings of the National Academy of Sciences*, *108*(46). <https://doi.org/10.1073/pnas.1110574108>
- Yang, X., Lu, X., Ran, L., & Tarolli, P. (2019). Geomorphometric assessment of the impacts of dam construction on river disconnectivity and flow regulation in the Yangtze basin. *Sustainability (Switzerland)*, *11*(12). <https://doi.org/10.3390/SU11123427>
- Yang, Y. (2005). Can the strengths of AIC and BIC be shared? A conflict between model identification and regression estimation. *Biometrika*, *92*(4), 937–950. <https://doi.org/10.1093/biomet/92.4.937>

APÊNDICES

APÊNDICE A - ESTAÇÕES FLUVIOMÉTRICAS ANALISADAS NA REGIÃO HIDROGRÁFICA DO URUGUAI

Tabela 0.1 - Estações fluviométricas analisadas na Região Hidrográfica do Uruguai

Nº	Estação	Nome	Rio	Município	Altitude (m)	Área dren. (km ²)	Latitude (°)	Longitude (°)
1	70200000	Invernada Velha	Pelotas	Bom Jesus	2820	763.92	-28.4394	-50.3019
2	71200000	Vila Canoas	Canoas	Bocaina do Sul	1010	837.46	-27.8028	-49.7786
3	71250000	Ponte do Rio João Paulo	João Paulo	Bom Retiro	489	900	-27.8297	-49.6269
4	71300000	Rio Bonito	Canoas	Bocaina do Sul	2000	839.56	-27.7022	-49.84
5	71383000	Ponte Alta do Sul	Canoas	Ponte Alta	4610	814.66	-27.4858	-50.3917
6	71550000	Passo Caru	Canoas	São José do Cerrito	10000	720	-27.5381	-50.86
7	72430000	Passo do Granzotto	Forquilha	Sananduva	1620	600	-27.8786	-51.7547
8	72630000	Passo Santa Tereza	Apue	Paim Filho	2800	400	-27.7067	-51.8853
9	72680000	Passo Colombelli	Apue	Marcelino Ramos	3660	400	-27.5619	-51.8578
10	72810000	Tangará	Do Peixe	Tangará	2010	627.4	-27.0881	-51.2581
11	73765000	Passo Quilombo	Do Ouro	Quilombo	266	400	-26.76	-52.7503
12	73780000	Jardinópolis	Três Voltas	Sul Brasil	642	360	-26.7369	-52.9017
13	73900000	Saudades	Saudades	Saudades	418	263.36	-26.9244	-53.0089
14	74205000	Linha Cescon	Arroio Caturete	Sarandi	437	350	-27.8131	-53.0294
15	74270000	Passo Rio da Várzea	Da Várzea	Frederico Westphalen	5340	240	-27.2786	-53.3203
16	74370000	Palmitinho	Guarita	Tenente Portela	2020	240	-27.3328	-53.6444

Nº	Estação	Nome	Rio	Município	Altitude (m)	Área dren. (km ²)	Latitude (°)	Longitude (°)
17	74460000	Ponte do Rio Turvo	Turvo	Santo Augusto	502	400	-27.8247	-53.7303
18	74700000	Tucunduva	Santa Rosa	Tucunduva	1140	120	-27.6728	-54.4644
19	74880000	Passo São João	Comandaí	Cerro Largo	817	700	-28.0631	-54.7558
20	74900000	Linha União	Comandaí	São Paulo das Missões	1260	125	-27.9308	-54.9392
21	75155000	Passo Faxinal	Ijuí	Ajuricaba	1940	200	-28.2869	-53.7808
22	75200000	Conceição	Conceição	Ijuí	811	160	-28.4544	-53.9731
23	75205000	Ponte Nova do Conceição	Conceição	Coronel Barros	970	160	-28.3847	-54.0314
24	75230000	Santo Angelo	Ijuí	Entre-Ijuis	5440	189	-28.3553	-54.2675
25	75295000	Colônia Mousquer	Ijuizinho	Entre-Ijuis	2160	200	-28.3897	-54.3308
26	75400000	Passo do Dias	Piratini	São Miguel das Missões	932	200	-28.6569	-54.4589
27	75450000	Passo Santa Maria	Piratini	Bossoroca	3240	120	-28.5783	-54.9144
28	75500000	Passo do Sarmiento	Piratini	Santo Antônio das Missões	5230	80	-28.2119	-55.3197
29	76100000	Vila Clara	Toropi	São Pedro do Sul	2790	80	-29.5561	-54.3422
30	76440000	Jaguari	Jaguari	Jaguari	2320	100	-29.4989	-54.6892
31	76460000	Ernesto Alves	Jaquarizinho	Santiago	926	300	-29.3625	-54.7353
32	76650000	Passo da Cachoeira	Itu	Manoel Viana	2560	60	-29.3086	-55.7069
33	76750000	Alegrete	Ibirapuitã	Alegrete	5867.84	66.25	-29.7683	-55.7875

APÊNDICE B - VALORES DO CRITÉRIO DE INFORMAÇÃO BAYESIANO (BIC) PARA CADA SÉRIE DAS ESTAÇÕES DA REGIÃO HIDROGRÁFICA DO URUGUAI CONSIDERANDO CADA MODELO ESTATÍSTICO E CADA COVARIÁVEL ANALISADA.

Tabela 0.2 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável Tempo

Nº	Estação	Tempo			
		Modelo			
		0	1	2	3
1	70200000	723.34	716.19	719.21	720.26
2	71200000	684.04	677.58	679.42	681.57
3	71250000	569.46	572.84	572.20	575.54
4	71300000	837.05	832.44	832.74	836.56
5	71383000	756.12	758.83	758.46	762.49
6	71550000	992.82	992.03	993.63	996.44
7	72430000	783.39	785.45	786.18	789.53
8	72630000	865.27	864.46	863.72	867.65
9	72680000	1204.16	1197.64	1198.64	1201.48
10	72810000	594.52	598.03	597.80	601.47
11	73765000	551.66	555.26	554.72	556.30
12	73780000	535.02	536.88	533.55	536.22
13	73900000	823.02	825.02	825.46	829.22
14	74205000	689.15	693.19	693.02	696.82
15	74270000	1286.47	1282.98	1285.95	1287.27
16	74370000	748.26	748.13	749.54	752.02
17	74460000	407.89	411.39	411.08	414.63
18	74700000	894.06	874.97	872.33	875.45
19	74880000	812.38	810.55	812.21	814.50
20	74900000	618.21	621.07	620.52	623.88
21	75155000	1057.47	1054.95	1058.90	1057.28
22	75200000	934.69	938.68	937.70	941.62

Tempo					
Nº	Estação	Modelo			
		0	1	2	3
23	75205000	481.56	485.31	485.29	488.70
24	75230000	1209.25	1207.76	1210.49	1212.08
25	75295000	626.95	630.72	630.70	634.15
26	75400000	1099.82	1104.01	1104.12	1107.87
27	75450000	908.27	912.13	910.95	913.83
28	75500000	1124.09	1126.90	1126.91	1131.14
29	76100000	1184.81	1189.16	1188.64	1191.20
30	76440000	1113.97	1118.27	1117.95	1121.70
31	76460000	917.36	920.48	921.45	922.20
32	76650000	923.06	927.08	927.01	929.12
33	76750000	1059.98	1064.26	1064.14	1067.81

Tabela 0.3 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável El Niño 1+2

El Niño Oscilação Sul (ENOS) na região El Niño 1+2					
Nº	Estação	Modelo			
		0	1	2	3
1	70200000	723.34	725.43	725.65	729.27
2	71200000	684.04	683.03	683.59	687.11
3	71250000	569.46	571.41	571.23	575.23
4	71300000	837.05	839.73	839.91	844.03
5	71383000	756.12	754.67	753.85	757.87
6	71550000	992.82	989.35	989.55	992.61
7	72430000	783.39	777.42	774.59	778.25
8	72630000	865.27	860.79	856.98	860.34
9	72680000	1204.16	1201.22	1197.06	1198.20
10	72810000	594.52	596.58	595.14	595.94
11	73765000	551.66	554.53	553.05	556.33
12	73780000	535.02	535.99	532.70	533.41

El Niño Oscilação Sul (ENOS) na região El Niño 1+2					
Nº	Estação	Modelo			
		0	1	2	3
13	73900000	823.02	823.62	822.52	826.69
14	74205000	689.15	689.32	685.09	684.78
15	74270000	1286.47	1282.38	1282.29	1286.11
16	74370000	748.26	744.53	744.64	748.28
17	74460000	407.89	408.96	406.48	408.16
18	74700000	894.06	895.70	896.19	900.07
19	74880000	812.38	813.29	813.04	817.30
20	74900000	618.21	615.57	614.09	617.12
21	75155000	1057.47	1059.03	1061.19	1062.18
22	75200000	934.69	935.00	930.66	933.87
23	75205000	481.56	481.20	479.98	483.49
24	75230000	1209.25	1206.53	1208.97	1210.90
25	75295000	626.95	624.47	621.86	624.81
26	75400000	1099.82	1097.44	1093.13	1097.46
27	75450000	908.27	905.22	904.73	908.48
28	75500000	1124.09	1122.27	1122.57	1126.30
29	76100000	1184.81	1188.93	1186.03	1182.98
30	76440000	1113.97	1114.50	1109.98	1110.86
31	76460000	917.36	905.74	909.67	910.53
32	76650000	923.06	914.19	914.07	918.23
33	76750000	1059.98	1059.60	1057.65	1061.21

Tabela 0.4 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável El Niño 3

El Niño Oscilação Sul (ENOS) na região El Niño 3					
Nº	Estação	Modelo			
		0	1	2	3
1	70200000	723.34	720.35	722.80	724.38
2	71200000	684.04	674.85	677.48	678.79

El Niño Oscilação Sul (ENOS) na região El Niño 3					
Nº	Estação	Modelo			
		0	1	2	3
3	71250000	569.46	569.39	570.18	573.30
4	71300000	837.05	837.02	838.54	840.95
5	71383000	756.12	751.57	750.44	754.46
6	71550000	992.82	985.29	985.72	987.99
7	72430000	783.39	772.55	774.17	776.68
8	72630000	865.27	855.94	851.59	855.65
9	72680000	1204.16	1198.39	1197.36	1201.70
10	72810000	594.52	596.21	595.66	599.33
11	73765000	551.66	554.15	551.53	555.12
12	73780000	535.02	535.47	532.91	535.92
13	73900000	823.02	823.00	821.01	825.15
14	74205000	689.15	687.21	683.57	687.14
15	74270000	1286.47	1280.04	1282.60	1284.22
16	74370000	748.26	739.24	742.84	743.64
17	74460000	407.89	403.95	401.46	404.58
18	74700000	894.06	893.52	893.75	897.84
19	74880000	812.38	812.68	812.83	817.00
20	74900000	618.21	612.73	610.69	613.52
21	75155000	1057.47	1056.51	1060.25	1058.97
22	75200000	934.69	935.15	931.65	935.03
23	75205000	481.56	480.48	478.66	481.64
24	75230000	1209.25	1205.23	1207.46	1209.31
25	75295000	626.95	627.18	624.67	626.68
26	75400000	1099.82	1100.63	1098.45	1102.74
27	75450000	908.27	908.59	907.34	911.44
28	75500000	1124.09	1124.46	1123.84	1128.14
29	76100000	1184.81	1188.87	1186.79	1187.76
30	76440000	1113.97	1114.88	1109.58	1108.79
31	76460000	917.36	911.43	914.18	915.63
32	76650000	923.06	919.33	920.09	923.60

El Niño Oscilação Sul (ENOS) na região El Niño 3					
Nº	Estação	Modelo			
		0	1	2	3
33	76750000	1059.98	1053.18	1048.83	1051.76

Tabela 0.5 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável El Niño 3.4

El Niño Oscilação Sul (ENOS) na região El Niño 3.4					
Nº	Estação	Modelo			
		0	1	2	3
1	70200000	723.34	721.92	722.33	725.55
2	71200000	684.04	677.63	678.07	681.42
3	71250000	569.46	571.54	571.53	575.44
4	71300000	837.05	837.86	839.24	841.65
5	71383000	756.12	756.40	755.54	759.54
6	71550000	992.82	992.57	991.67	995.57
7	72430000	783.39	778.31	779.57	782.30
8	72630000	865.27	861.32	858.15	862.21
9	72680000	1204.16	1202.36	1202.02	1206.30
10	72810000	594.52	597.71	597.46	601.12
11	73765000	551.66	555.39	554.23	556.93
12	73780000	535.02	537.75	536.98	540.43
13	73900000	823.02	825.50	824.59	828.76
14	74205000	689.15	690.19	689.17	693.21
15	74270000	1286.47	1284.62	1287.21	1288.53
16	74370000	748.26	745.56	747.38	749.60
17	74460000	407.89	402.71	400.90	404.04
18	74700000	894.06	895.84	897.27	898.16
19	74880000	812.38	814.33	814.82	818.46
20	74900000	618.21	615.32	614.49	617.86
21	75155000	1057.47	1058.35	1060.88	1060.31
22	75200000	934.69	937.02	936.43	940.72

El Niño Oscilação Sul (ENOS) na região El Niño 3.4					
Nº	Estação	Modelo			
		0	1	2	3
23	75205000	481.56	480.02	478.57	481.64
24	75230000	1209.25	1208.15	1210.48	1210.83
25	75295000	626.95	627.10	626.49	630.23
26	75400000	1099.82	1101.71	1103.04	1105.66
27	75450000	908.27	910.38	910.59	914.44
28	75500000	1124.09	1126.61	1127.72	1129.90
29	76100000	1184.81	1188.77	1188.08	1191.79
30	76440000	1113.97	1114.55	1112.30	1115.20
31	76460000	917.36	912.61	918.20	914.12
32	76650000	923.06	919.67	921.55	923.98
33	76750000	1059.98	1043.81	1038.11	1041.89

Tabela 0.6 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável El Niño 4

El Niño Oscilação Sul (ENOS) na região El Niño 4					
Nº	Estação	Modelo			
		0	1	2	3
1	70200000	723.34	725.14	724.46	728.27
2	71200000	684.04	683.03	682.81	686.76
3	71250000	569.46	573.47	573.11	576.03
4	71300000	837.05	839.88	840.24	844.14
5	71383000	756.12	759.87	759.57	763.44
6	71550000	992.82	996.54	995.88	999.81
7	72430000	783.39	784.51	785.14	788.61
8	72630000	865.27	865.98	865.01	869.06
9	72680000	1204.16	1206.21	1206.31	1210.53
10	72810000	594.52	598.19	598.20	601.71
11	73765000	551.66	554.65	555.38	556.44
12	73780000	535.02	538.62	538.37	541.77

El Niño Oscilação Sul (ENOS) na região El Niño 4					
Nº	Estação	Modelo			
		0	1	2	3
13	73900000	823.02	826.23	826.03	830.18
14	74205000	689.15	692.61	692.62	696.61
15	74270000	1286.47	1289.12	1290.25	1293.01
16	74370000	748.26	749.14	749.98	753.09
17	74460000	407.89	406.12	406.05	409.69
18	74700000	894.06	897.04	898.18	898.55
19	74880000	812.38	815.81	816.28	819.46
20	74900000	618.21	617.96	618.19	621.89
21	75155000	1057.47	1059.82	1061.20	1063.14
22	75200000	934.69	938.56	938.18	942.37
23	75205000	481.56	481.89	481.58	485.34
24	75230000	1209.25	1210.92	1212.05	1215.02
25	75295000	626.95	628.40	628.78	632.18
26	75400000	1099.82	1102.71	1103.96	1106.12
27	75450000	908.27	911.60	911.63	915.68
28	75500000	1124.09	1127.83	1128.38	1130.49
29	76100000	1184.81	1188.98	1188.77	1193.01
30	76440000	1113.97	1114.91	1114.32	1118.62
31	76460000	917.36	913.14	919.83	912.65
32	76650000	923.06	921.22	923.87	925.29
33	76750000	1059.98	1046.57	1042.58	1046.86

Tabela 0.7 - Valores obtidos pelo BIC para as séries de vazões máximas anuais analisadas na RH do Uruguai aplicados aos modelos estatísticos (Modelo 0, 1, 2 e 3) considerando a covariável ODP

Oscilação Decenal do Pacífico (ODP)					
Nº	Estação	Modelo			
		0	1	2	3
1	70200000	723.34	725.72	725.14	728.94
2	71200000	684.04	684.58	686.25	687.28

Oscilação Decenal do Pacífico (ODP)					
Nº	Estação	Modelo			
		0	1	2	3
3	71250000	569.46	572.77	571.62	574.11
4	71300000	837.05	839.57	840.33	843.31
5	71383000	756.12	759.47	759.26	763.29
6	71550000	992.82	995.83	996.32	999.85
7	72430000	783.39	784.05	785.51	787.92
8	72630000	865.27	867.04	868.18	870.54
9	72680000	1204.16	1205.32	1206.04	1209.74
10	72810000	594.52	597.69	596.88	600.39
11	73765000	551.66	555.36	555.37	558.59
12	73780000	535.02	538.39	538.18	541.79
13	73900000	823.02	825.55	825.26	829.37
14	74205000	689.15	691.48	692.30	695.20
15	74270000	1286.47	1285.52	1289.22	1288.77
16	74370000	748.26	751.43	752.17	753.82
17	74460000	407.89	407.91	408.08	411.69
18	74700000	894.06	894.06	892.96	897.19
19	74880000	812.38	811.96	813.56	815.18
20	74900000	618.21	619.20	620.34	617.96
21	75155000	1057.47	1059.38	1061.61	1060.26
22	75200000	934.69	936.50	933.17	936.59
23	75205000	481.56	478.18	479.10	482.10
24	75230000	1209.25	1208.33	1211.33	1211.97
25	75295000	626.95	625.47	626.16	629.37
26	75400000	1099.82	1101.53	1099.61	1103.89
27	75450000	908.27	904.39	904.97	908.30
28	75500000	1124.09	1123.94	1124.06	1127.99
29	76100000	1184.81	1186.31	1185.28	1189.63
30	76440000	1113.97	1114.15	1113.53	1117.81
31	76460000	917.36	916.21	920.91	915.98
32	76650000	923.06	919.35	923.68	923.14

Oscilação Decenal do Pacífico (ODP)					
Nº	Estação	Modelo			
		0	1	2	3
33	76750000	1059.98	1061.75	1060.58	1064.59

APÊNDICE C - QUANTIS DA CHEIA DE 50 ANOS CONSIDERANDO OS ÍNDICES EXTREMOS PARA CADA COVARIÁVEL NAS SÉRIES SELECIONADAS POR MODELOS NÃO ESTACIONÁRIOS E A HIPÓTESE DE ESTACIONARIEDADE PARA ESSAS SÉRIES.

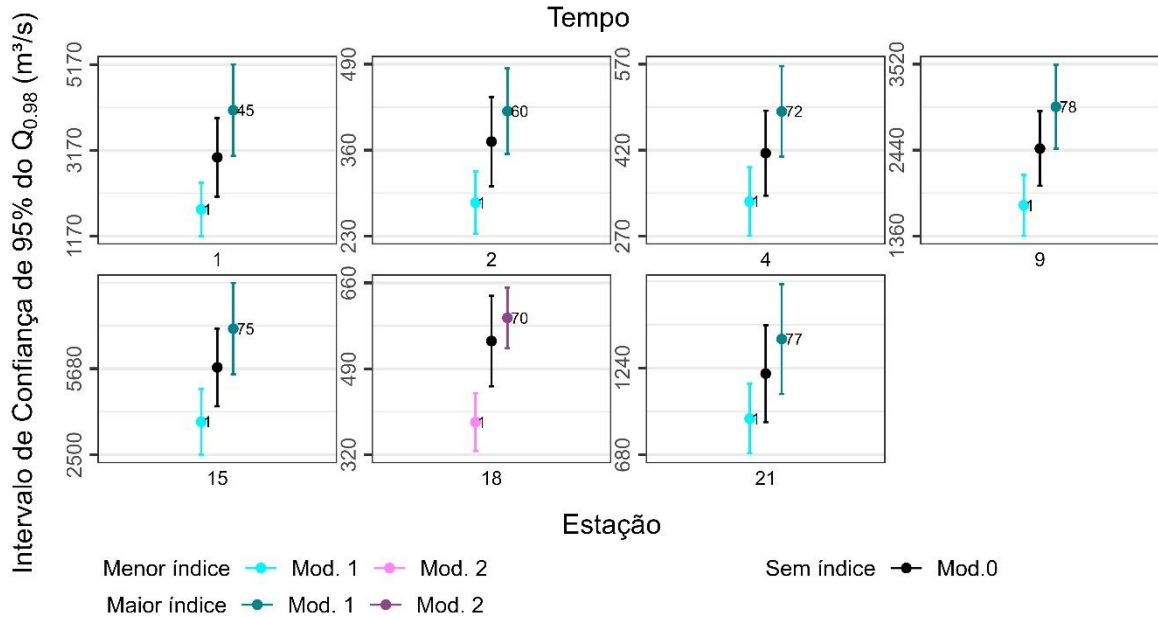


Figura 0.1 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável Tempo em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 1 (verde-claro) e Modelo 2 (rosa-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro) e Modelo 2 (rosa-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

Niño 1+2




Figura 0.2 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável El Niño 1+2 em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 1 (verde-claro), Modelo 2 (rosa-claro) e Modelo 3 (roxo-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro), Modelo 2 (rosa-escuro) e Modelo 3 (roxo-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

Niño 3




Figura 0.3 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável El Niño 3 em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 1 (verde-claro), Modelo 2 (rosa-claro) e Modelo 3 (roxo-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-escuro), Modelo 2 (rosa-escuro) e Modelo 3 (roxo-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

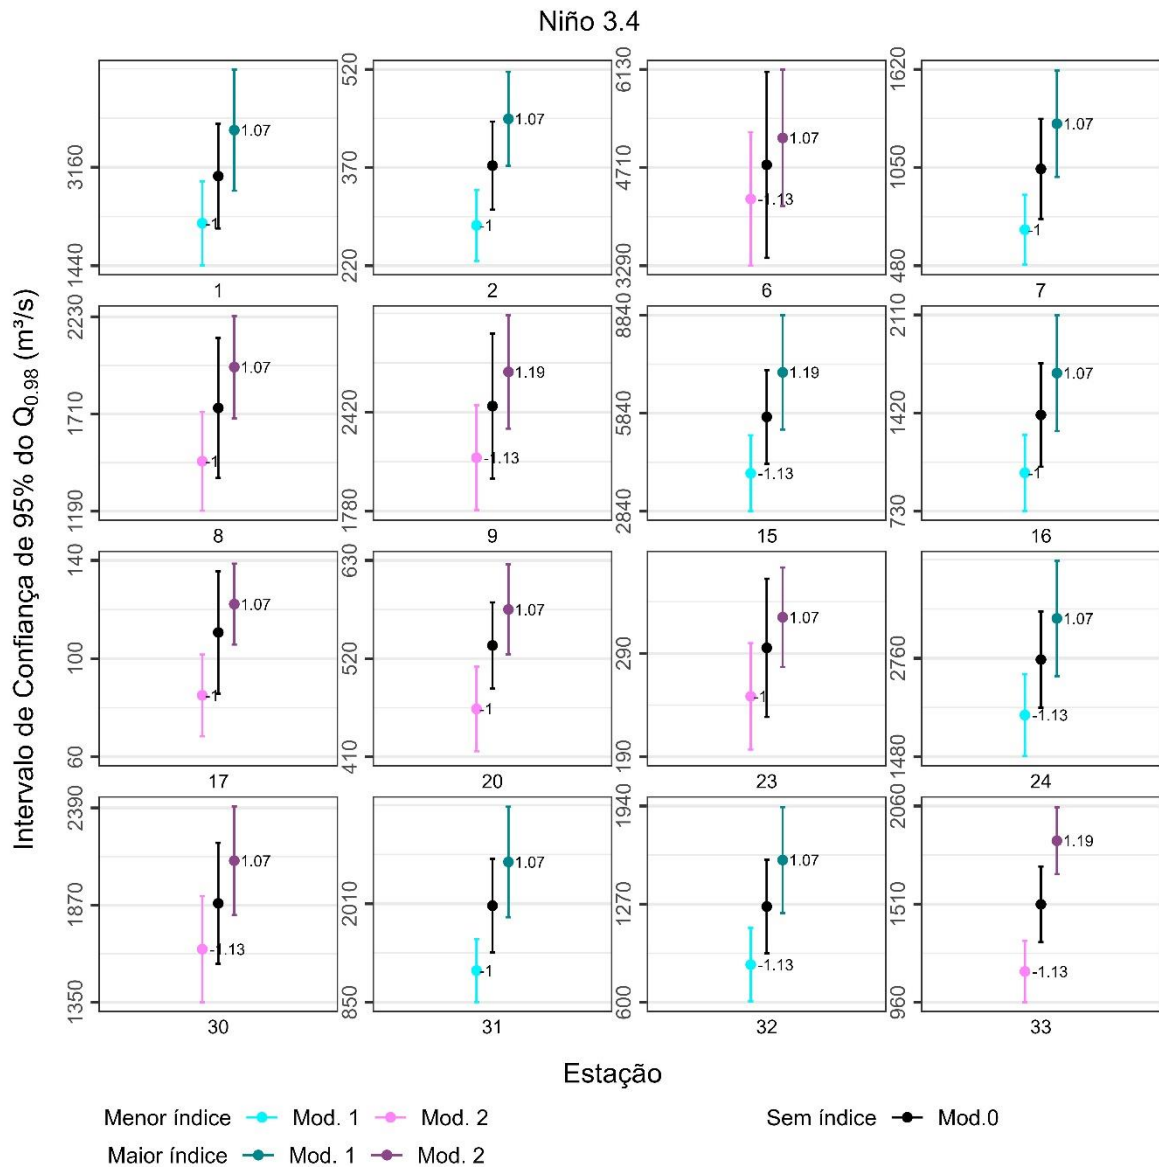


Figura 0.4 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável El Niño 3.4 em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 1 (verde-claro) e Modelo 2 (rosa-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 1 (verde-

escuro), Modelo 2 (rosa-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

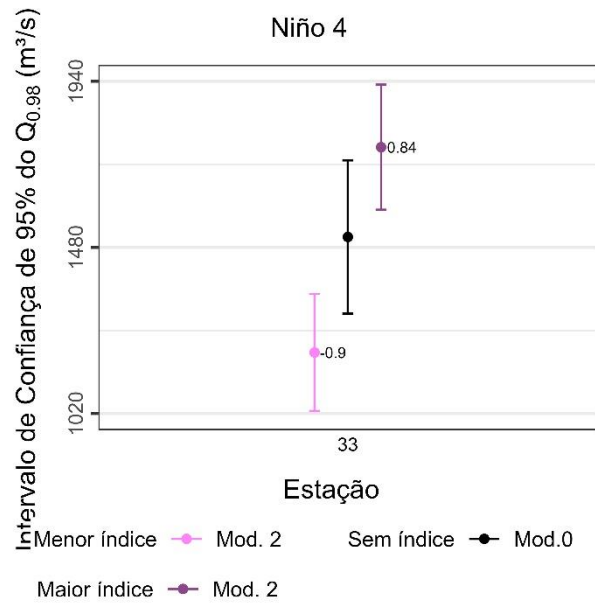
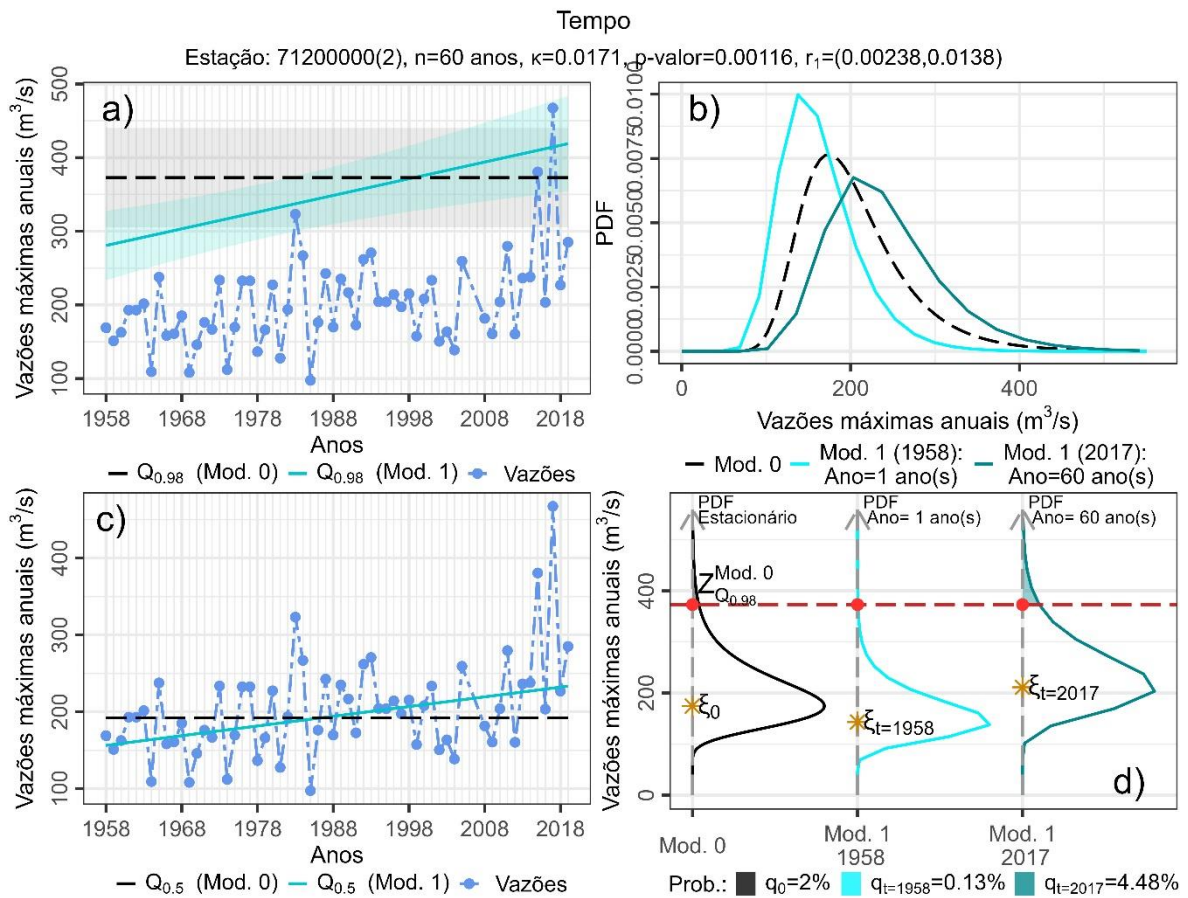
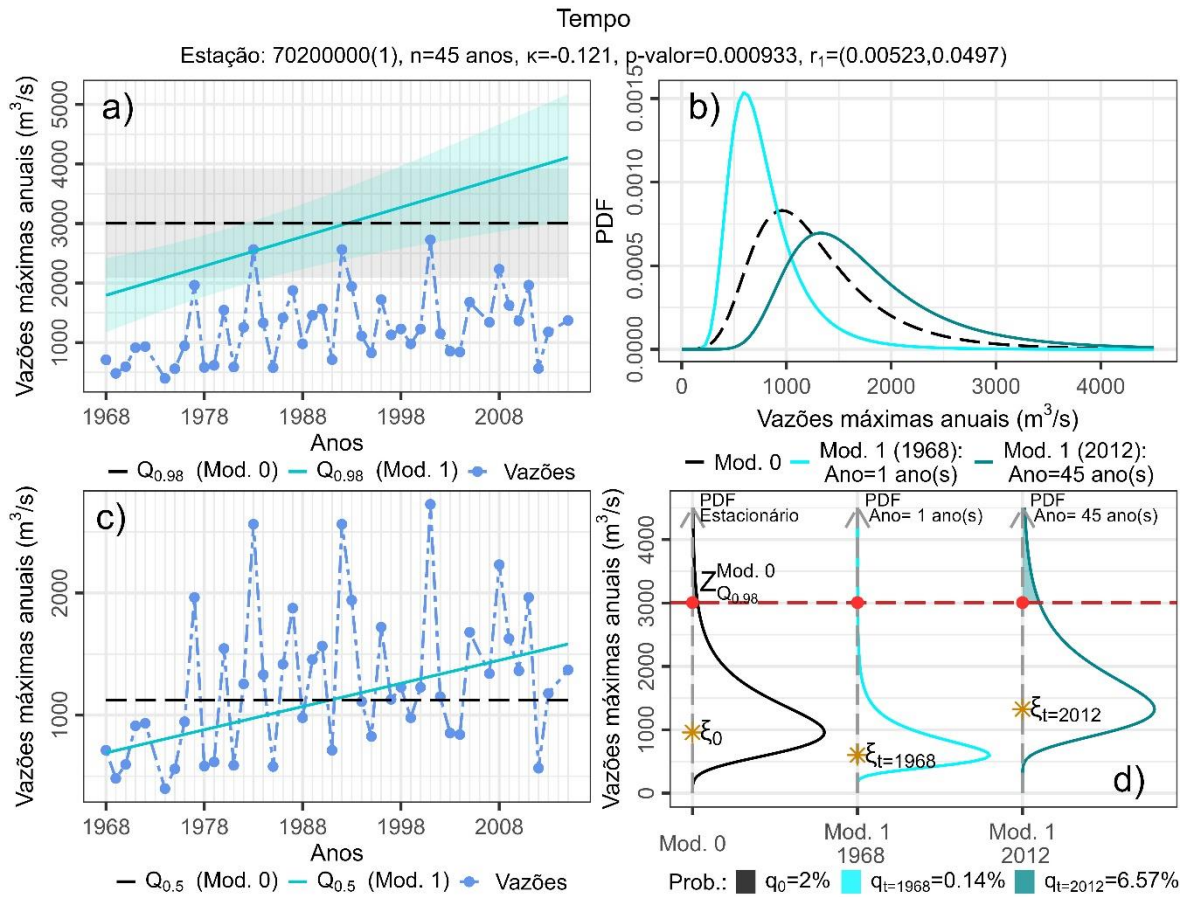
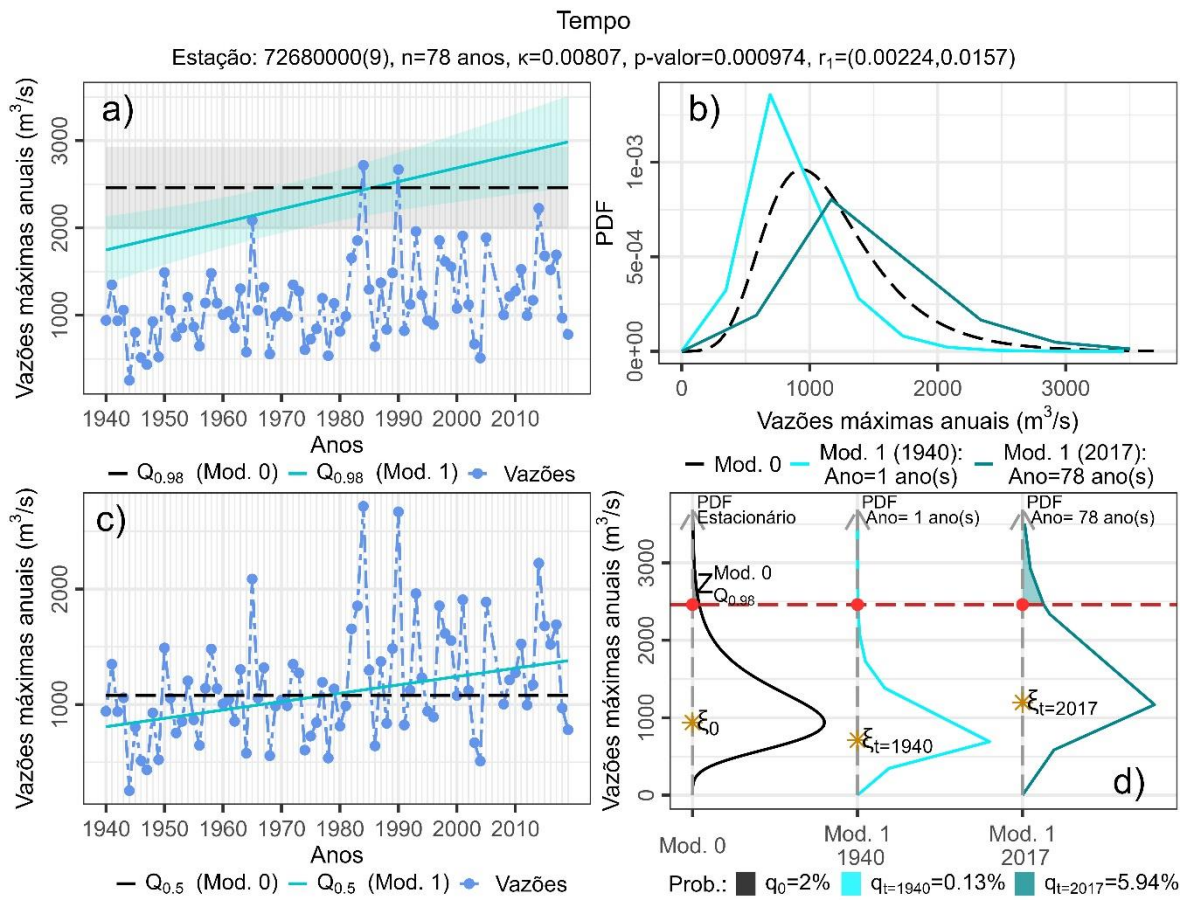
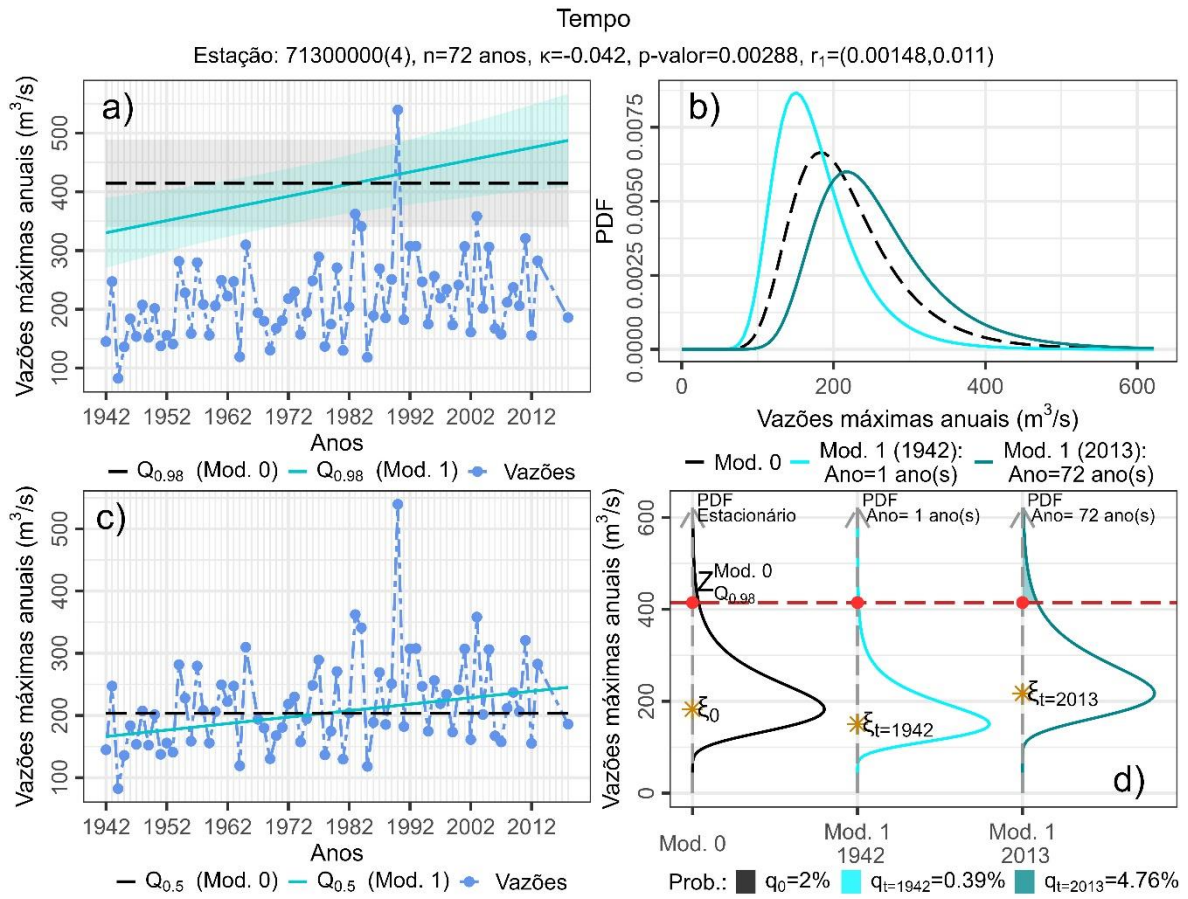
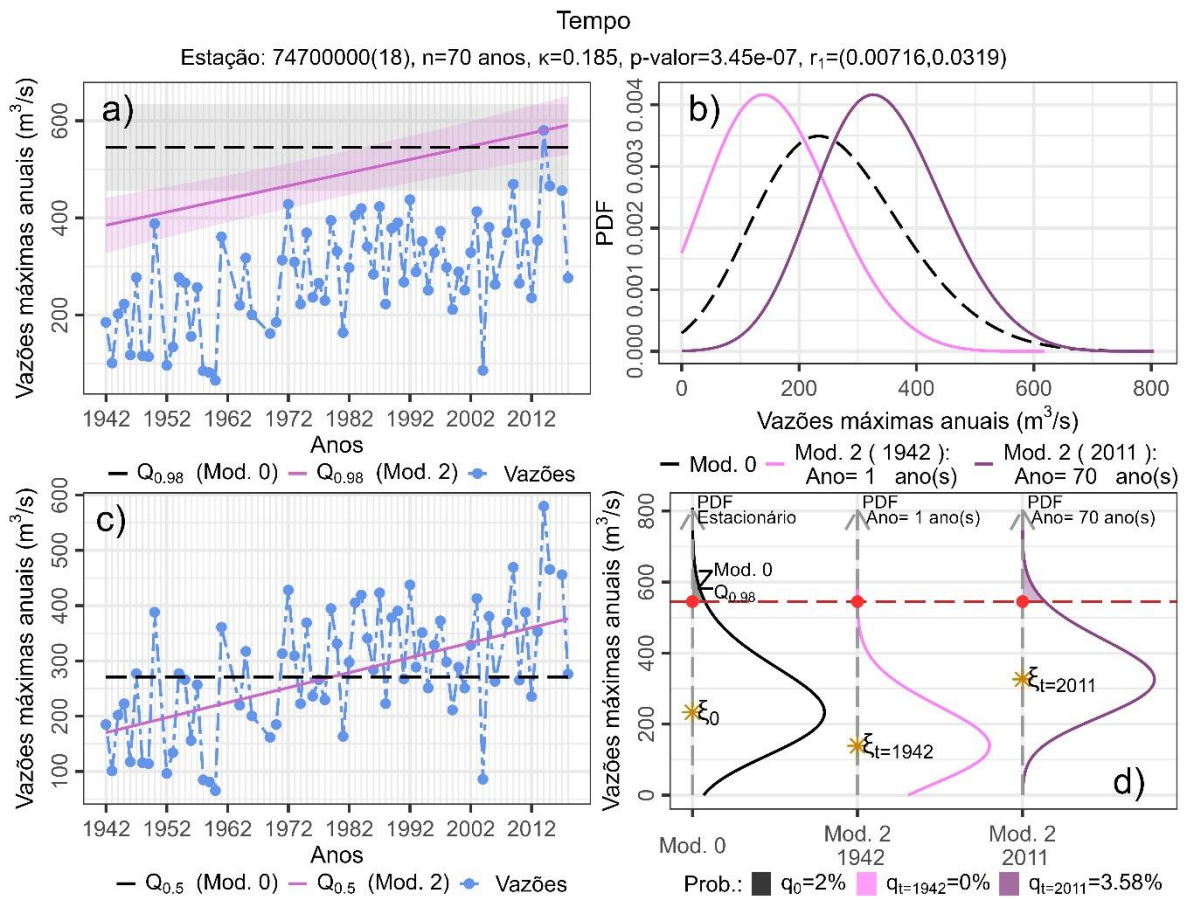
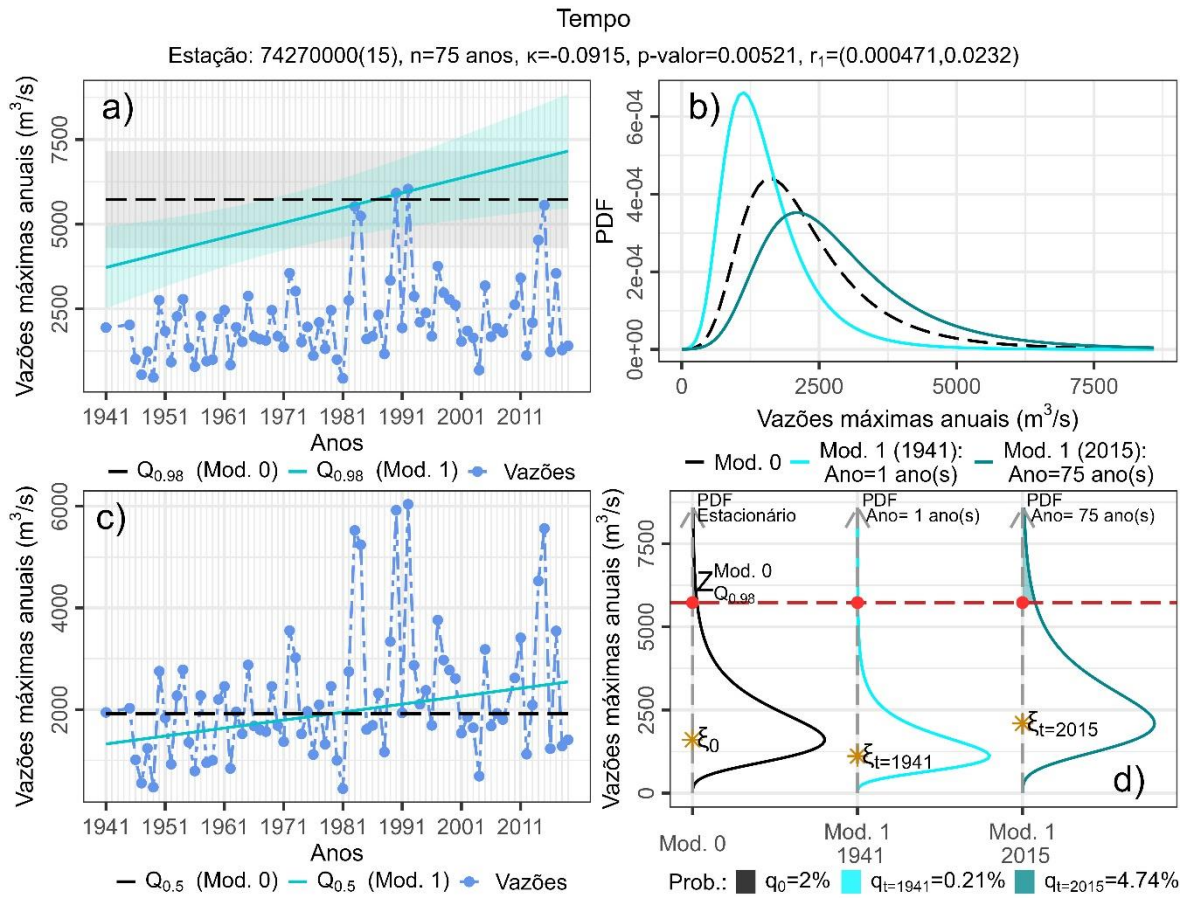


Figura 0.5 - Quantis da cheia de 50 anos. Considera-se os índices extremos para a covariável El Niño 4 em séries selecionadas por modelos não estacionários após análise regional (FDR + IC) e a hipótese de estacionariedade para essas séries (Modelo 0). Menor índice da covariável: Modelo 2 (rosa-claro). Sem índice (estacionariedade): Modelo 0 (preto). Maior índice da covariável: Modelo 2 (rosa-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

APÊNDICE D - RESULTADOS PARA AS SÉRIES TEMPORAIS DAS ESTAÇÕES MODELADAS POR MODELOS NÃO ESTACIONÁRIOS NA REGIÃO HIDROGRÁFICA DO URUGUAI PARA AS COVARIÁVEIS ANALISADAS. A) VAZÕES MÁXIMAS ANUAIS E ESTIMATIVAS DO $Q_{0.98}$ PARA O MODELO ESTACIONÁRIO E NÃO ESTACIONÁRIO E SEUS RESPECTIVOS IC DE 95%. B) PDF DO MODELO ESTACIONÁRIO E NÃO ESTACIONÁRIO PARA OS VALORES EXTREMOS DA SÉRIE HISTÓRICA DAS COVARIÁVEIS. C) VAZÕES ANUAIS MÁXIMAS E ESTIMATIVAS DE $Q_{0.5}$ PARA O MODELO ESTACIONÁRIO E NÃO ESTACIONÁRIO. D) PDF EM B) COM SEUS RESPECTIVOS P-VALORES BASEADOS NO QUANTIL DE REFERÊNCIA DE 50 ANOS ESTACIONÁRIO.







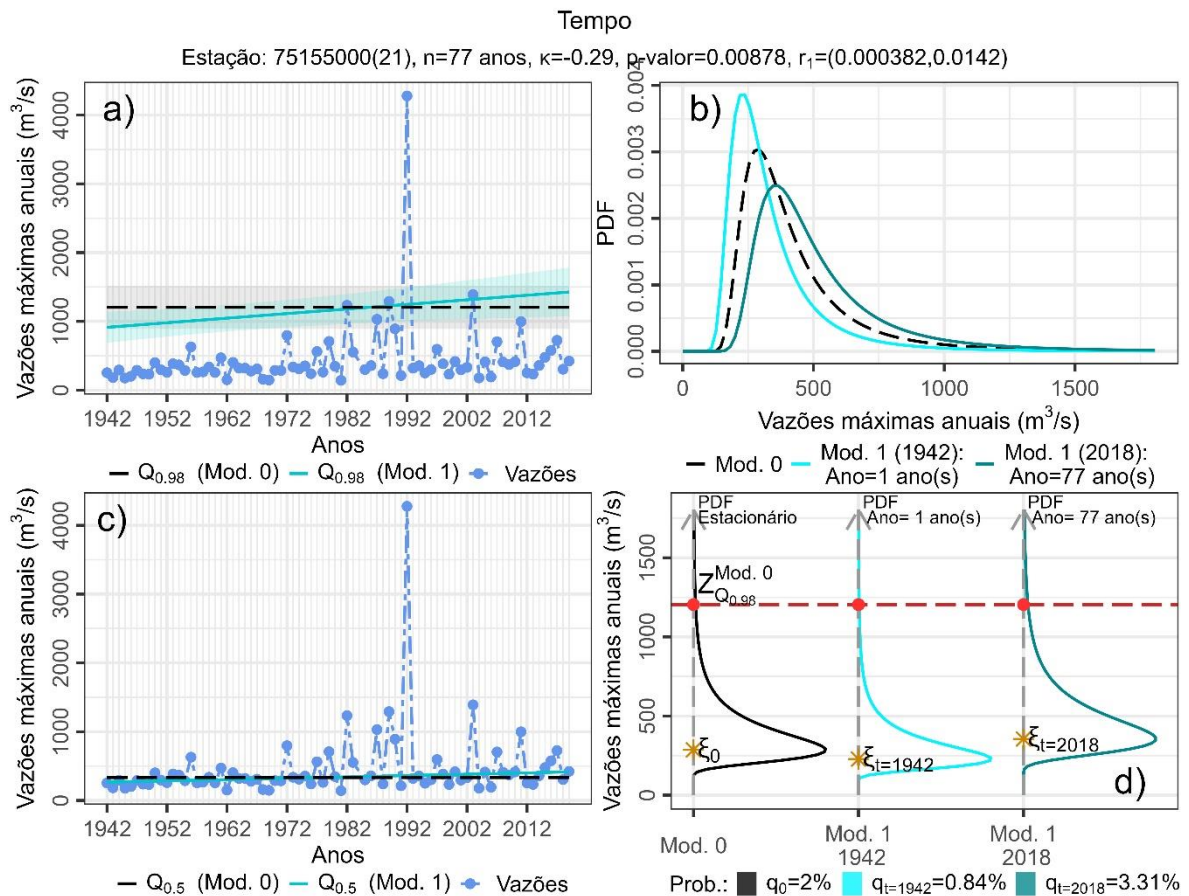
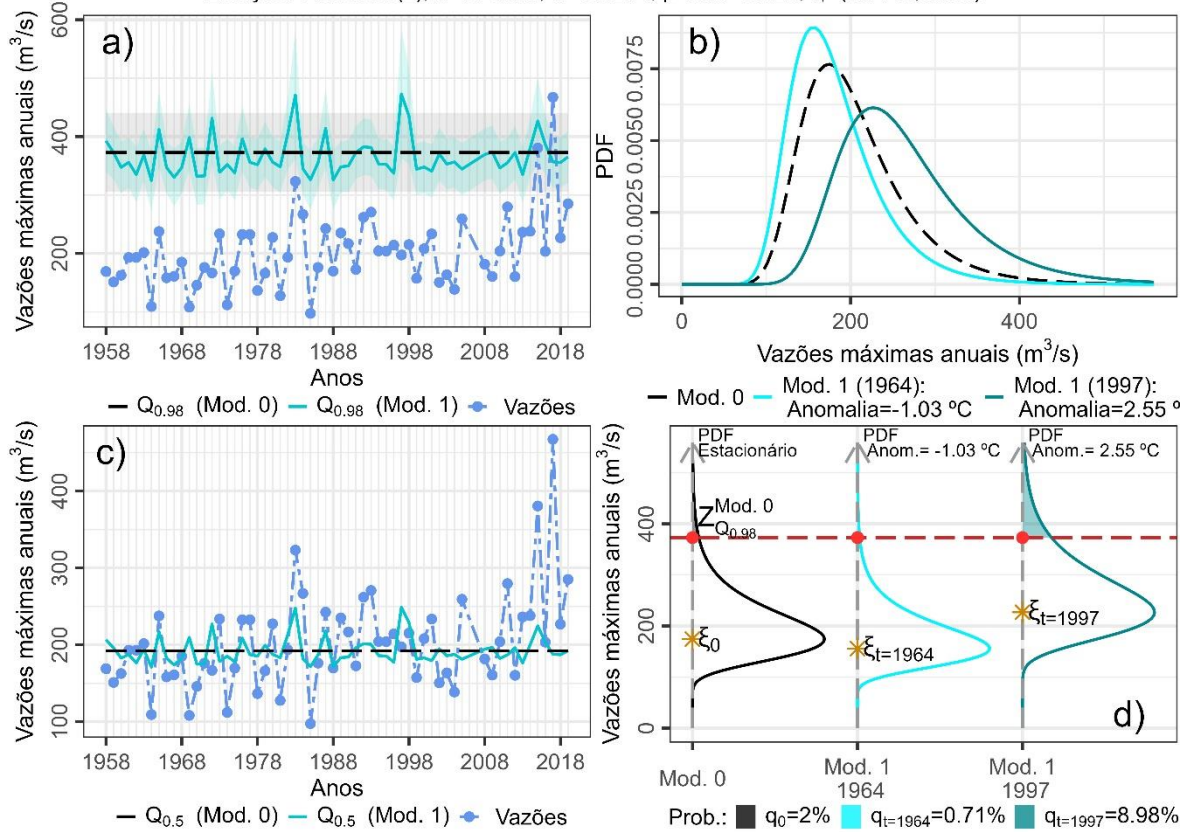


Figura 0.6 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável Tempo. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em azul-claro), ou Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 1: azul-claro; Modelo 2: rosa-claro) e a maior anomalia (Modelo 1: azul-escuro; Modelo 2: rosa- escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (azul-claro), ou Modelo 2 (em rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.

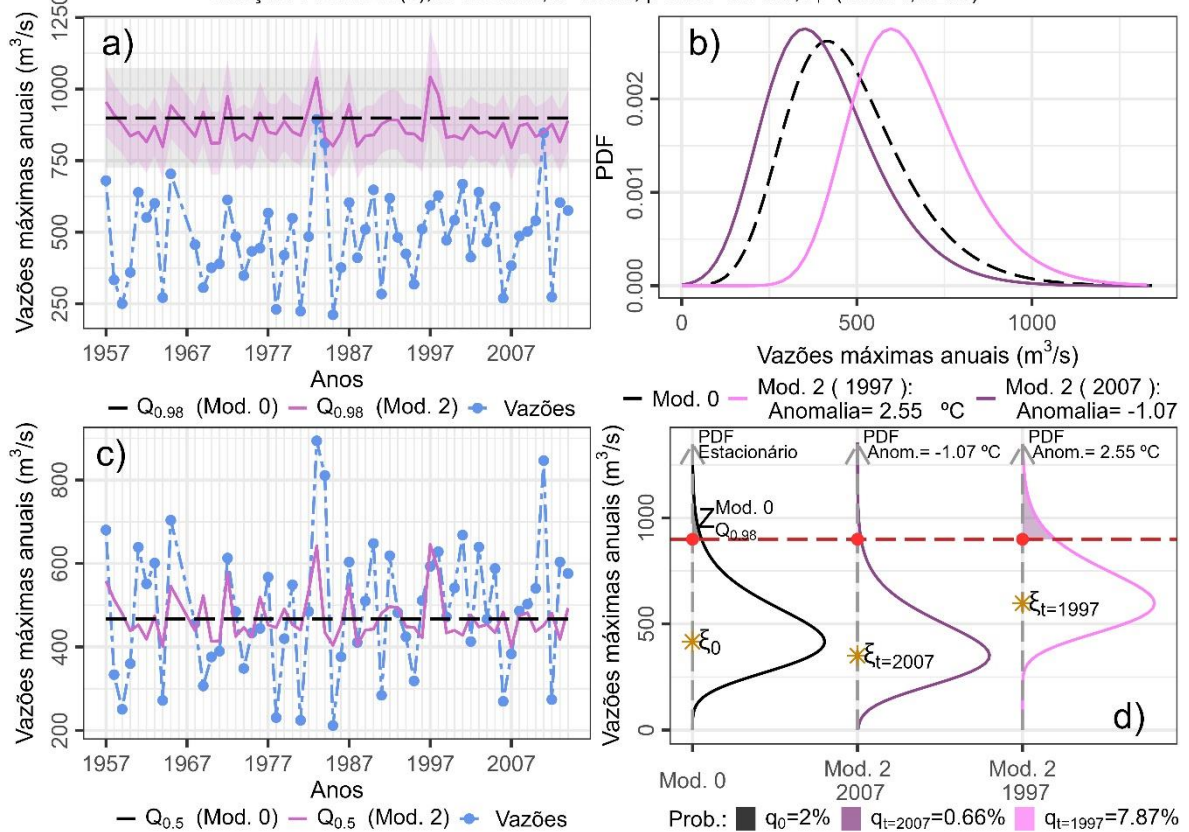
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

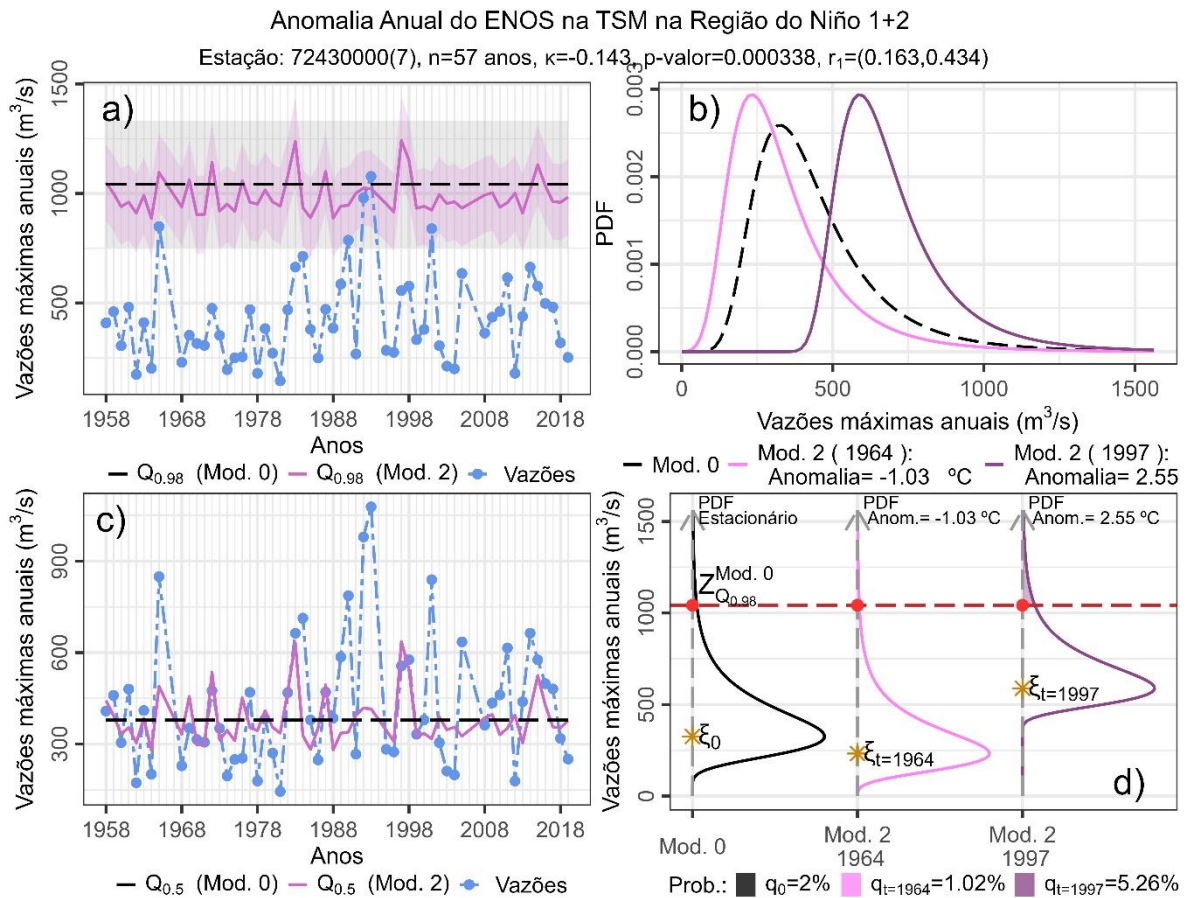
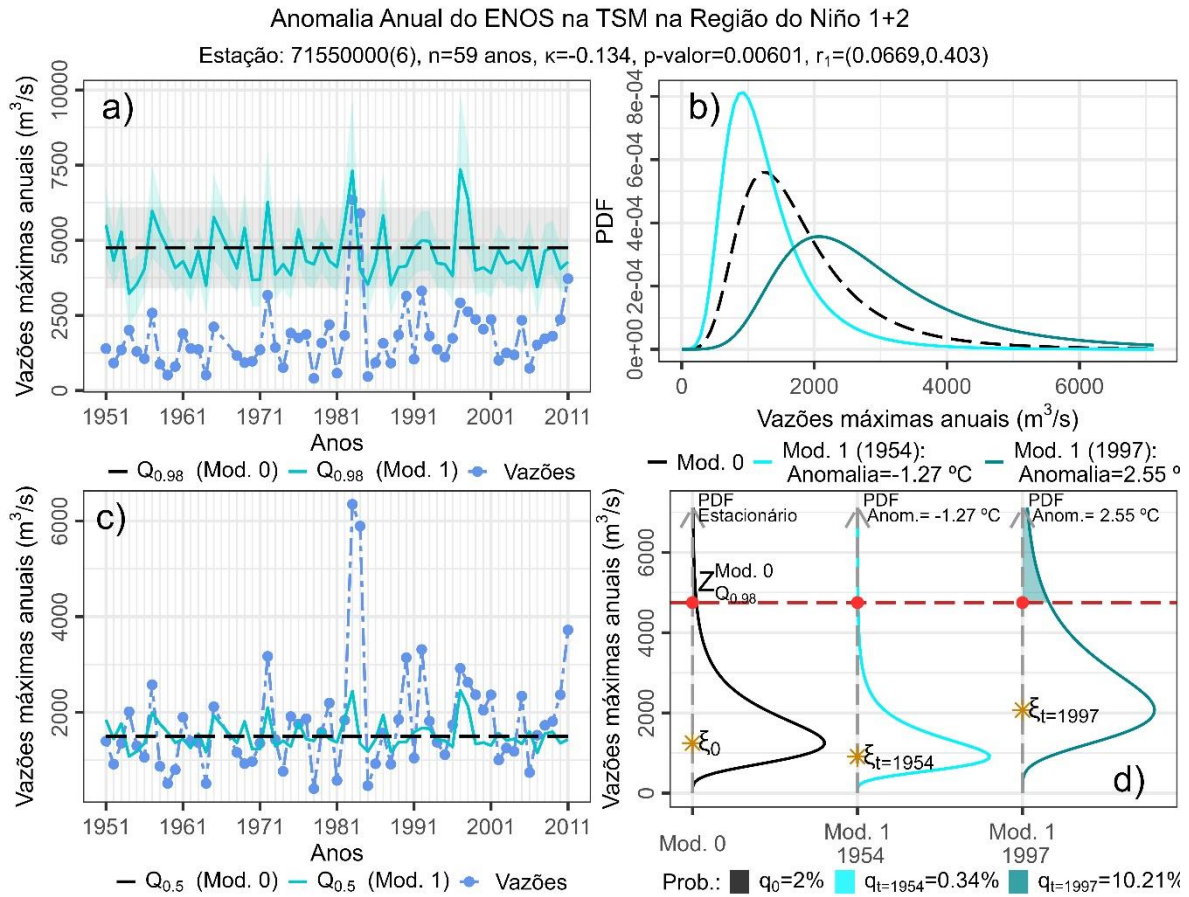
Estação: 71200000(2), n=60 anos, $\kappa=-0.0264$, p-valor=0.024, $r_1=(0.0148,0.211)$



Anomalia Anual do ENOS na TSM na Região do Niño 1+2

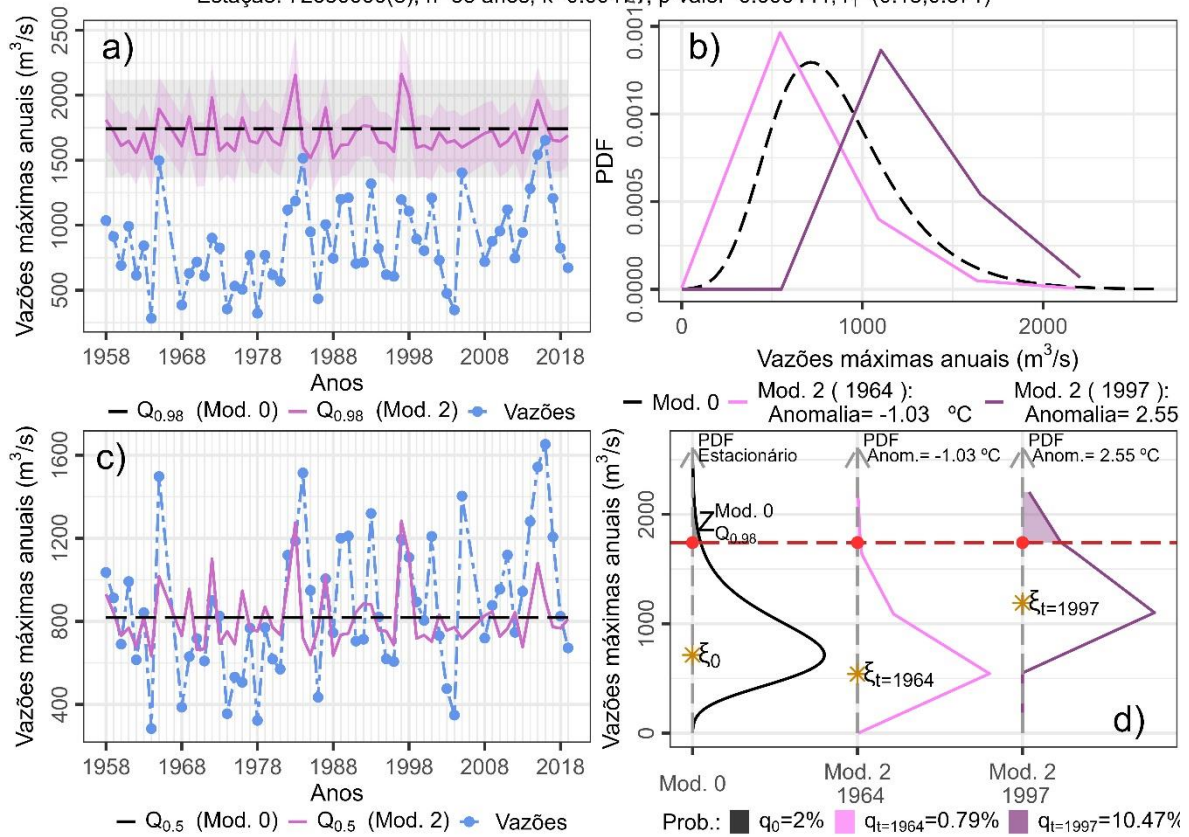
Estação: 71383000(5), n=56 anos, $\kappa=0.084$, p-valor=0.0121, $r_1=(0.0434,0.279)$





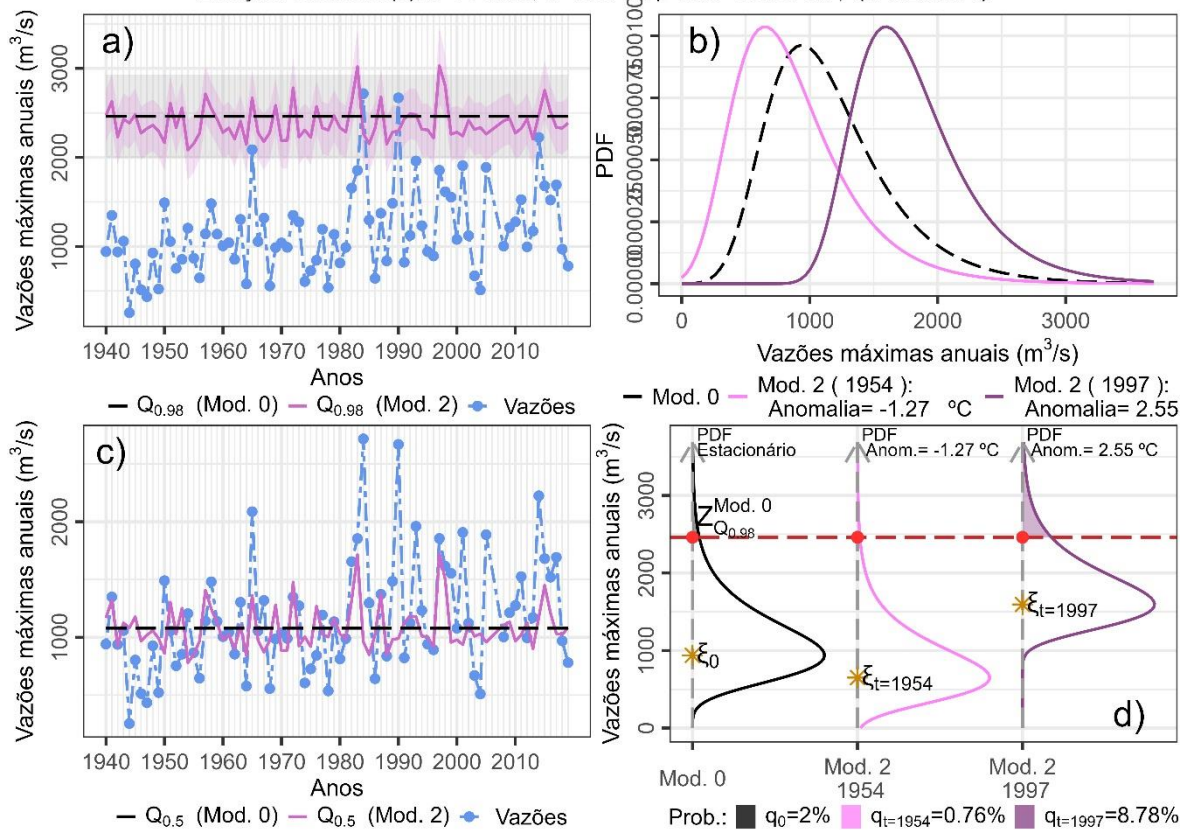
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 72630000(8), n=58 anos, $\kappa=0.00471$, p-valor=0.000441, $r_1=(0.13,0.371)$



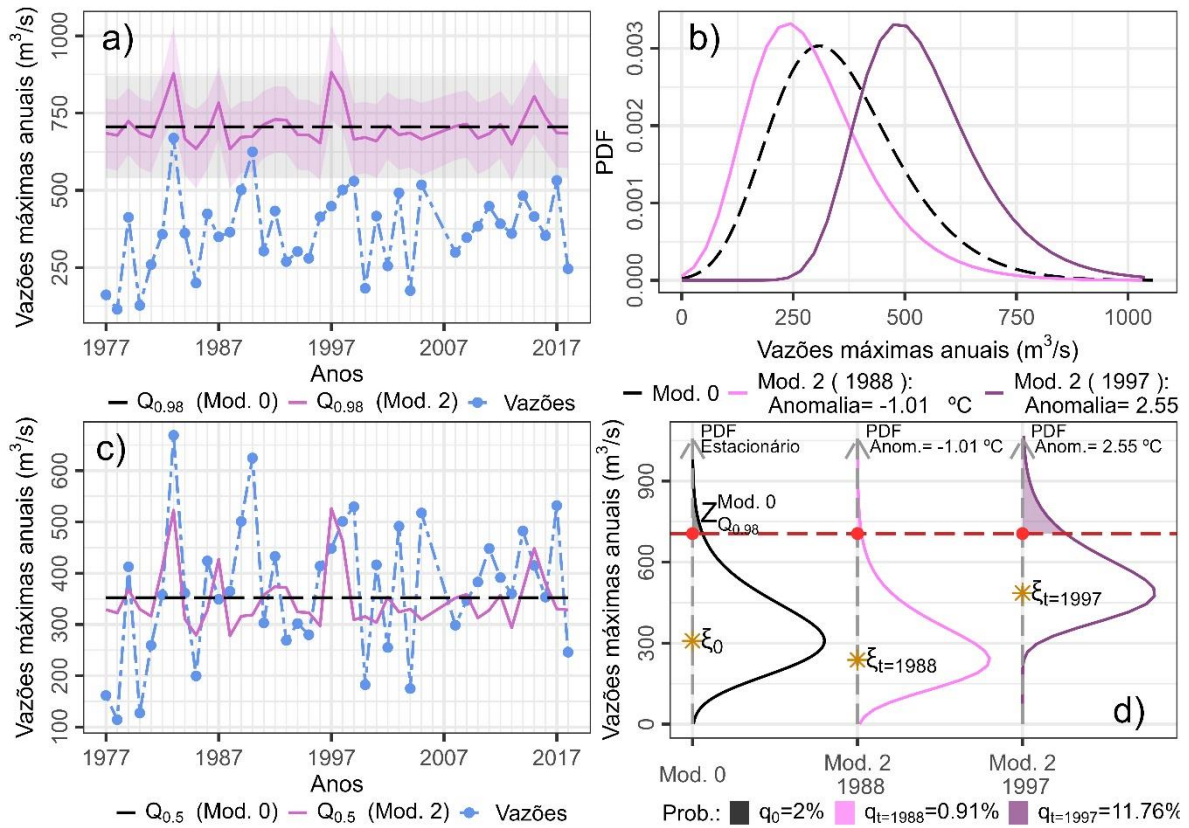
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 72680000(9), n=78 anos, $\kappa=-0.0183$, p-valor=0.00071, $r_1=(0.122,0.391)$



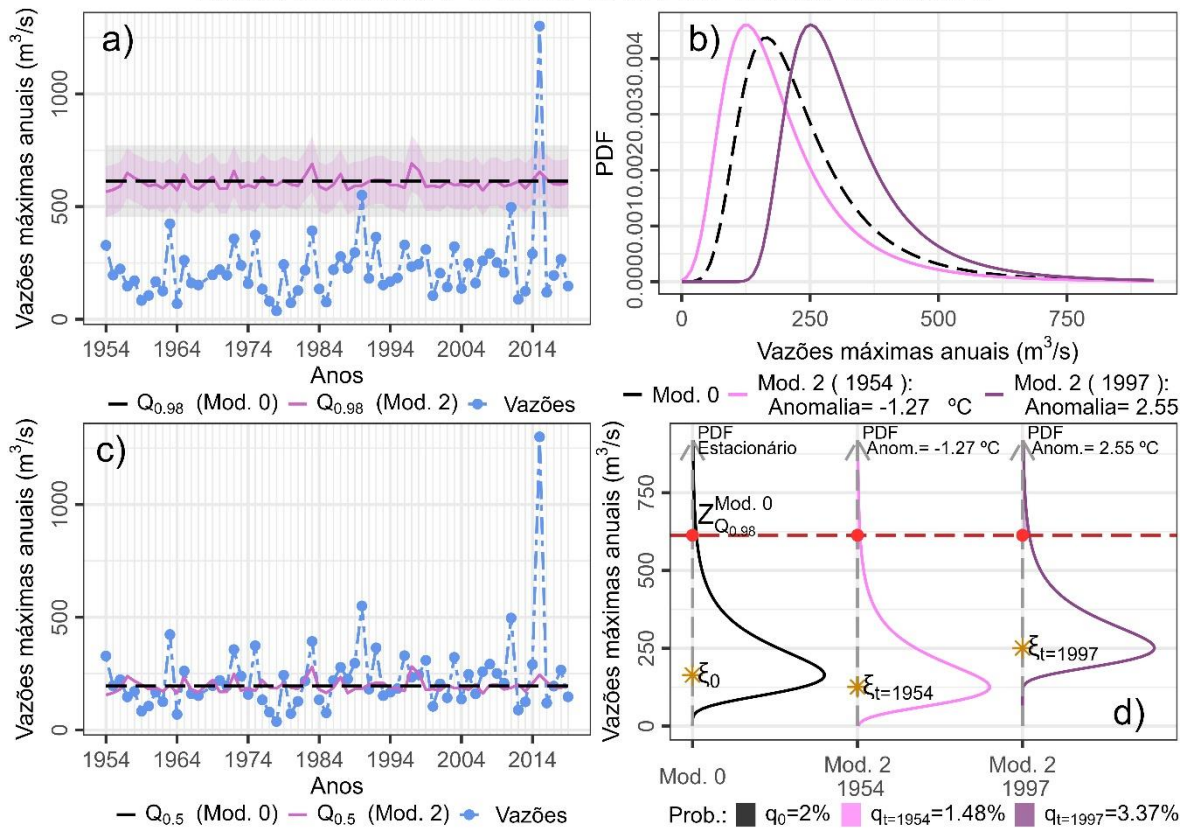
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 73780000(12), n=40 anos, $\kappa=0.0452$, p-valor=0.0142, $r_1=(0.0585,0.395)$



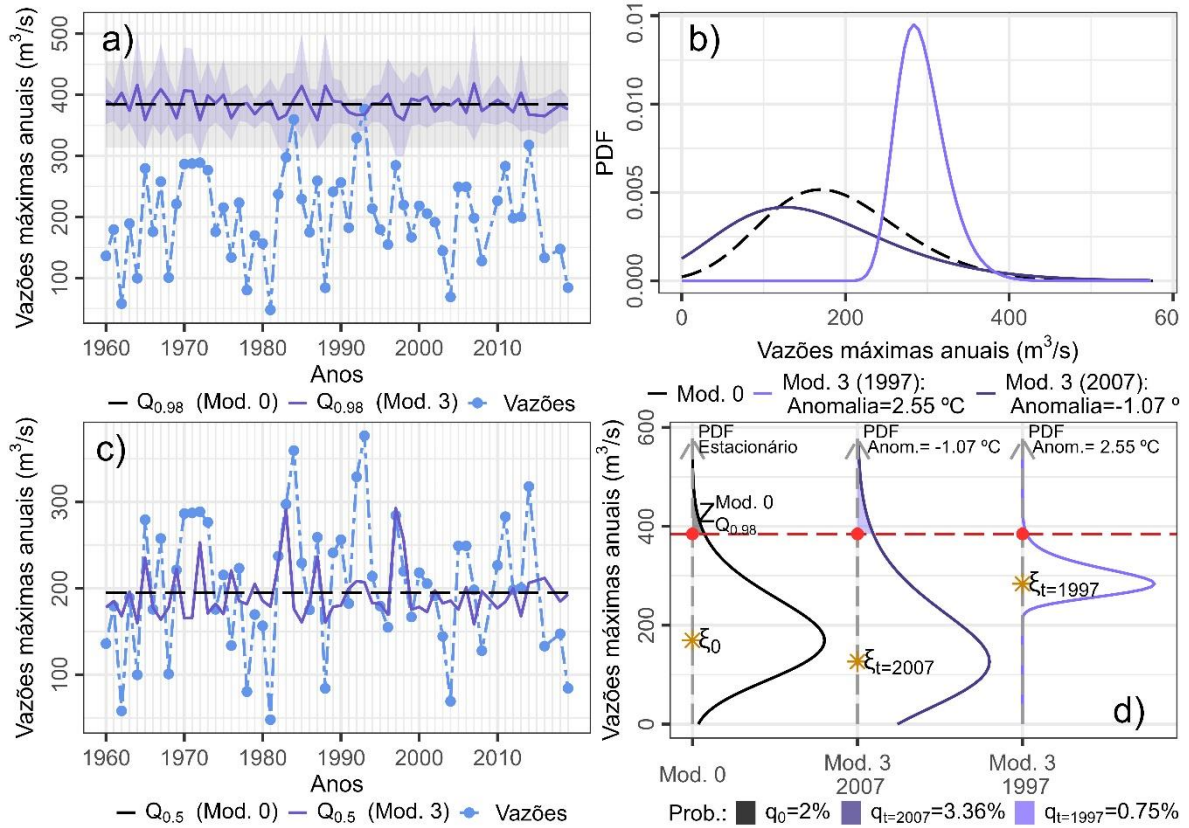
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 73900000(13), n=65 anos, $\kappa=-0.168$, p-valor=0.0305, $r_1=(0.0364,0.357)$



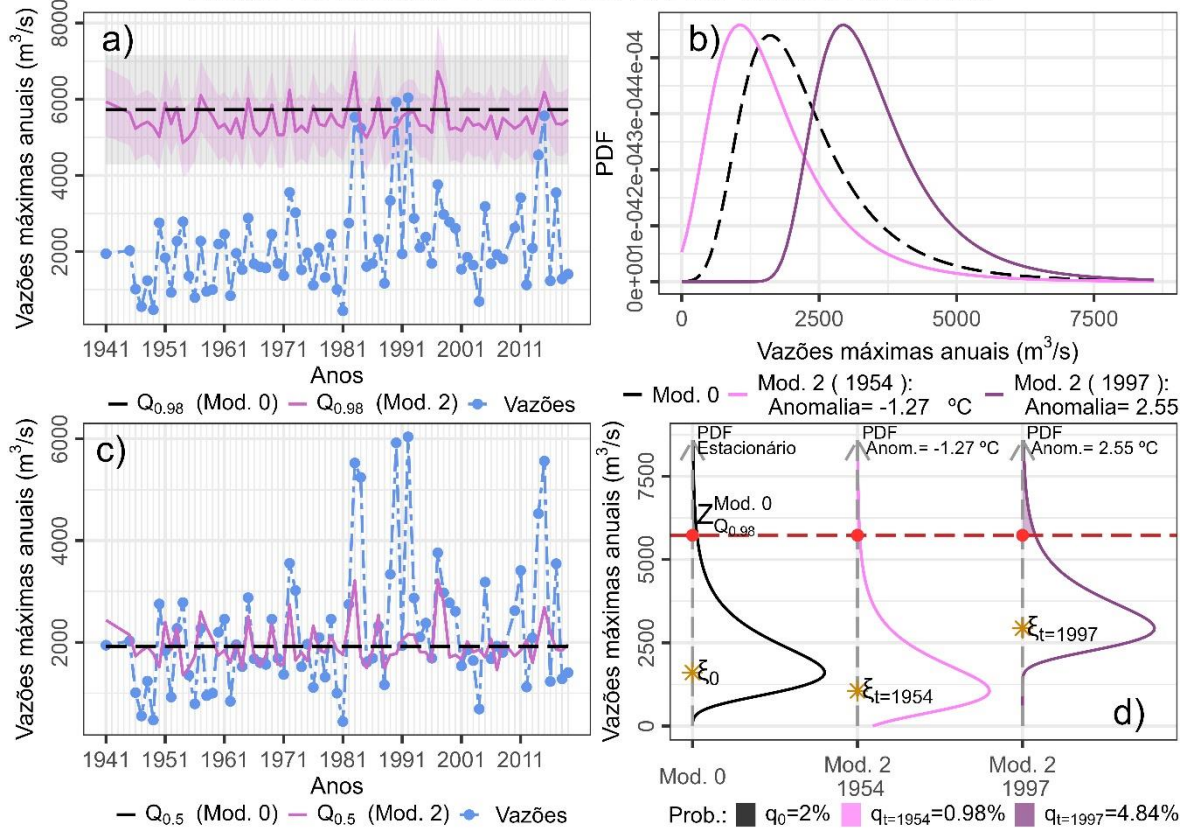
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 74205000(14), n=57 anos, $\kappa=43.4$, p-valor=0.00197, $r_1=(0.151,0.352)$, $\beta_1=(-0.445,-0.0413)$



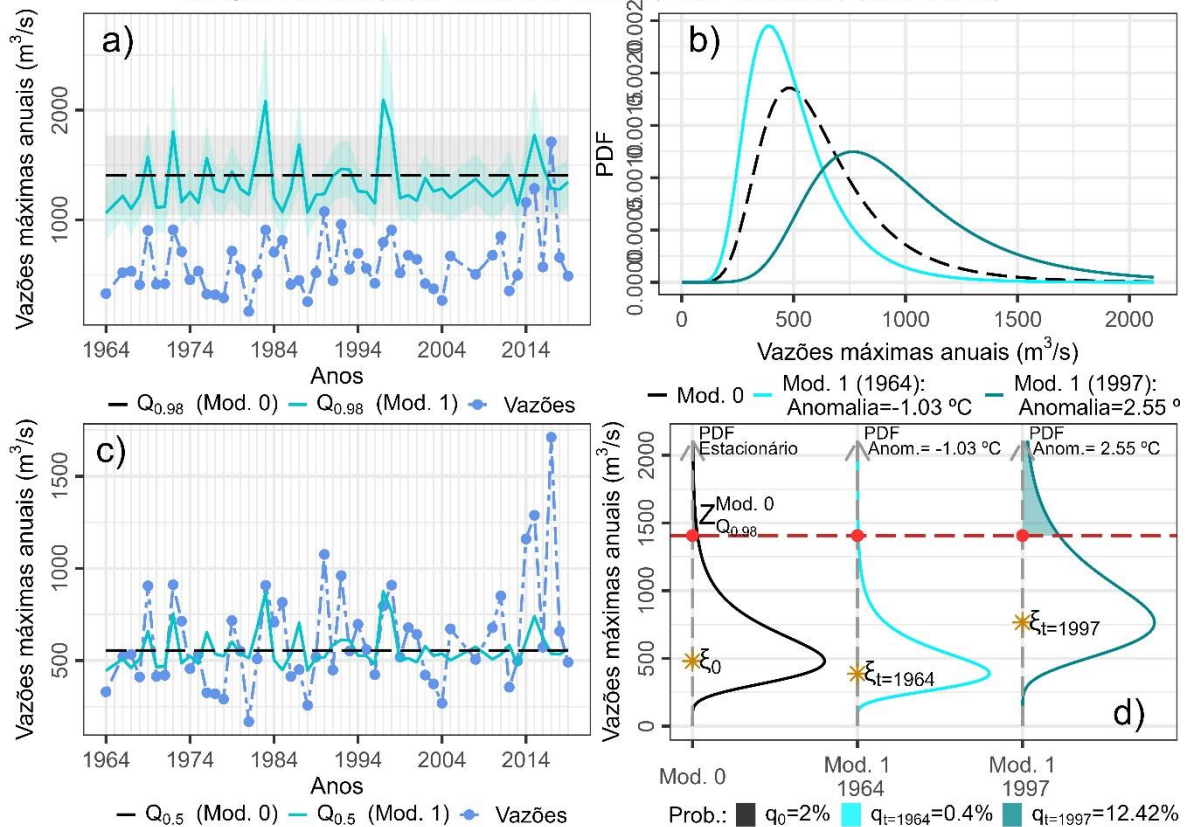
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 74270000(15), n=75 anos, $\kappa=-0.0964$, p-valor=0.00357, $r_1=(0.112,0.472)$



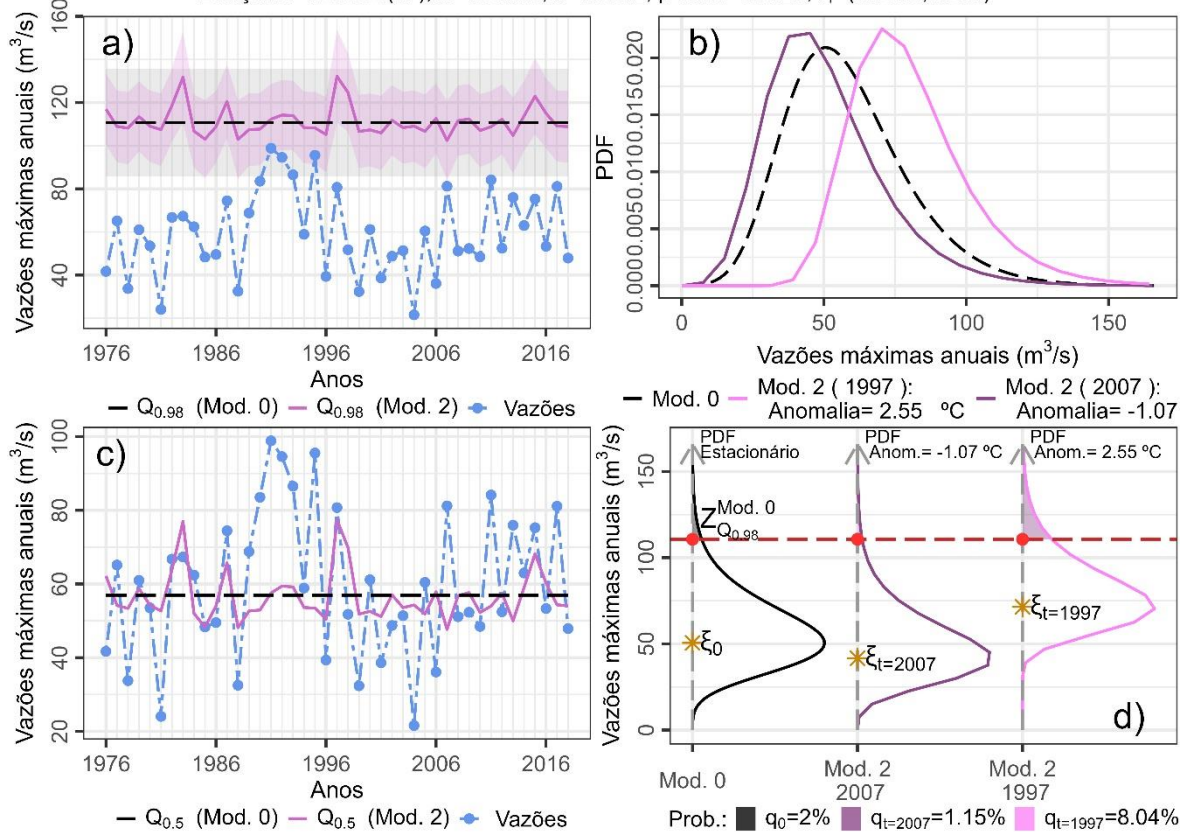
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

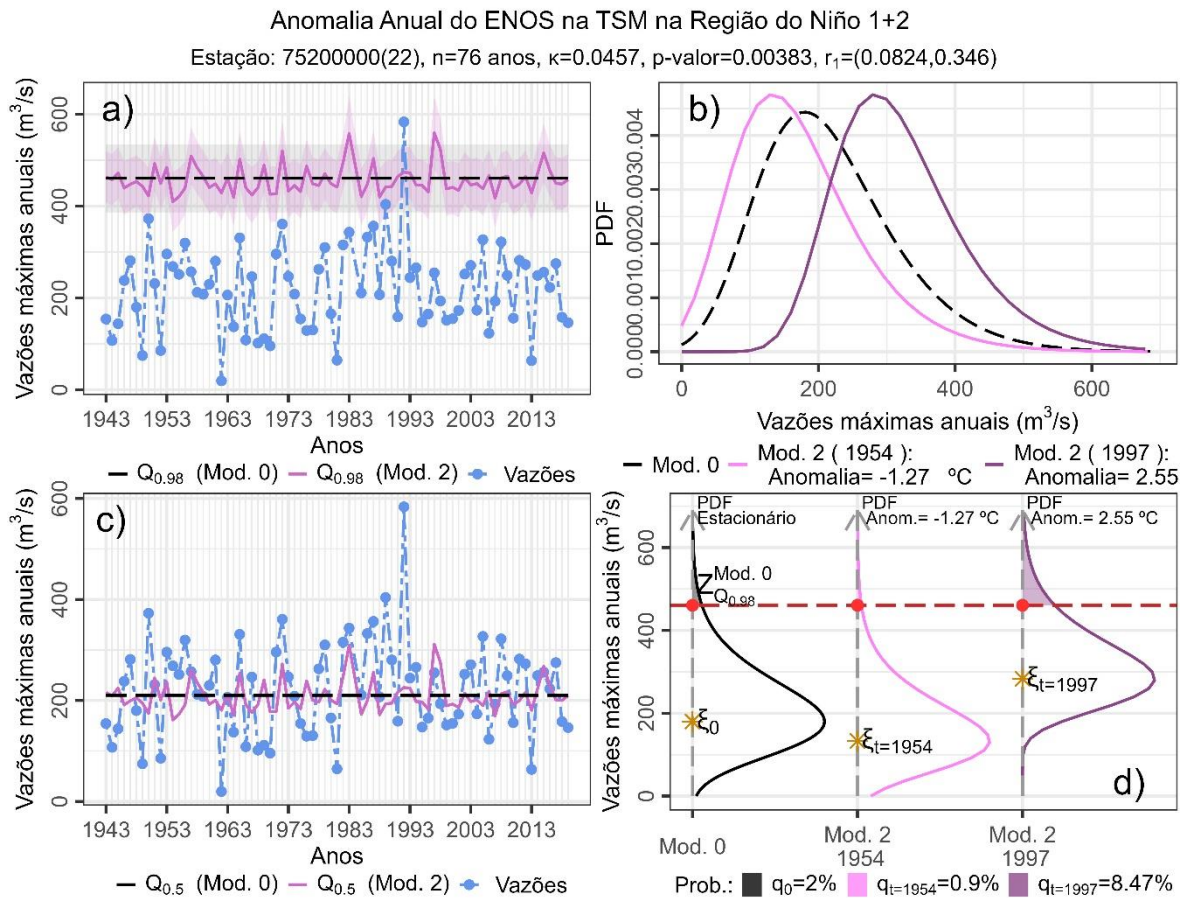

Estação: 74370000(16), n=52 anos, $\kappa=-0.0724$, p-valor=0.00555, $r_1=(0.0609,0.362)$

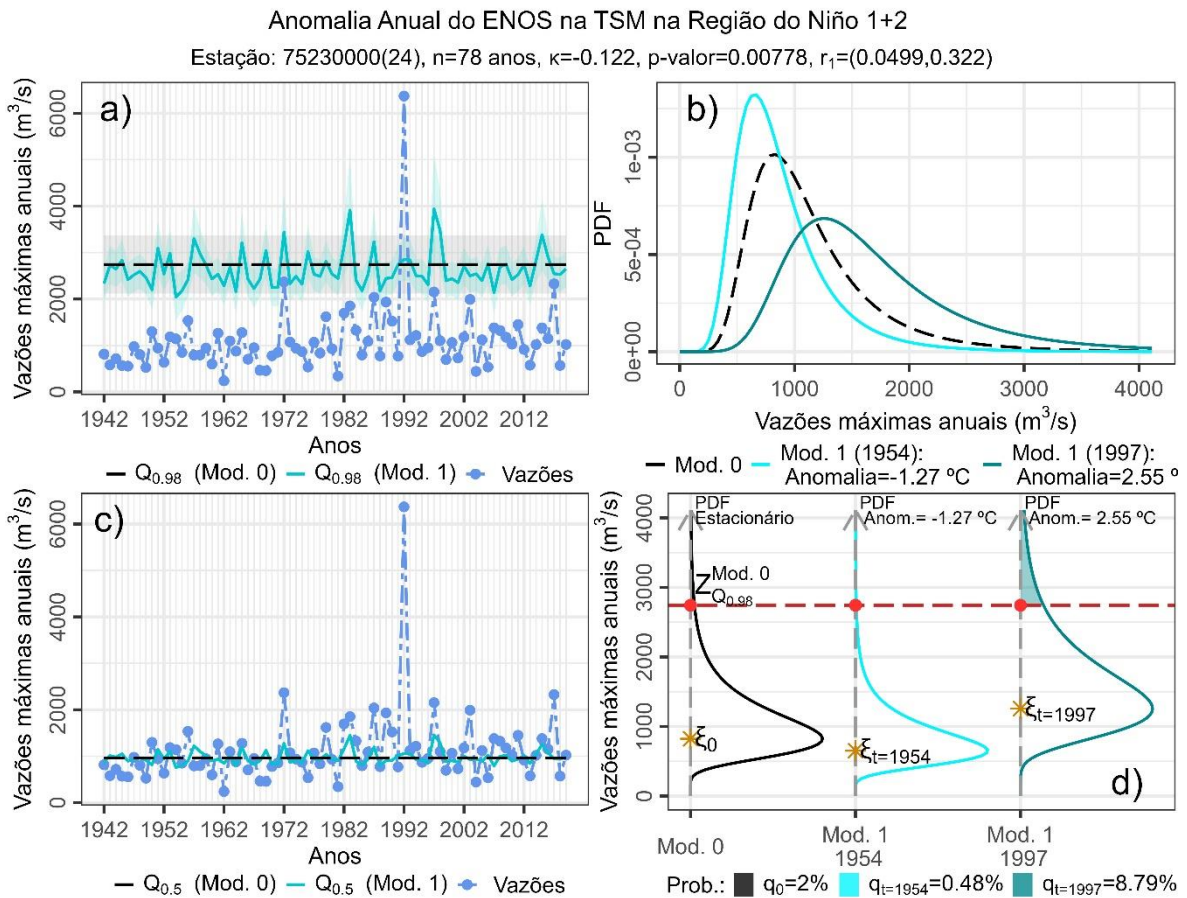
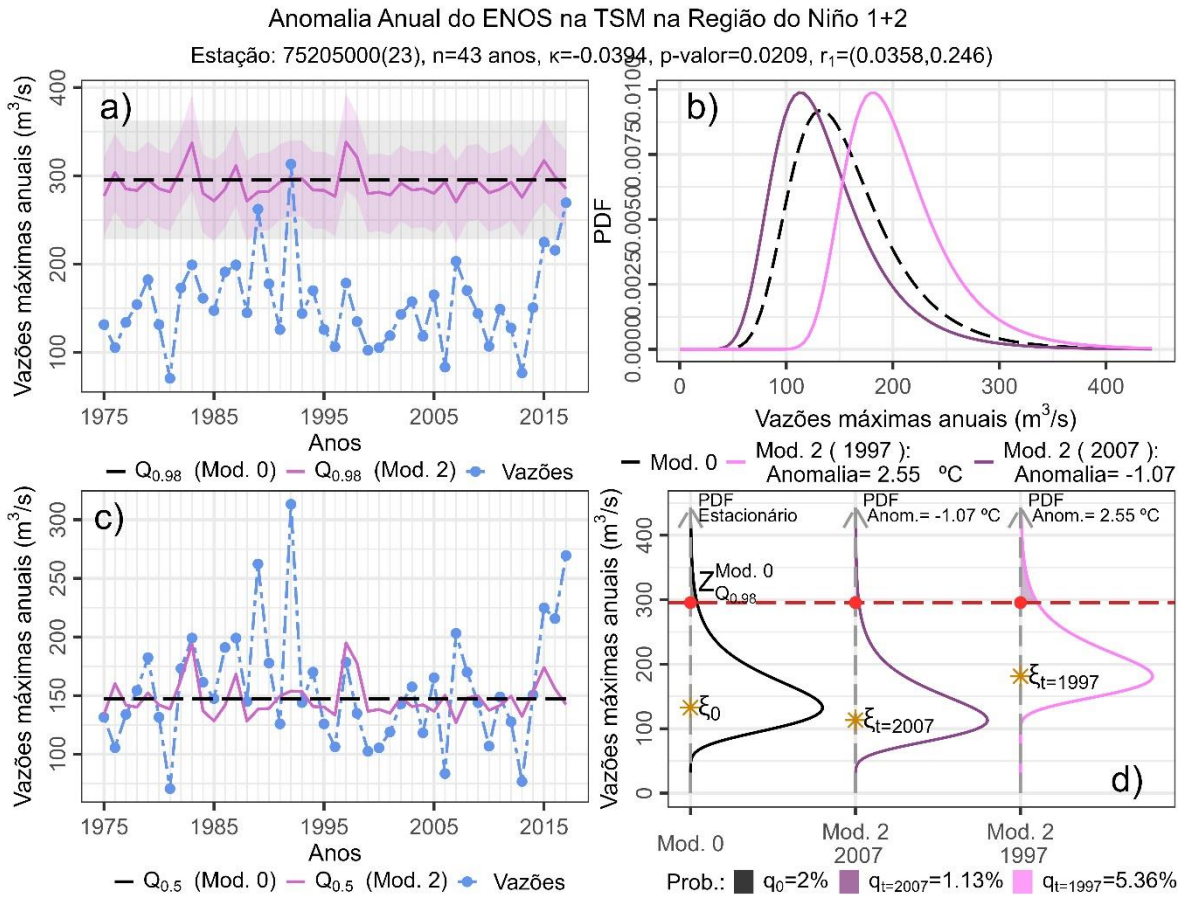


Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 74460000(17), n=43 anos, $\kappa=0.0232$, p-valor=0.0229, $r_1=(0.0365,0.289)$

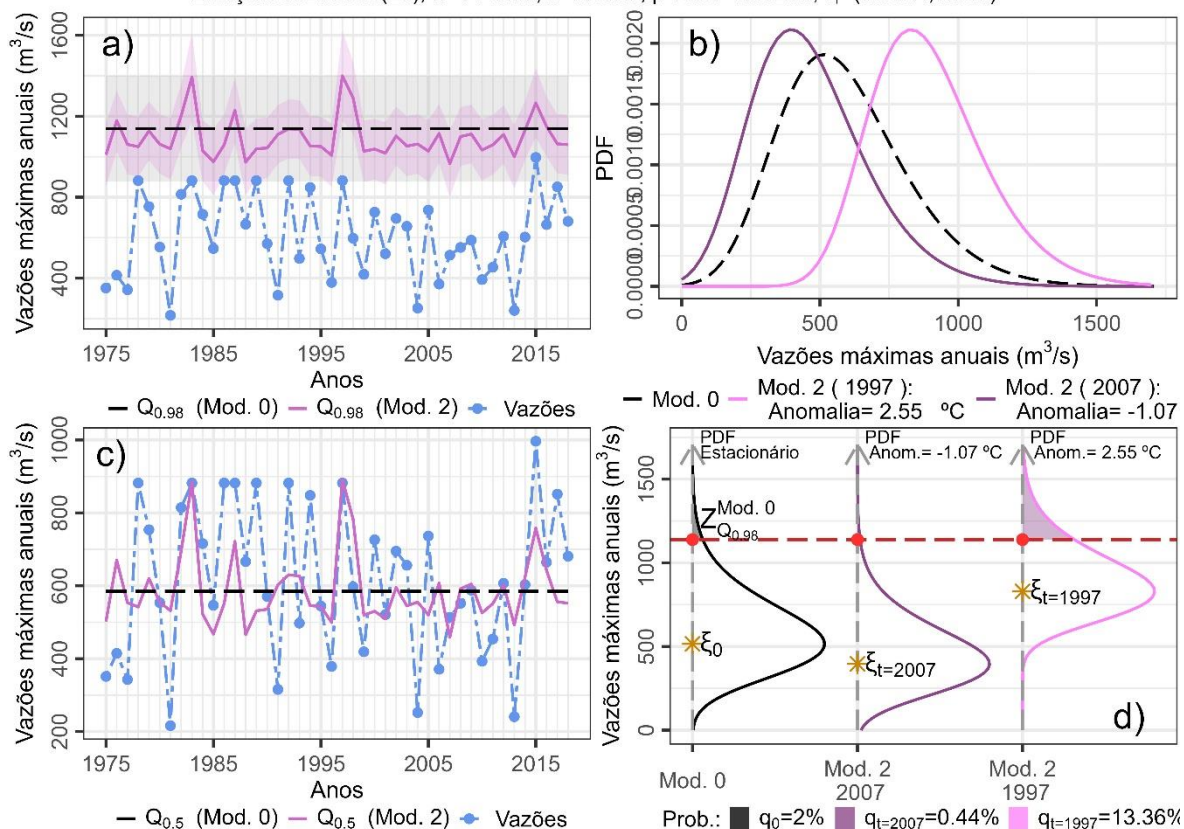






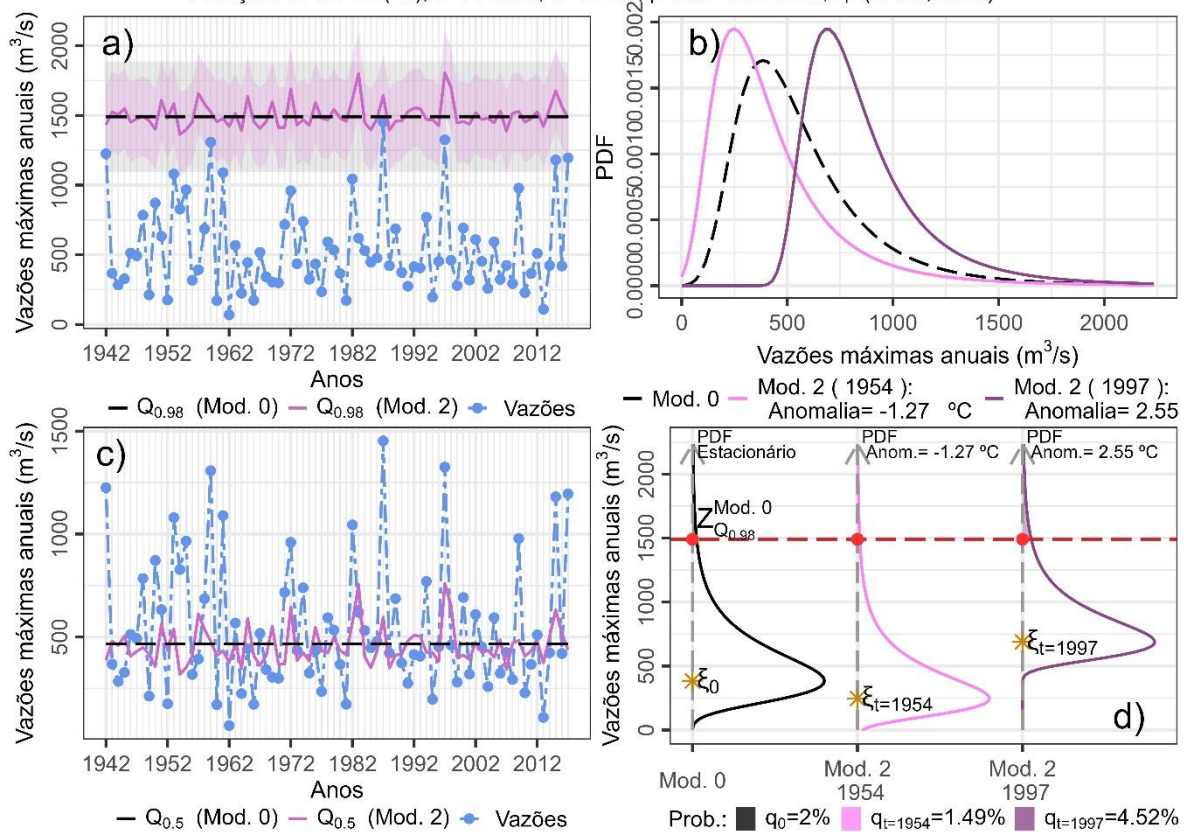
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 75295000(25), n=44 anos, $\kappa=0.0925$, p-valor=0.00288, $r_1=(0.0924,0.365)$



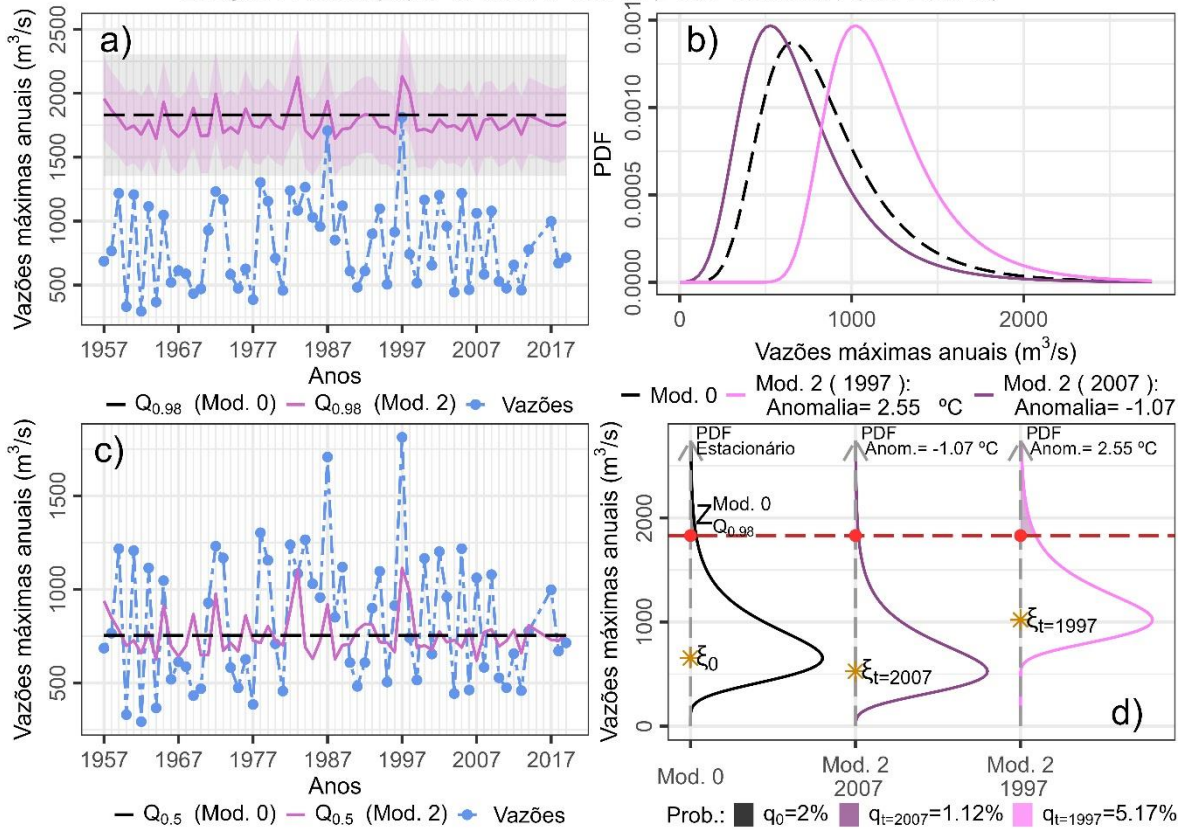
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 75400000(26), n=76 anos, $\kappa=-0.204$, p-valor=0.000898, $r_1=(0.154,0.433)$



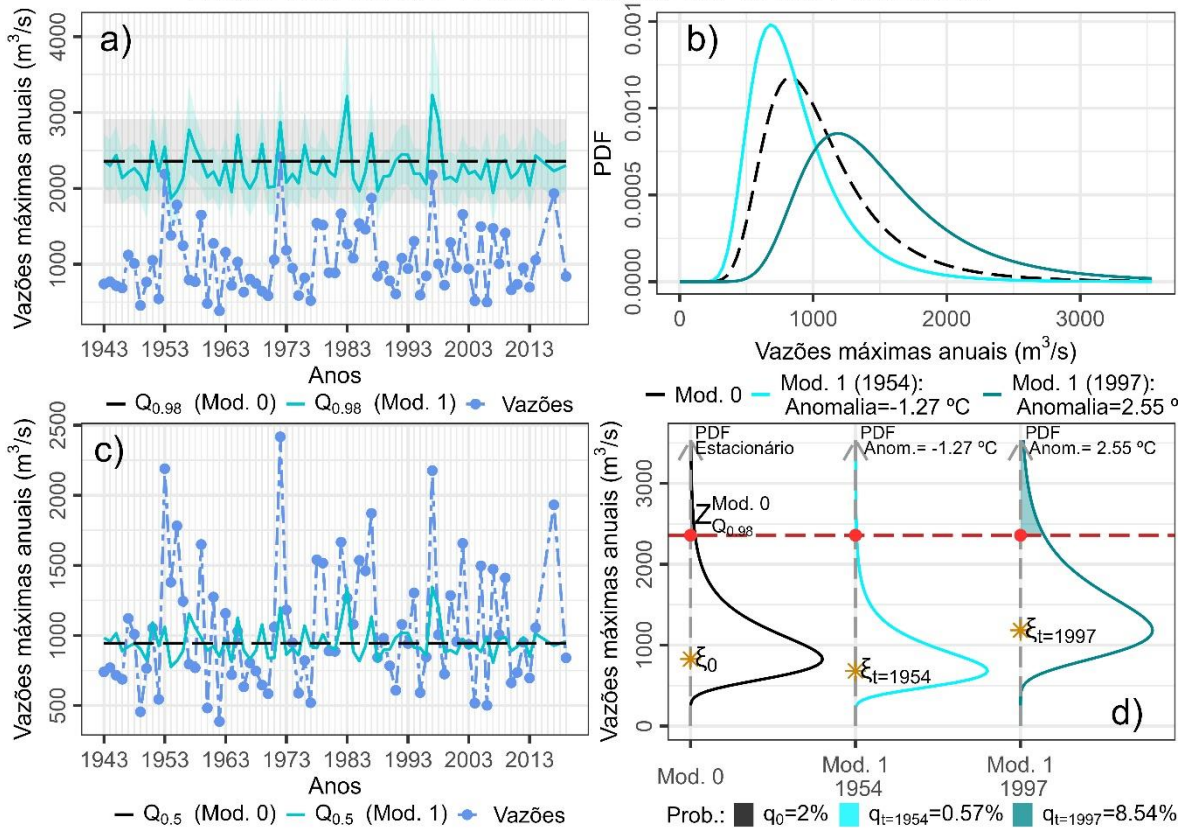
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 75450000(27), n=61 anos, $\kappa=-0.0646$, p-valor=0.00569, $r_1=(0.0745,0.332)$



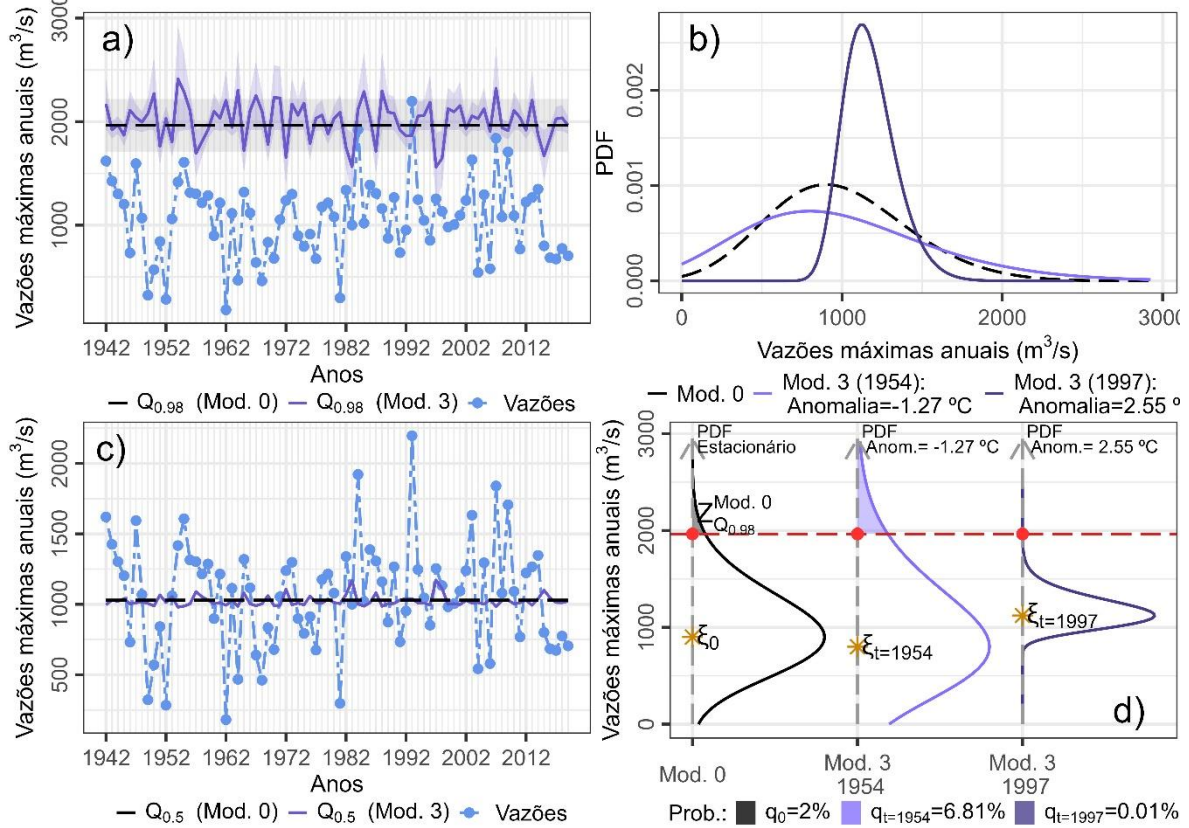
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 75500000(28), n=74 anos, $\kappa=-0.0986$, p-valor=0.0133, $r_1=(0.0324,0.276)$



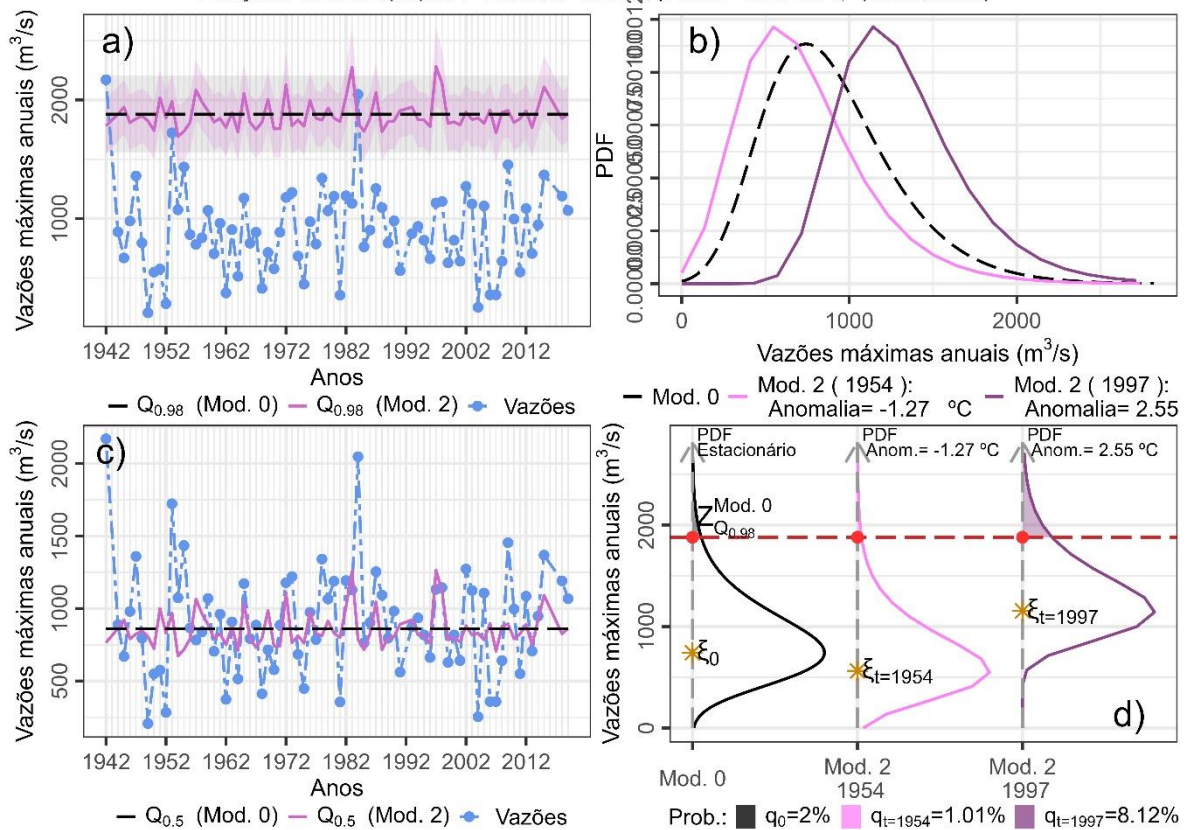
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 76100000(29), n=78 anos, $\kappa=84.8$, p-valor=0.00513, $r_1=(0.0158, 0.171)$, $\beta_1=(-0.419, -0.113)$



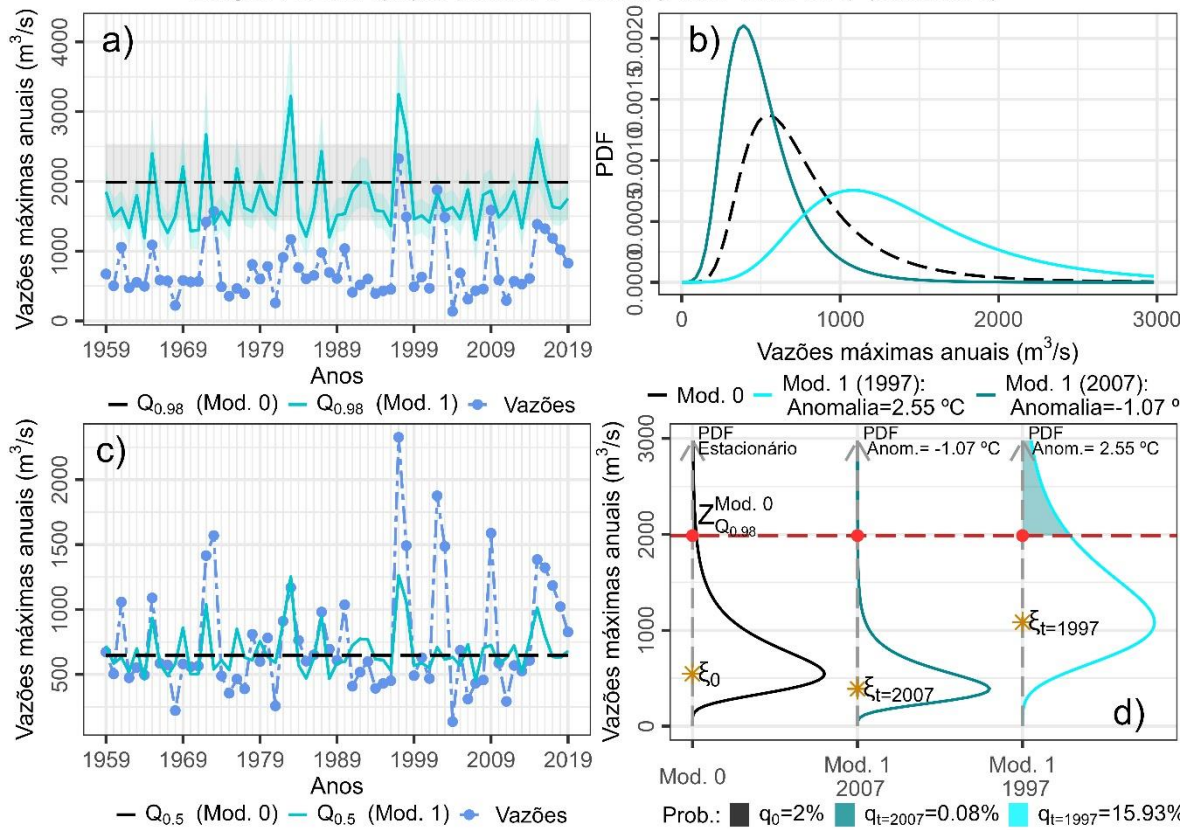
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 76440000(30), n=74 anos, $\kappa=0.0233$, p-valor=0.00398, $r_1=(0.079, 0.328)$



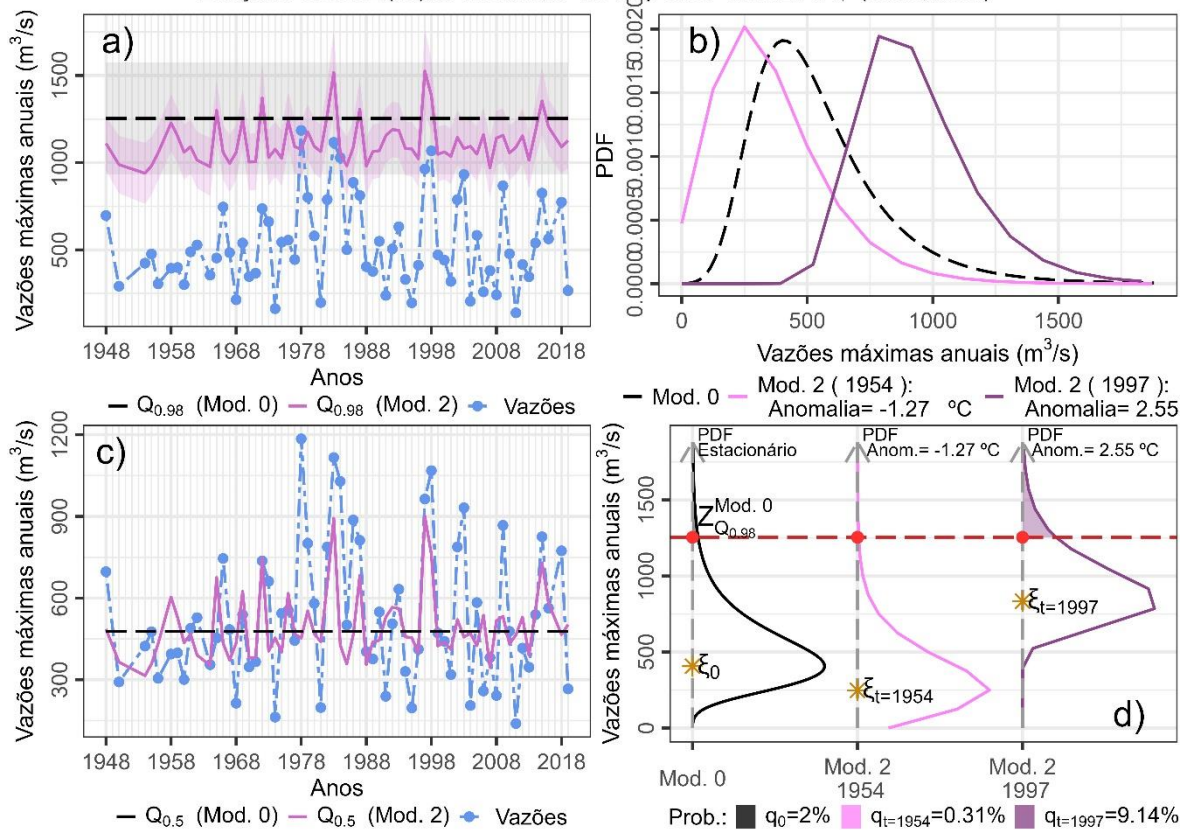
Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 76460000(31), n=61 anos, $\kappa=-0.0655$, p-valor=7.31e-05, $r_1=(0.173,0.474)$



Anomalia Anual do ENOS na TSM na Região do Niño 1+2

Estação: 76650000(32), n=65 anos, $\kappa=0.015$, p-valor=0.000284, $r_1=(0.185,0.506)$



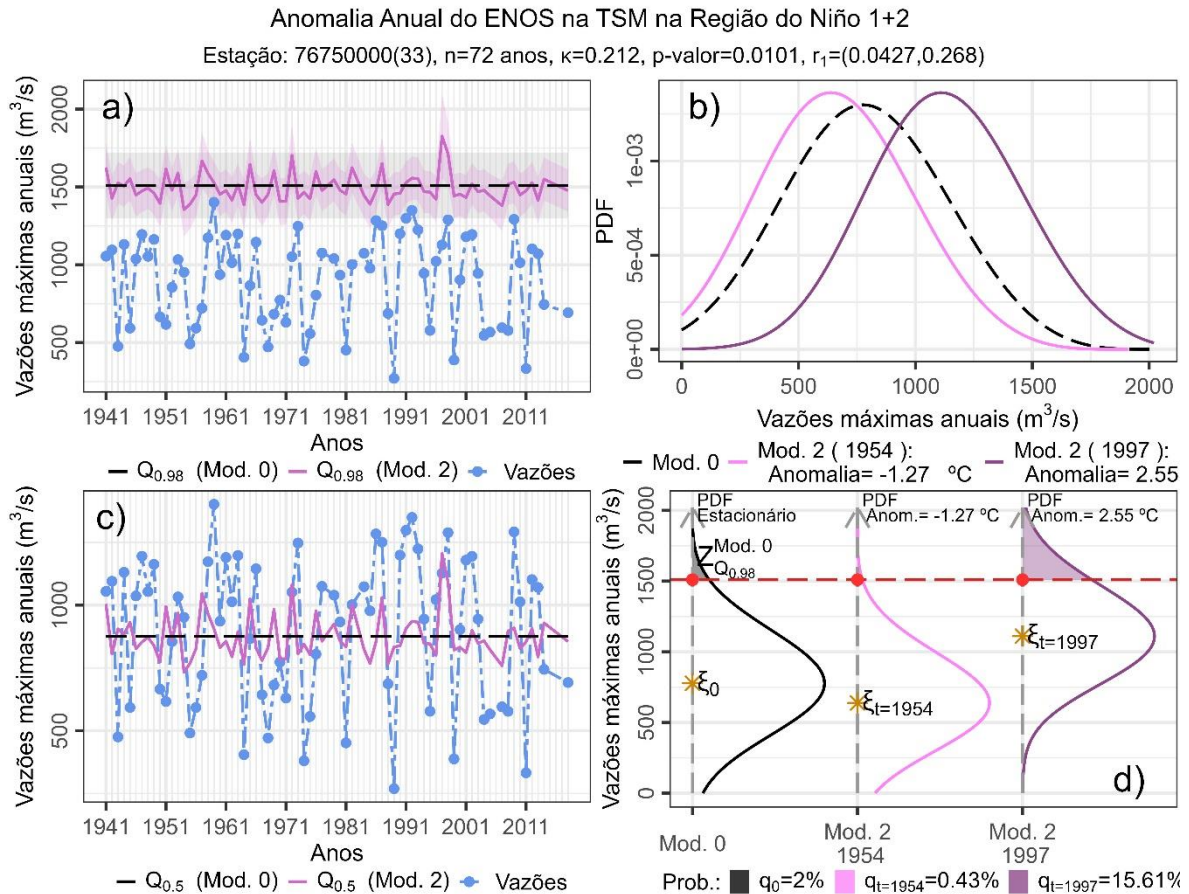
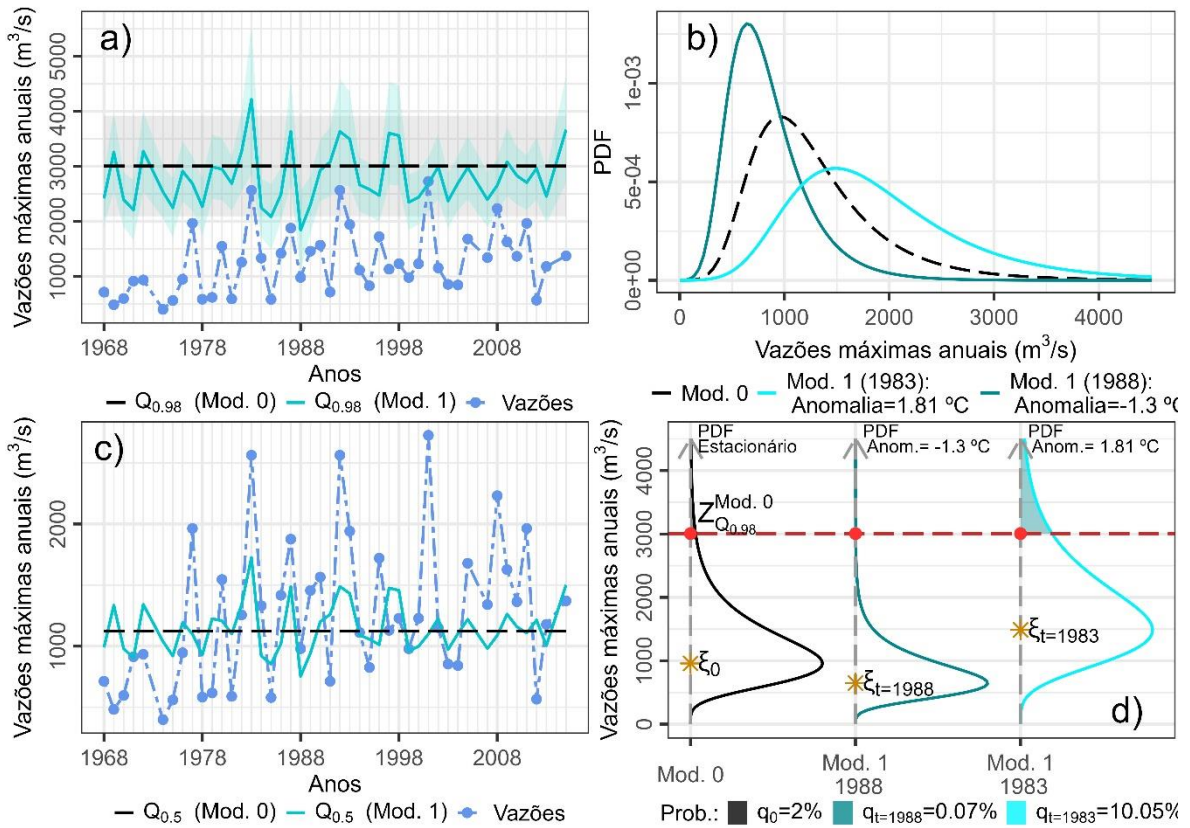


Figura 0.7 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável ENOS na região El Niño 1+2. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em azul-claro), Modelo 2 (não estacionário, em rosa-claro), ou Modelo 3 (não estacionário, em roxo-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 1: azul-claro; Modelo 2: rosa-claro, Modelo 3: roxo-claro) e a maior anomalia (Modelo 1: azul-escuro; Modelo 2: rosa-escuro, Modelo 3: roxo-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (azul-claro), Modelo 2 (em rosa-claro), ou Modelo 3 (roxo-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.

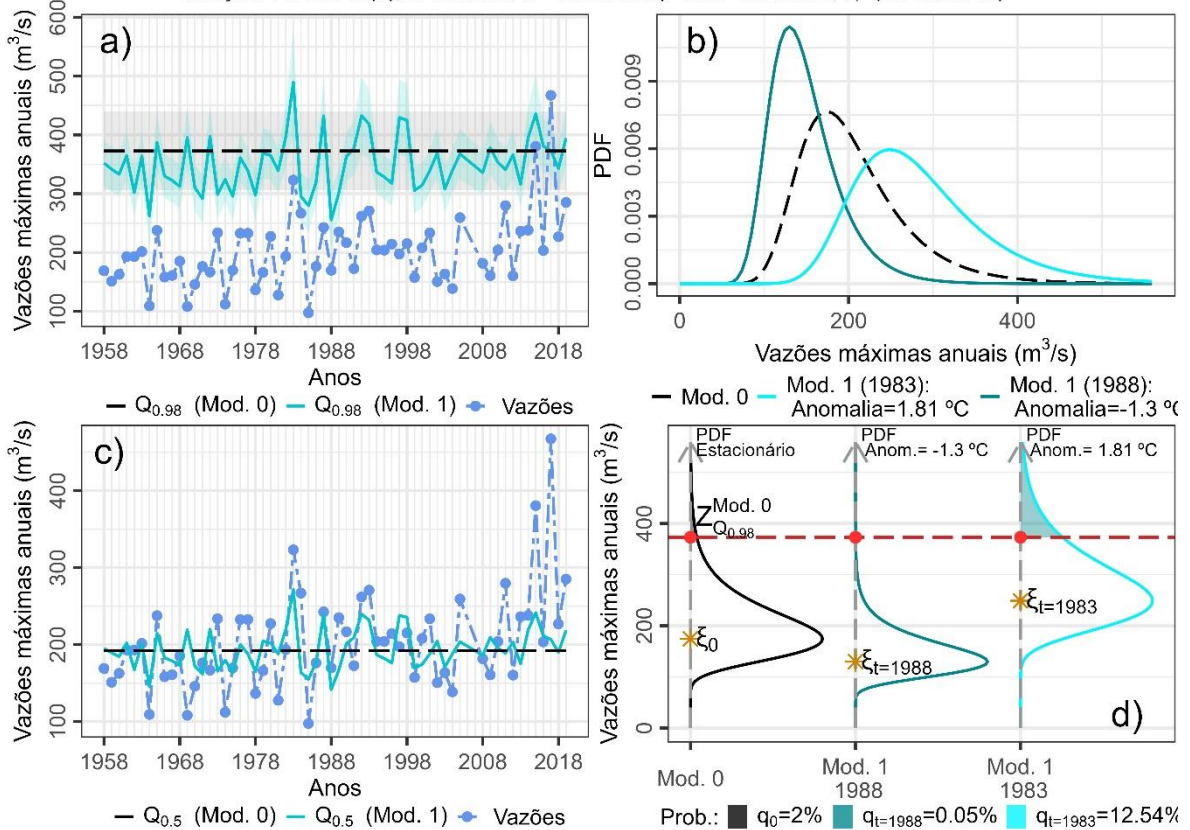
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 70200000(1), n=45 anos, $\kappa=-0.0392$, p-valor=0.00911, $r_1=(0.0791, 0.461)$



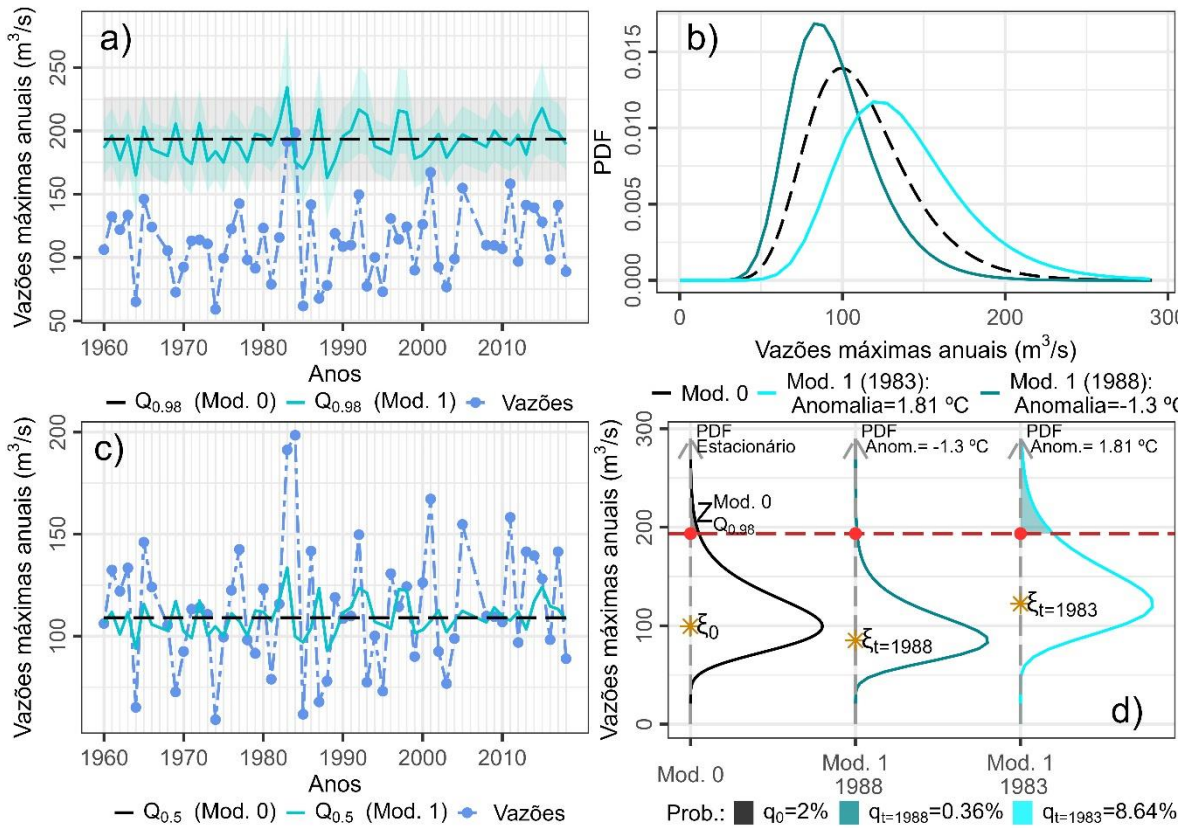
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 71200000(2), n=60 anos, $\kappa=-0.000282$, p-valor=0.000268, $r_1=(0.108, 0.319)$



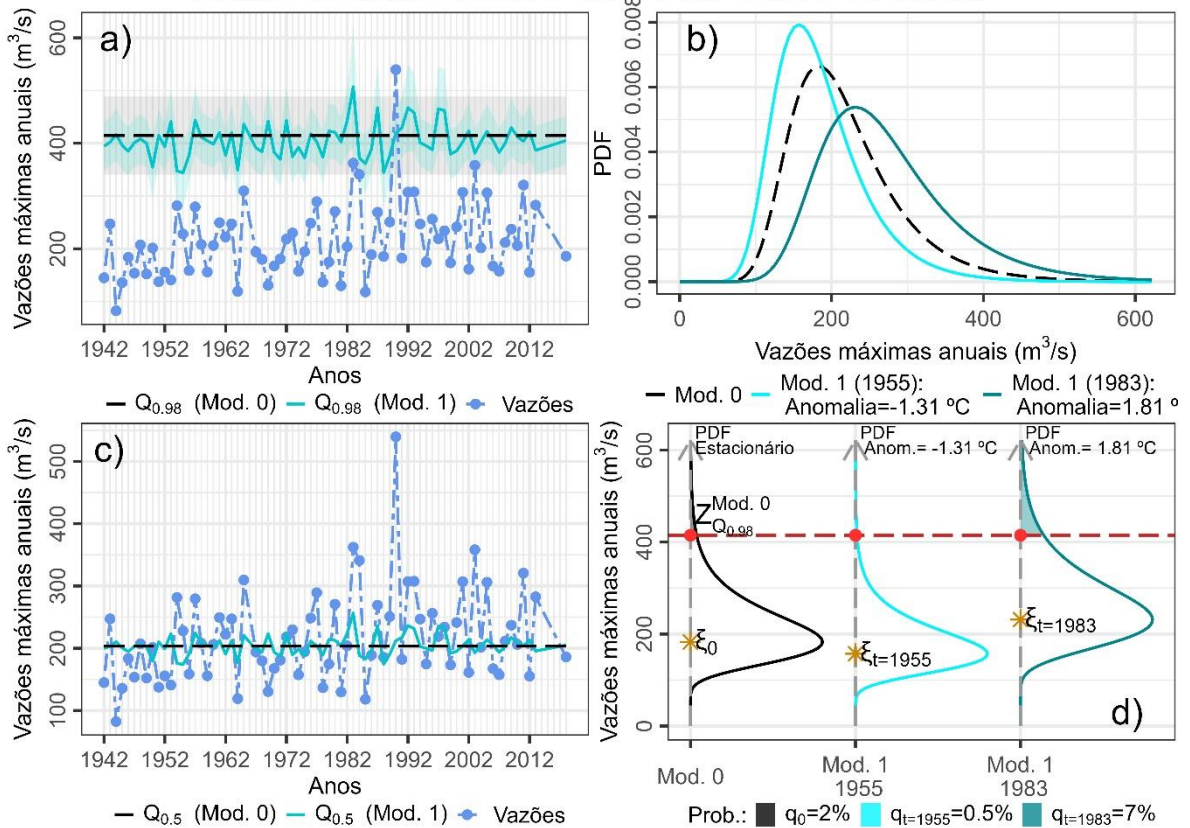
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 71250000(3), n=56 anos, $\kappa=0.0434$, p-valor=0.0431, $r_1=(0.00558,0.233)$



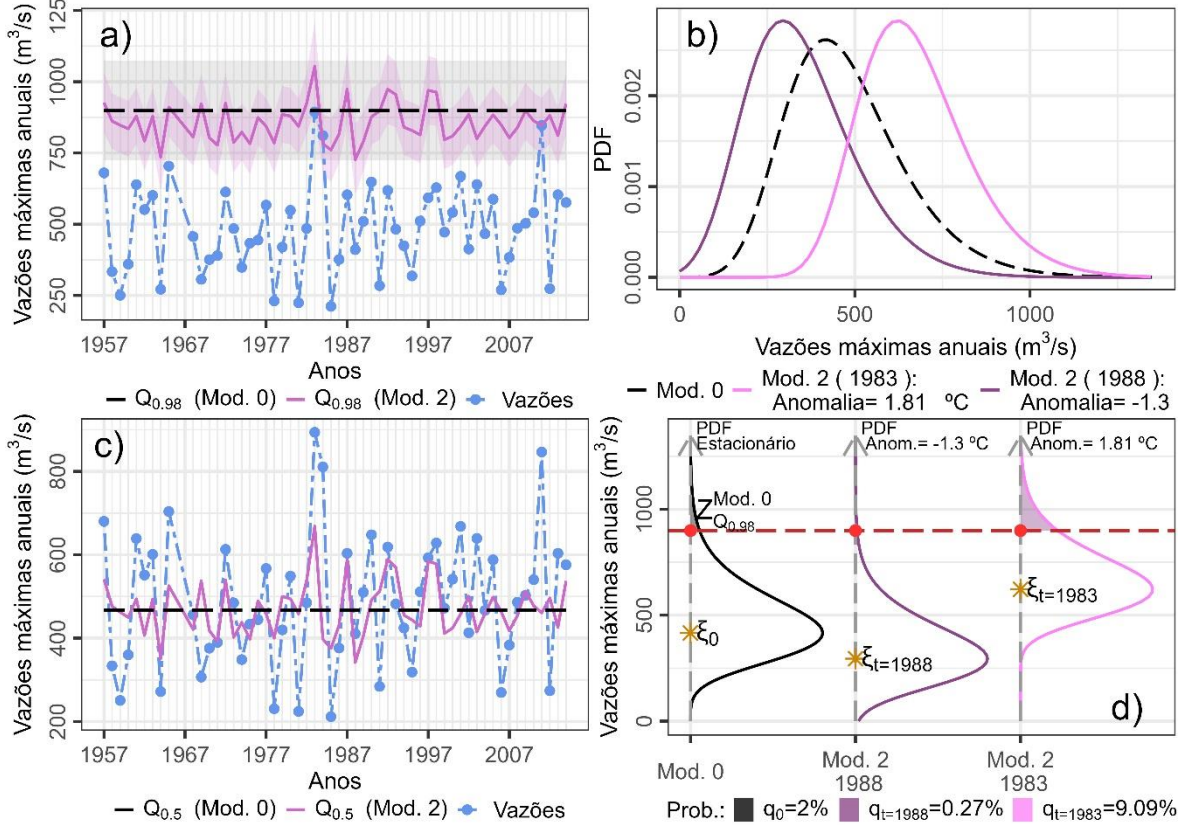
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 71300000(4), n=72 anos, $\kappa=-0.0168$, p-valor=0.0381, $r_1=(0.0111,0.242)$



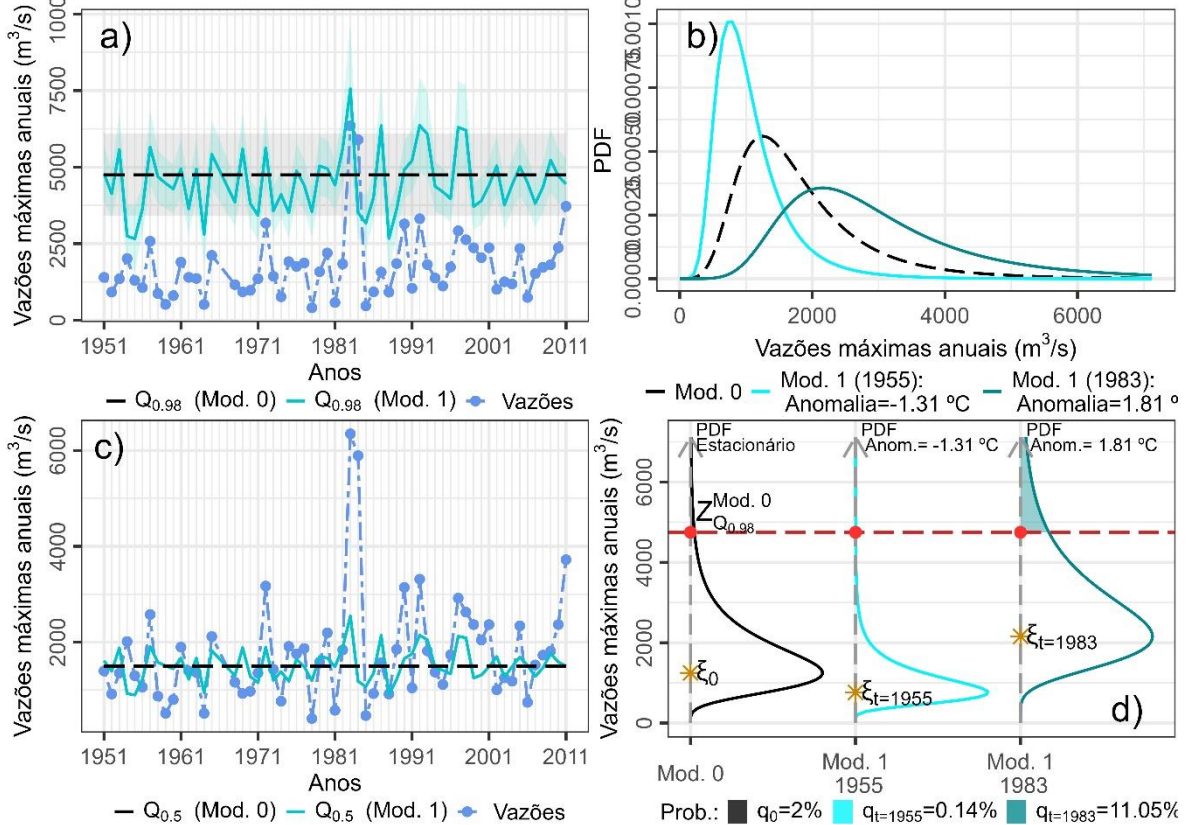
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 71383000(5), n=56 anos, $\kappa=0.0852$, p-valor=0.00183, $r_1=(0.0981,0.389)$



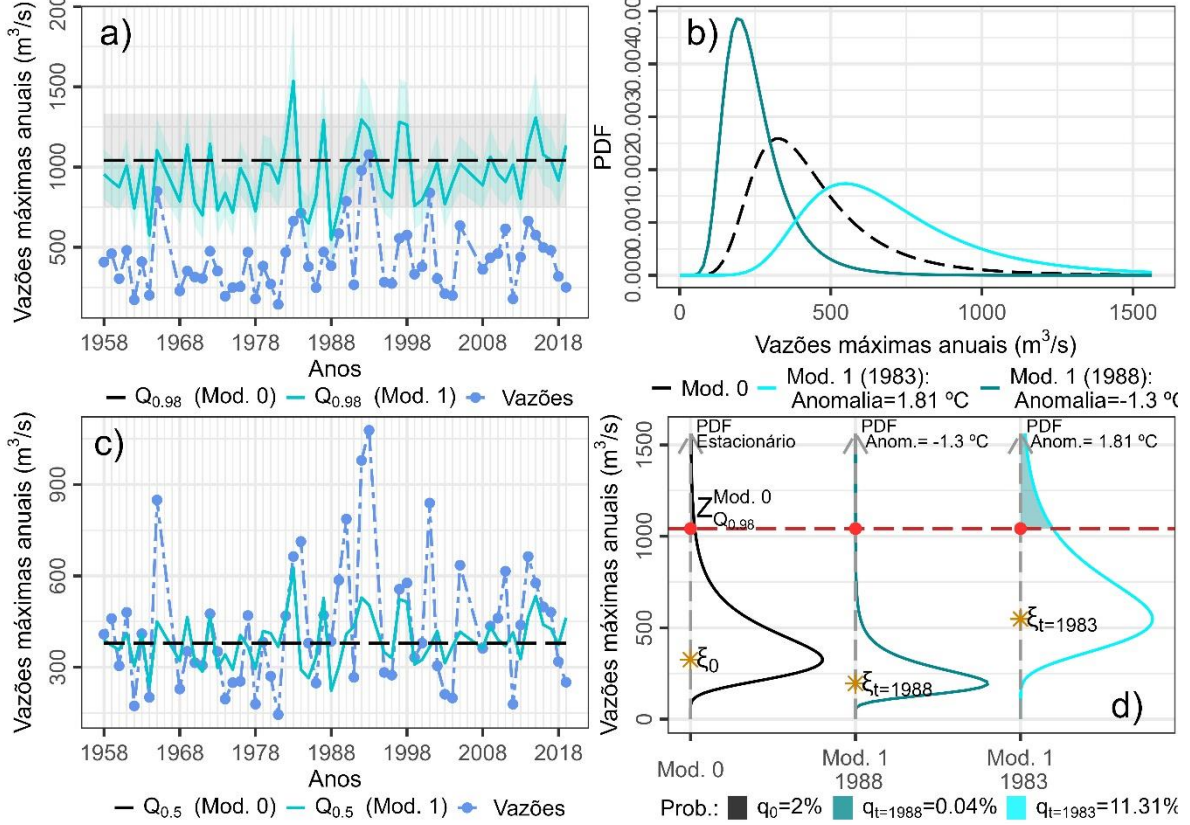
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 71550000(6), n=59 anos, $\kappa=-0.144$, p-valor=0.000655, $r_1=(0.168,0.499)$



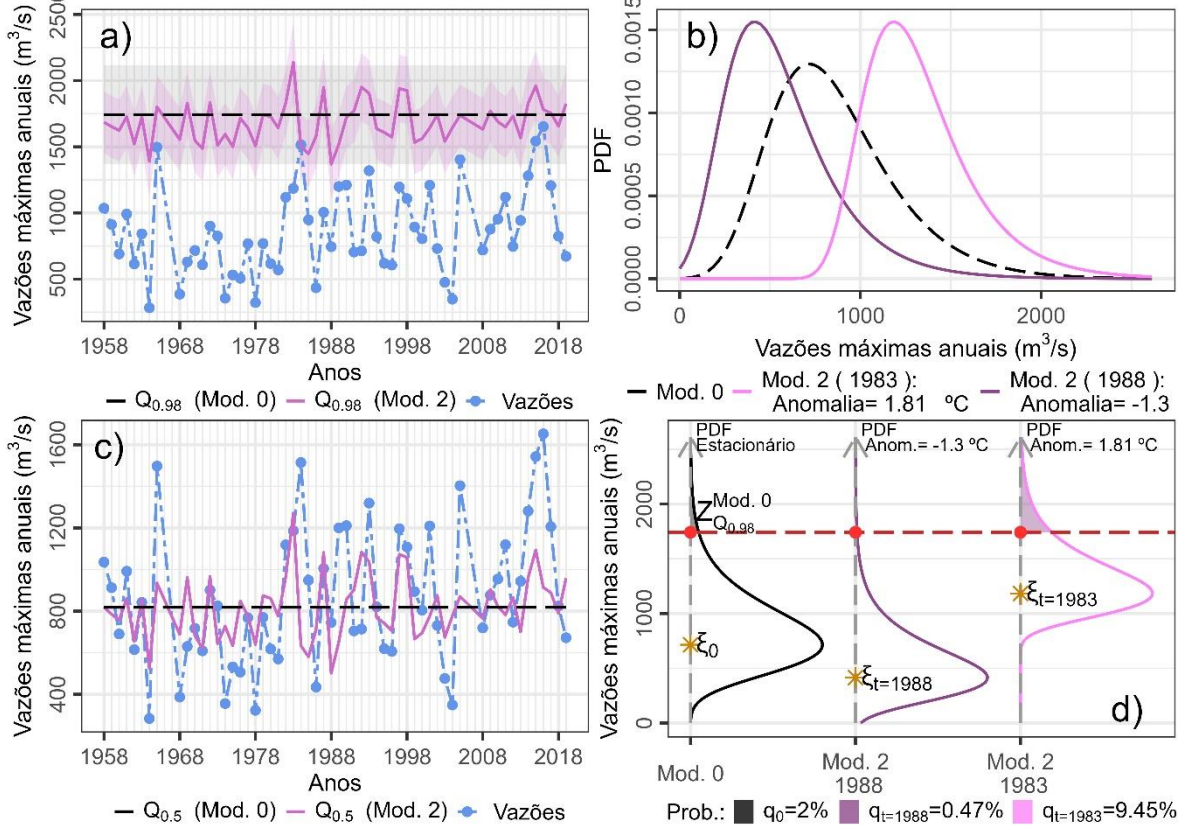
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 72430000(7), n=57 anos, $\kappa=-0.0887$, p-valor=0.000114, $r_1=(0.184,0.478)$



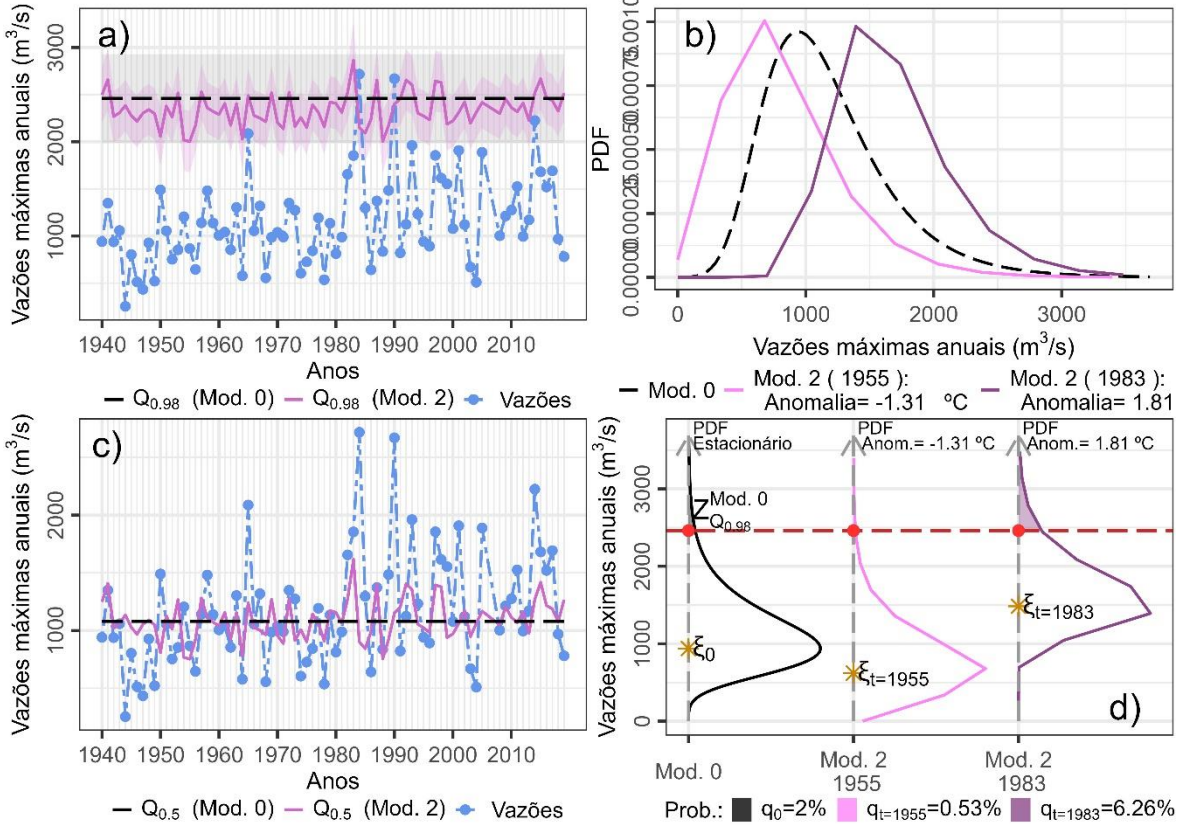
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 72630000(8), n=58 anos, $\kappa=-0.0152$, p-valor=2.53e-05, $r_1=(0.199,0.473)$



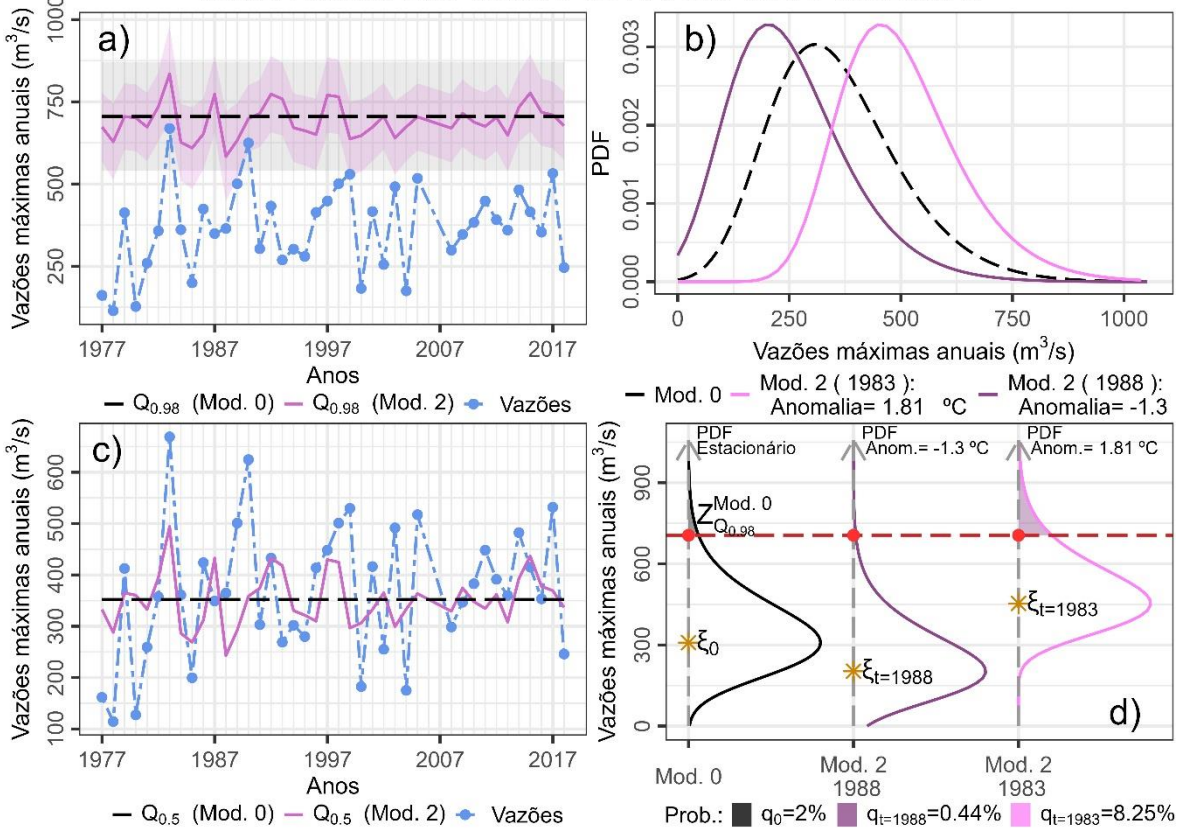
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 72680000(9), n=78 anos, $\kappa=0.011$, p-valor=0.000835, $r_1=(0.126, 0.438)$



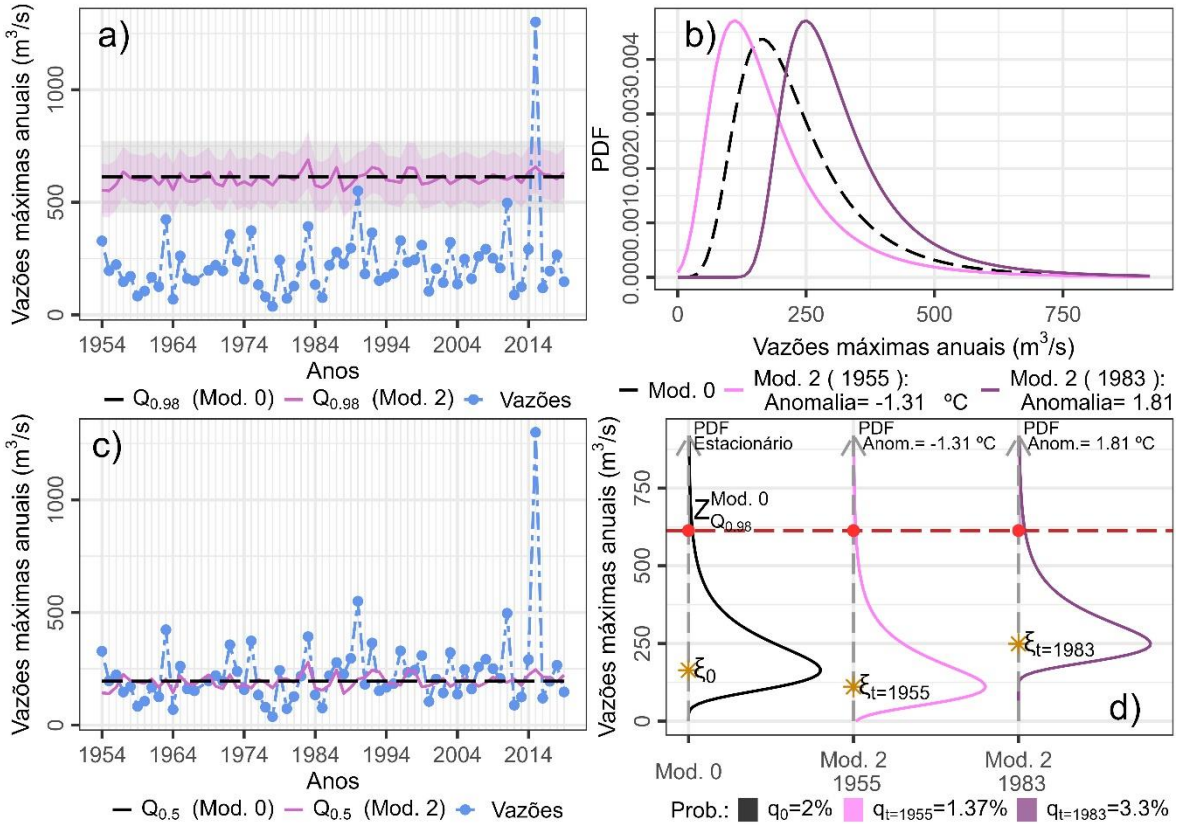
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 73780000(12), n=40 anos, $\kappa=0.0716$, p-valor=0.016, $r_1=(0.0521, 0.473)$



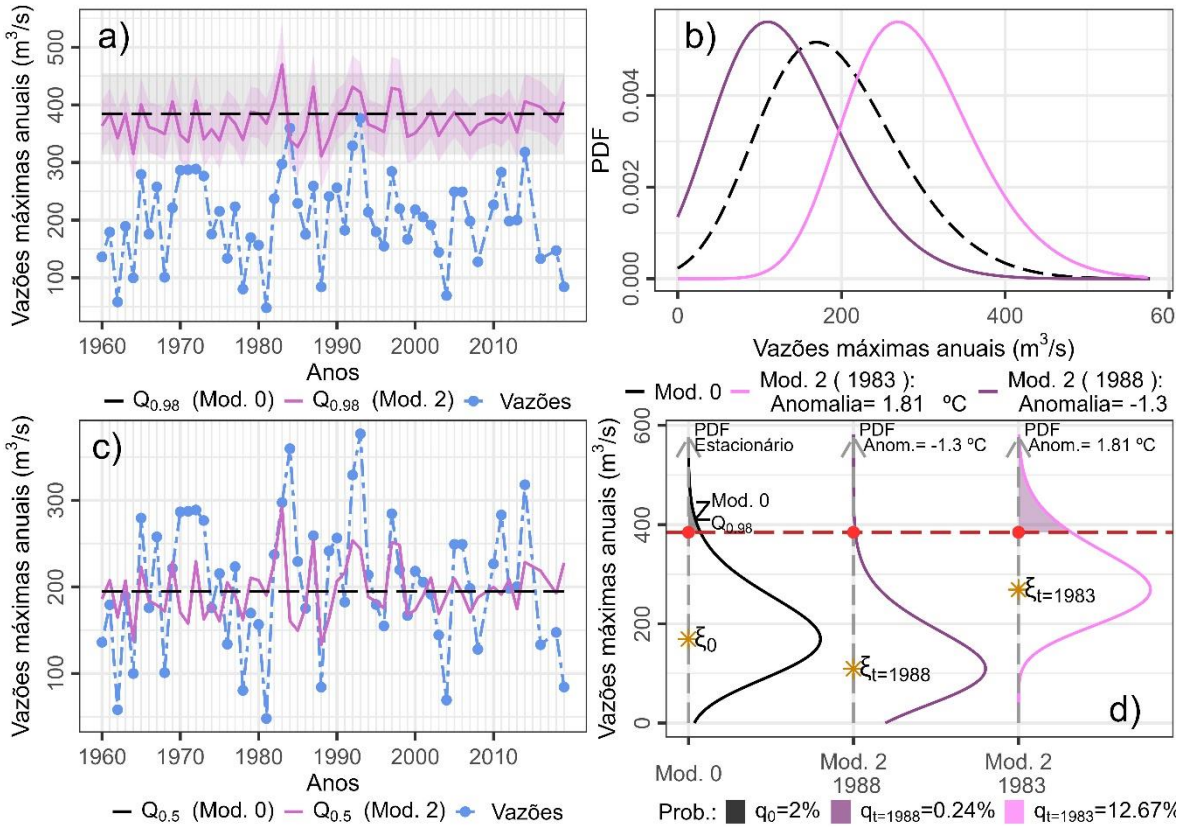
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 73900000(13), n=65 anos, $\kappa=-0.178$, p-valor=0.0129, $r_1=(0.0645,0.46)$



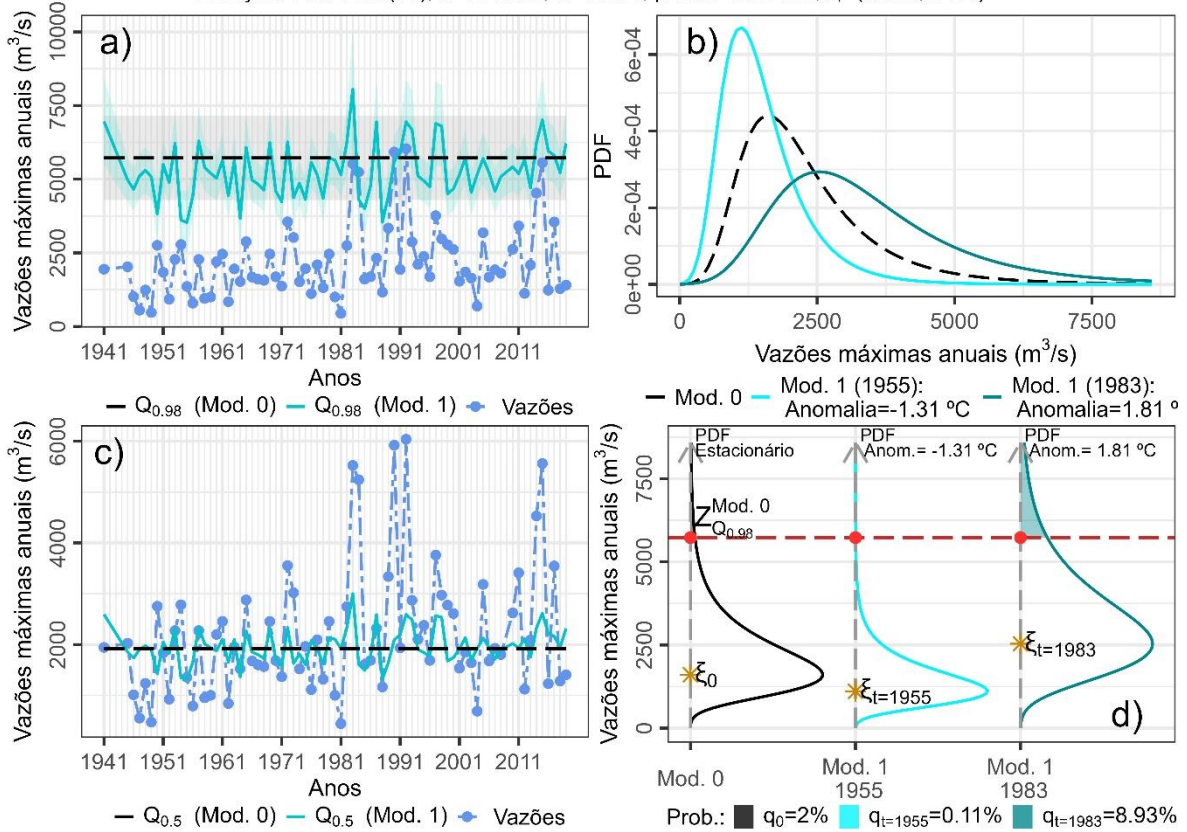
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 74205000(14), n=57 anos, $\kappa=0.129$, p-valor=0.00192, $r_1=(0.117,0.464)$



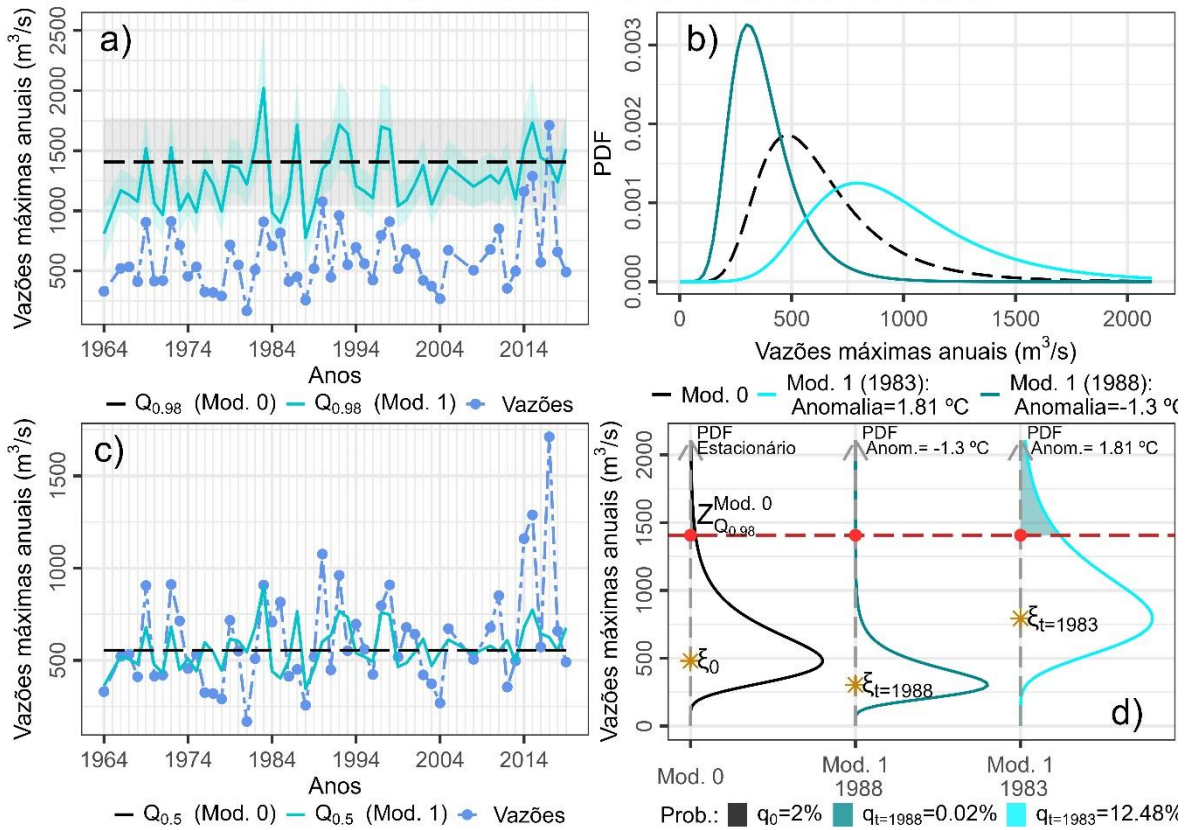
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 74270000(15), n=75 anos, $\kappa=-0.061$, p-valor=0.00105, $r_1=(0.124,0.411)$



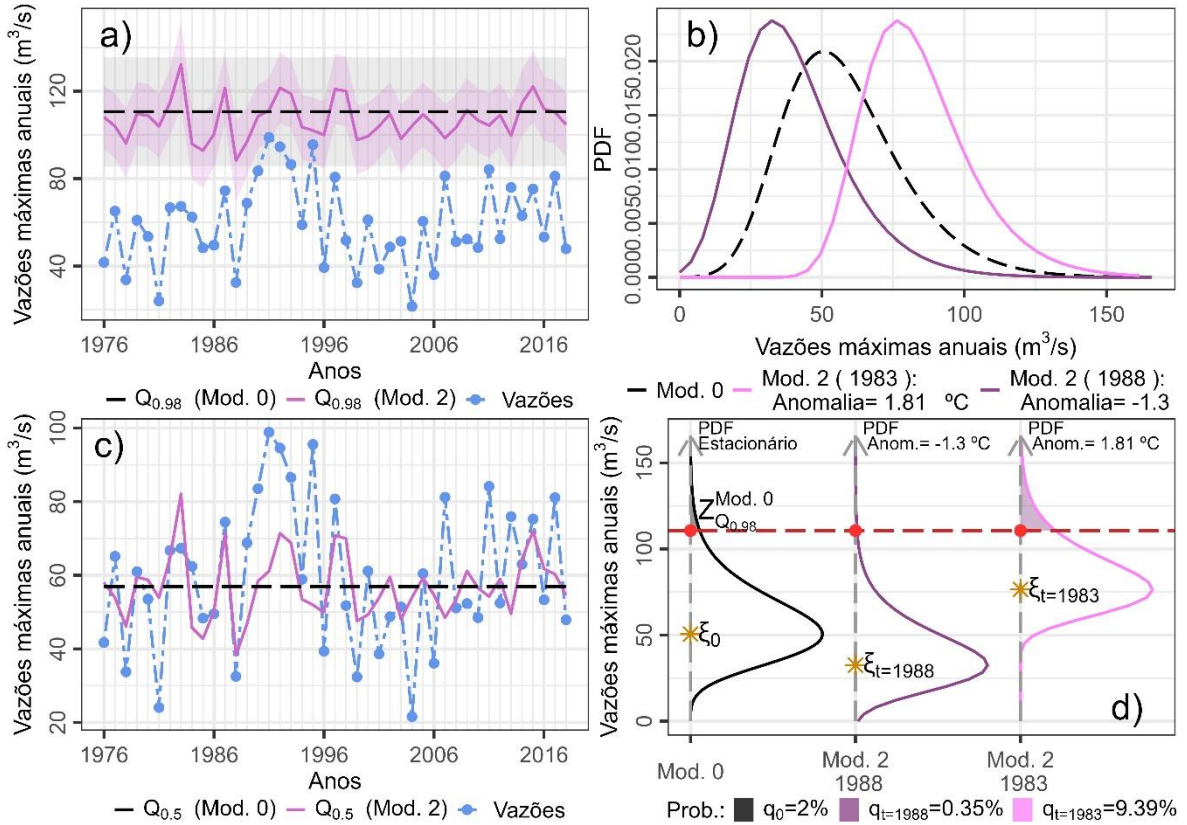
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 74370000(16), n=52 anos, $\kappa=-0.0336$, p-valor=0.000316, $r_1=(0.16,0.458)$



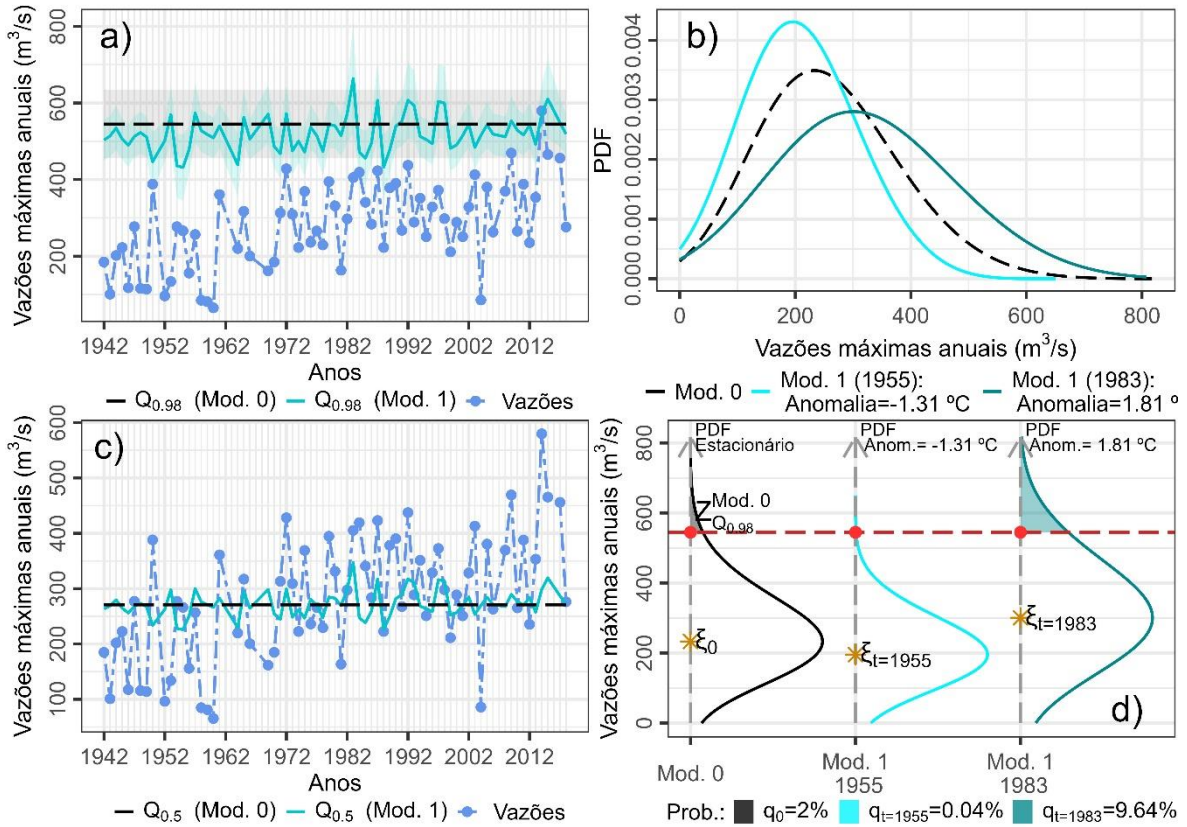
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 74460000(17), n=43 anos, $\kappa=0.0421$, p-valor=0.00141, $r_1=(0.121,0.433)$



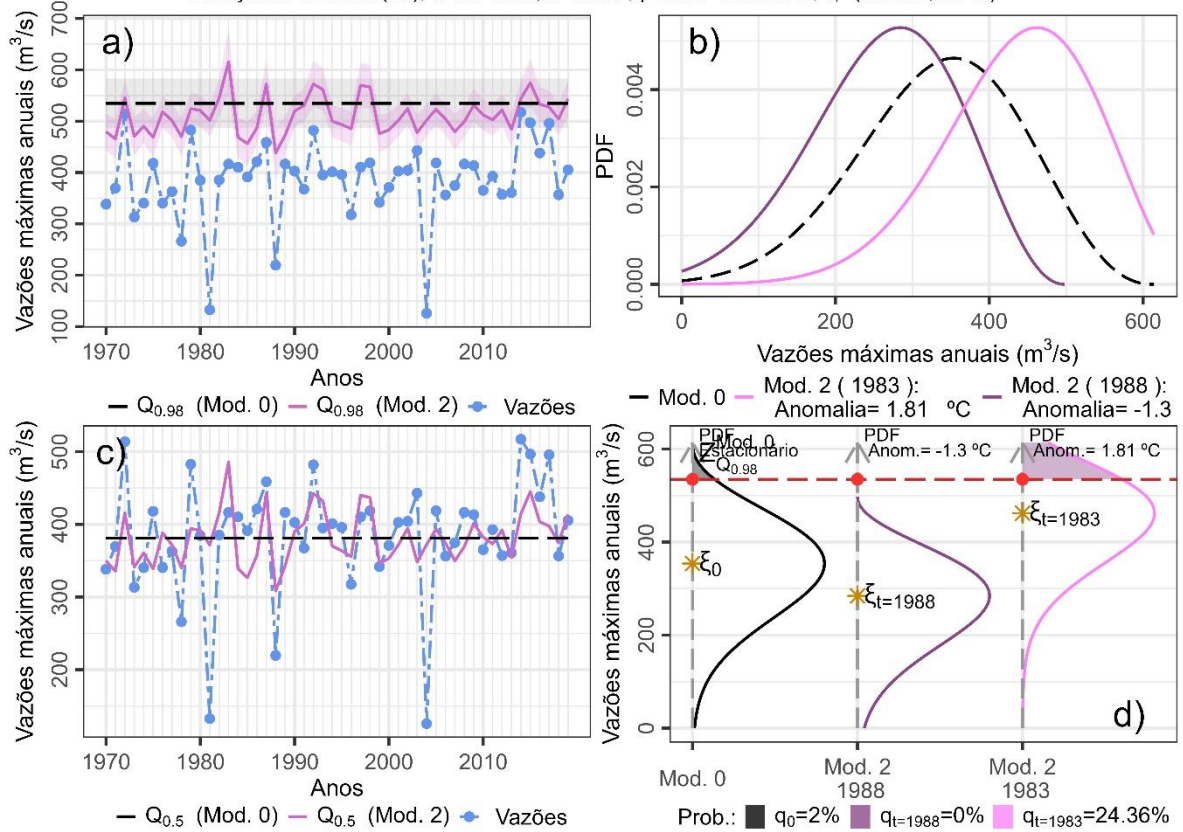
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 74700000(18), n=70 anos, $\kappa=0.188$, p-valor=0.0286, $r_1=(0.0214,0.26)$



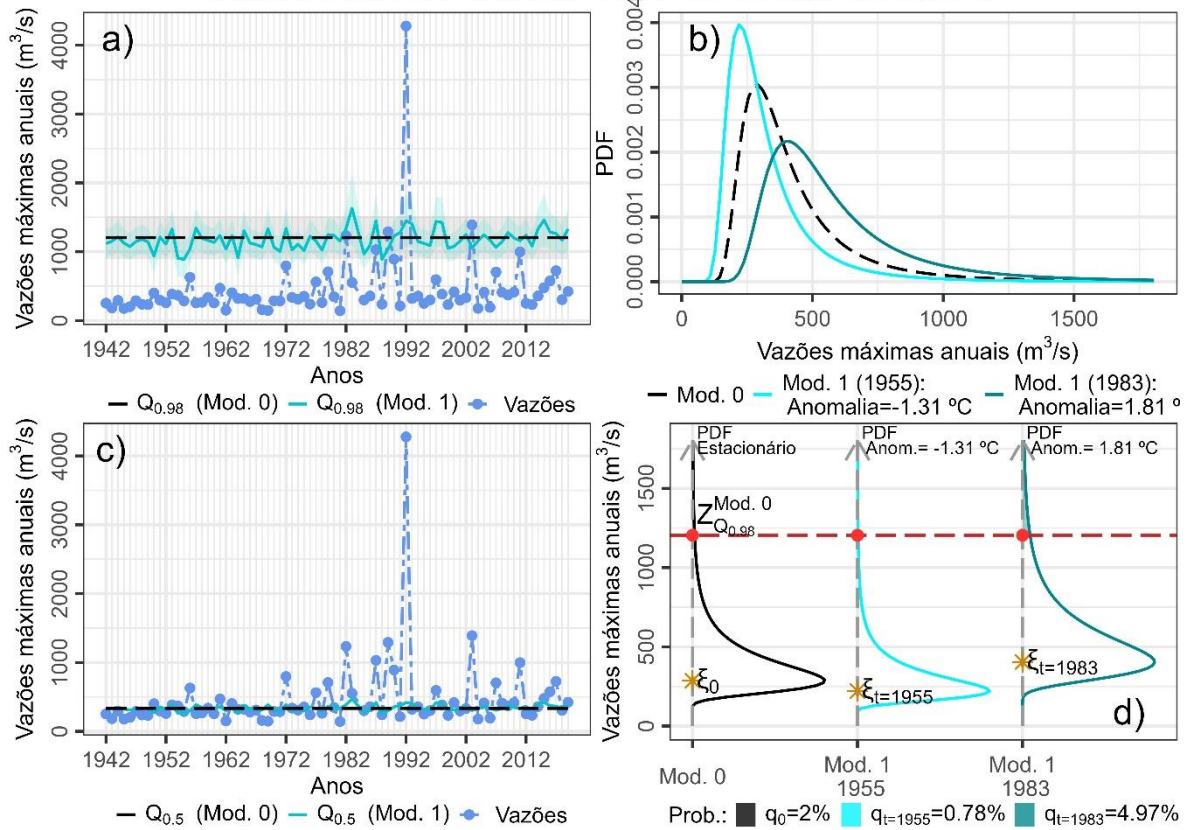
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 74900000(20), n=50 anos, $\kappa=0.327$, p-valor=0.000721, $r_1=(0.0732,0.245)$



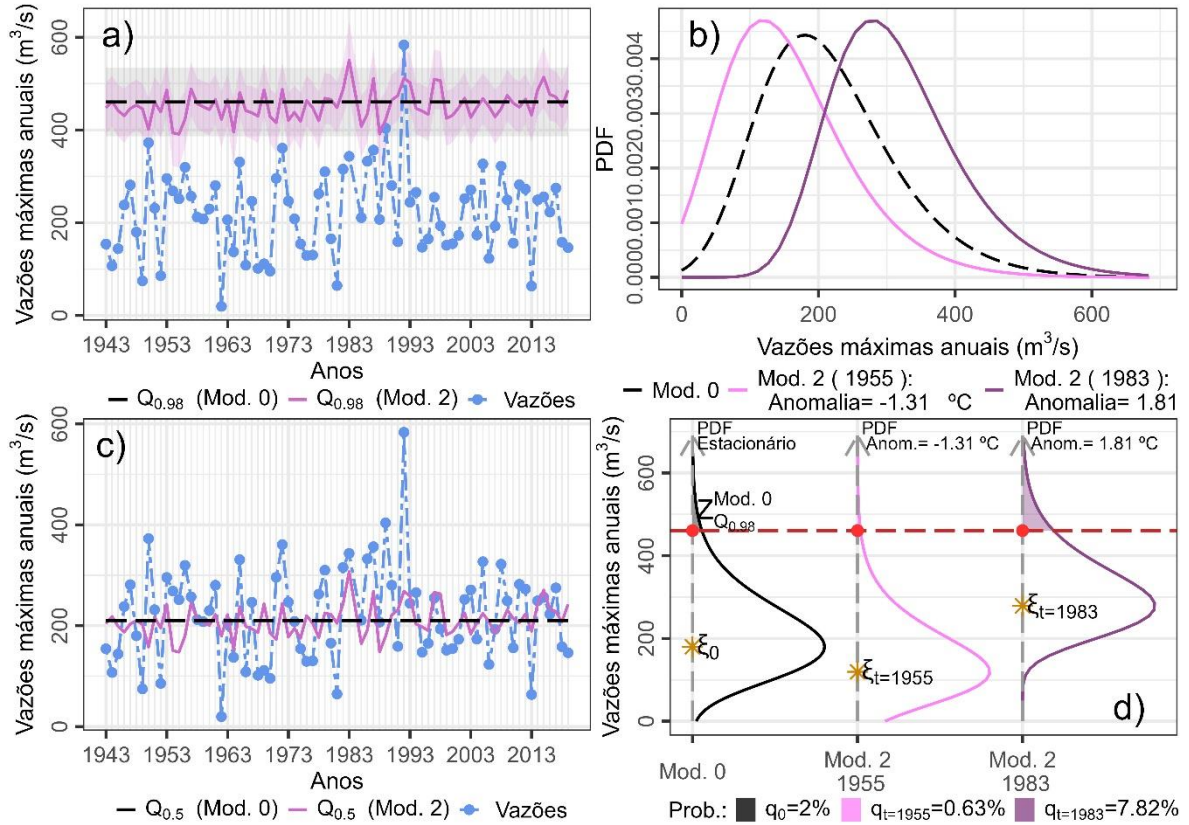
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 75155000(21), n=77 anos, $\kappa=-0.289$, p-valor=0.0212, $r_1=(0.0362,0.358)$



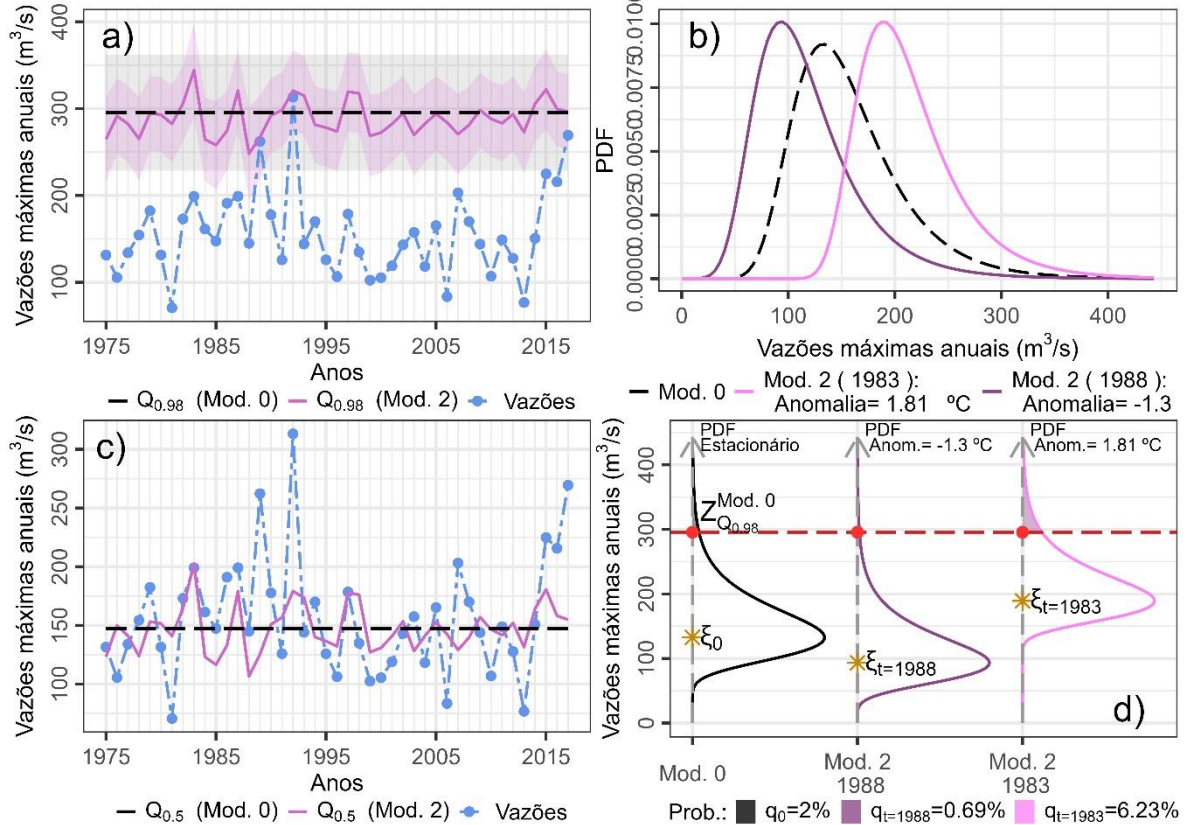
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 75200000(22), n=76 anos, $\kappa=0.0605$, p-valor=0.00662, $r_1=(0.0862,0.463)$



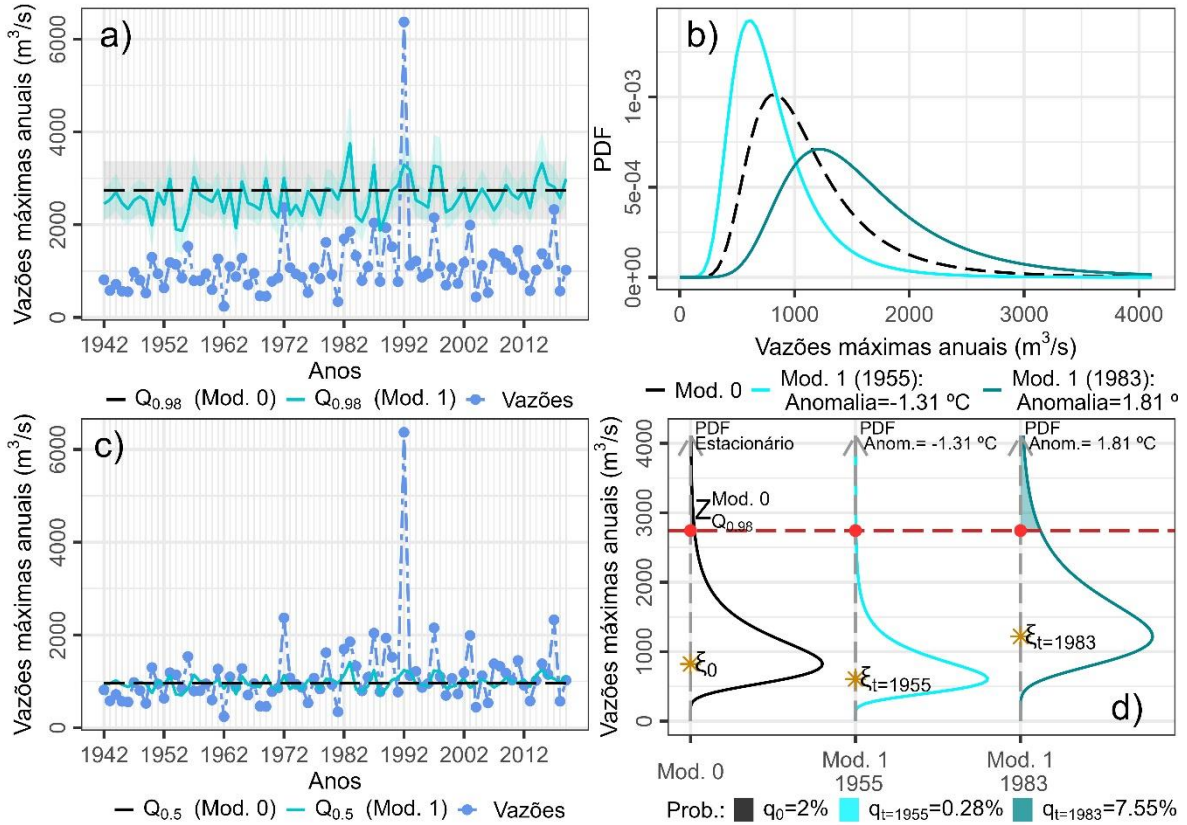
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 75205000(23), n=43 anos, $\kappa=-0.0429$, p-valor=0.00986, $r_1=(0.0689,0.394)$



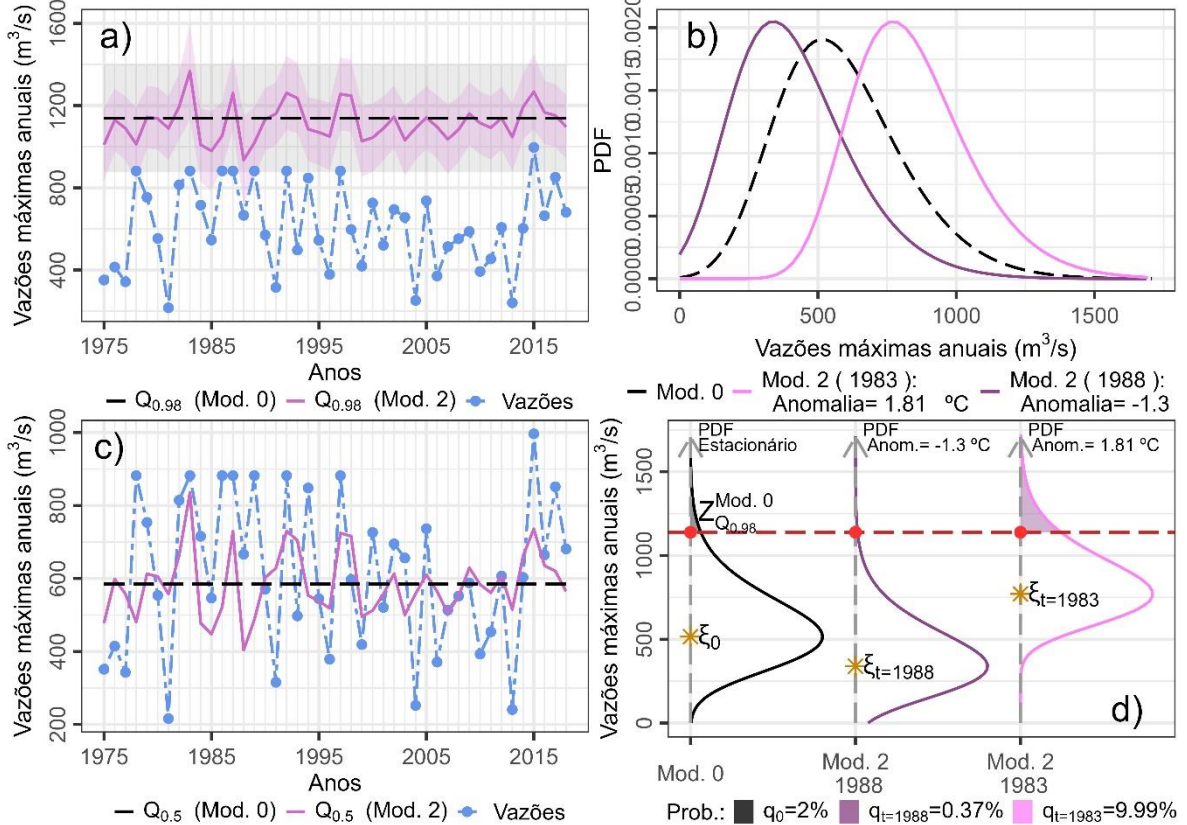
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 75230000(24), n=78 anos, $\kappa=-0.112$, p-valor=0.00379, $r_1=(0.0853,0.369)$



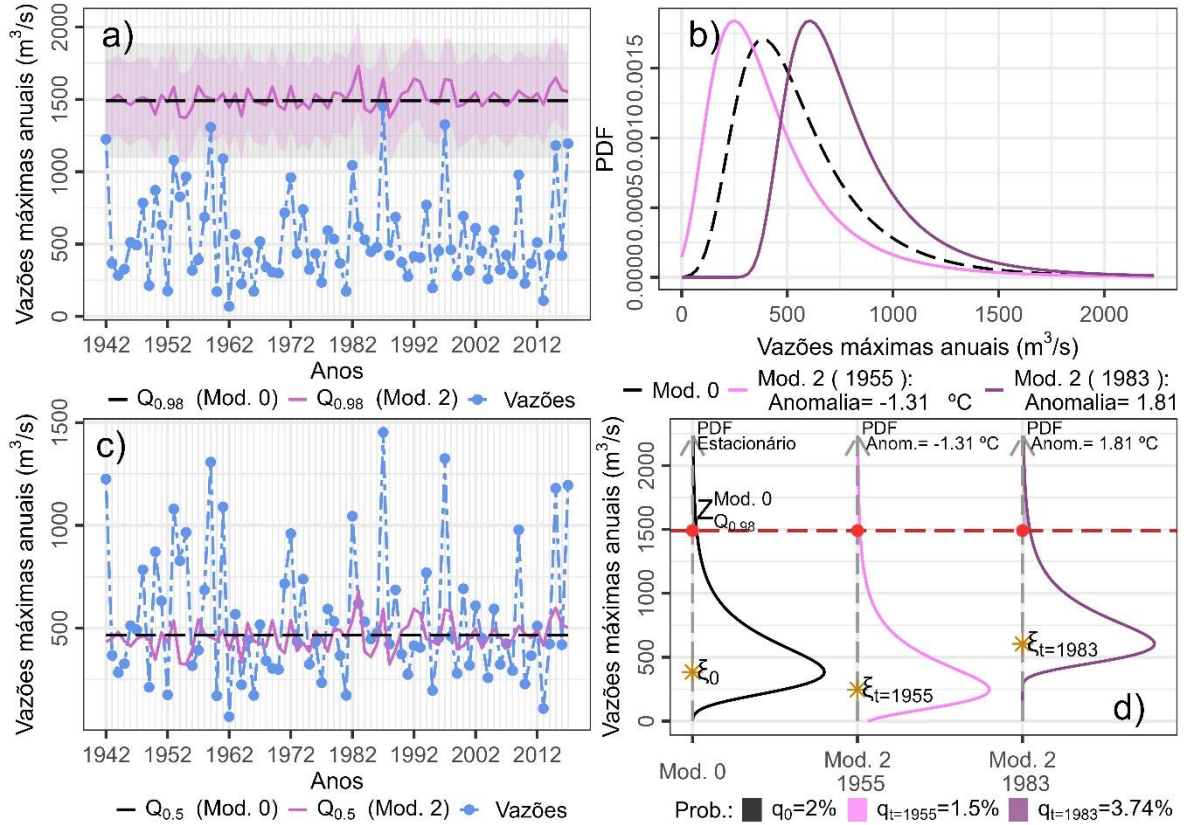
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 75295000(25), n=44 anos, $\kappa=0.0847$, p-valor=0.0137, $r_1=(0.0576,0.477)$



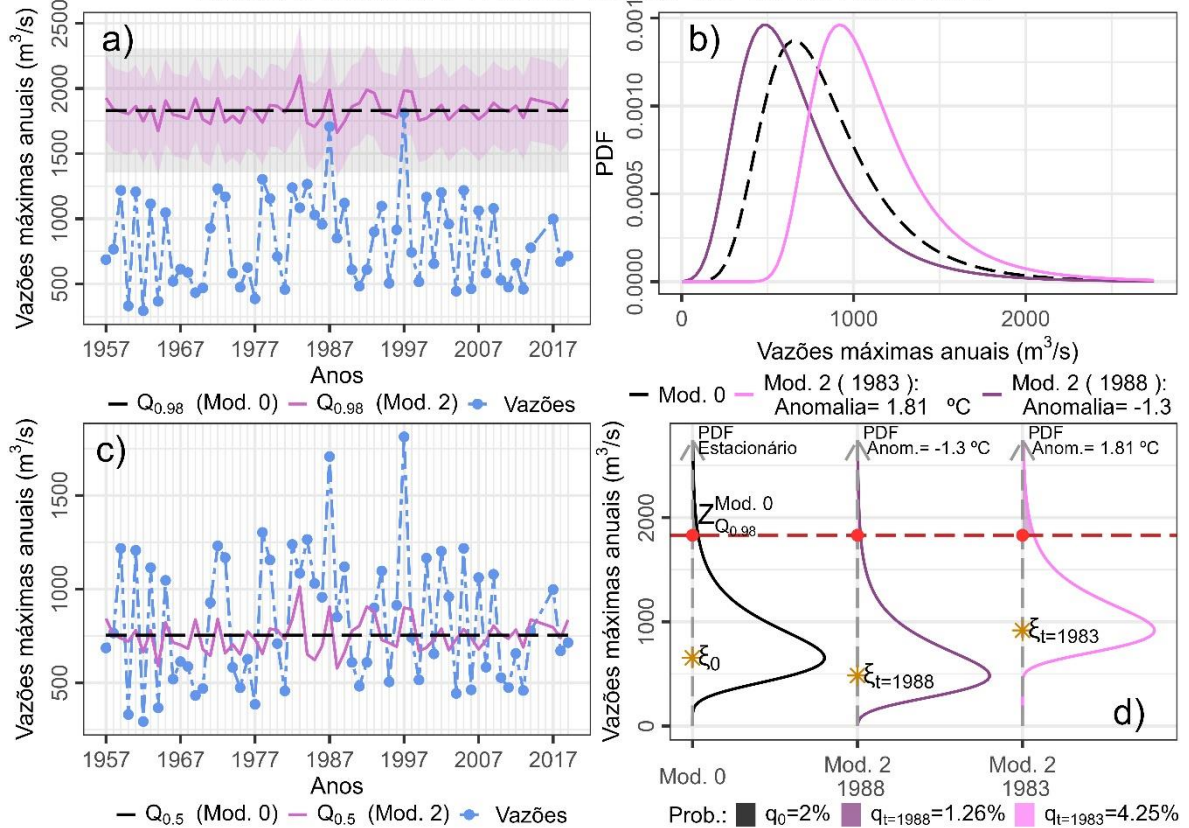
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 75400000(26), n=76 anos, $\kappa=-0.178$, p-valor=0.0169, $r_1=(0.0772,0.5)$



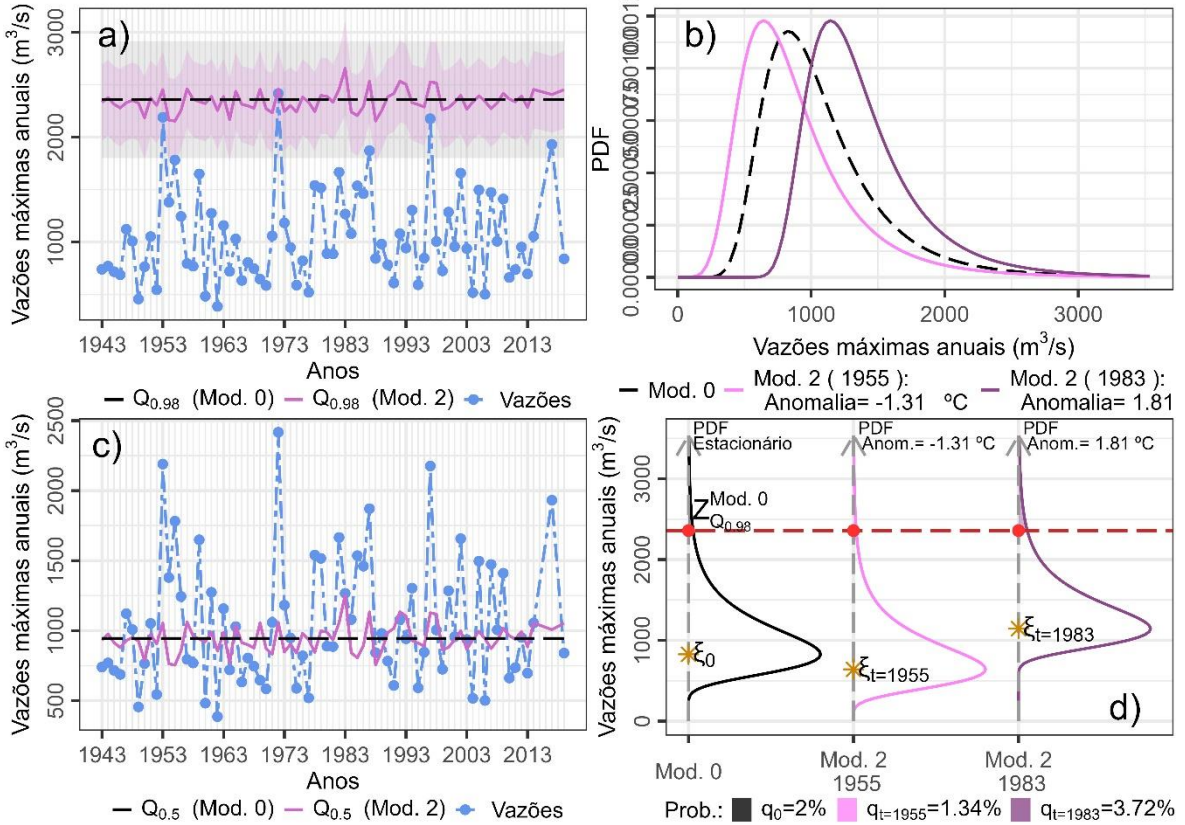
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 75450000(27), n=61 anos, $\kappa=-0.0905$, p-valor=0.0248, $r_1=(0.0394,0.38)$



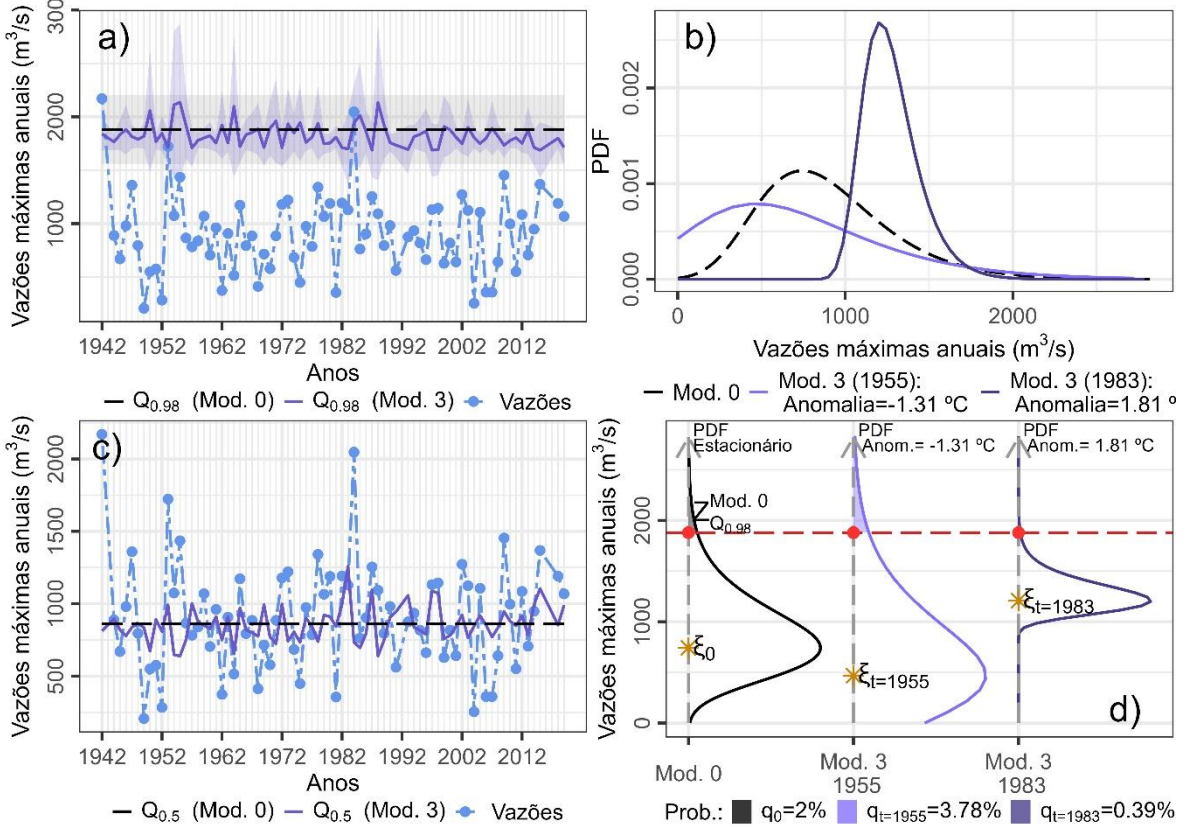
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 75500000(28), n=74 anos, $\kappa=-0.127$, p-valor=0.0328, $r_1=(0.0281,0.35)$



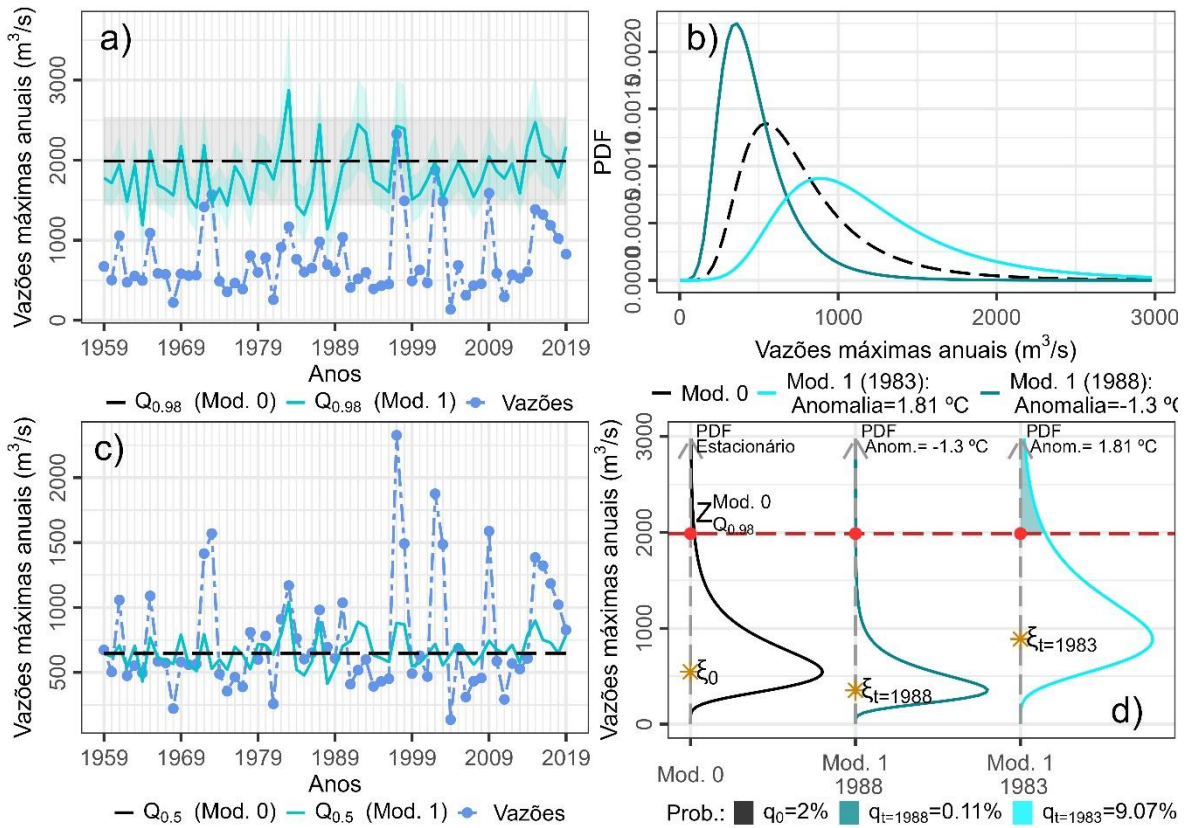
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 76440000(30), n=74 anos, $\kappa=237$, p-valor=0.00102, $r_1=(0.176,0.433)$, $\beta_1=(-0.521,-0.0684)$



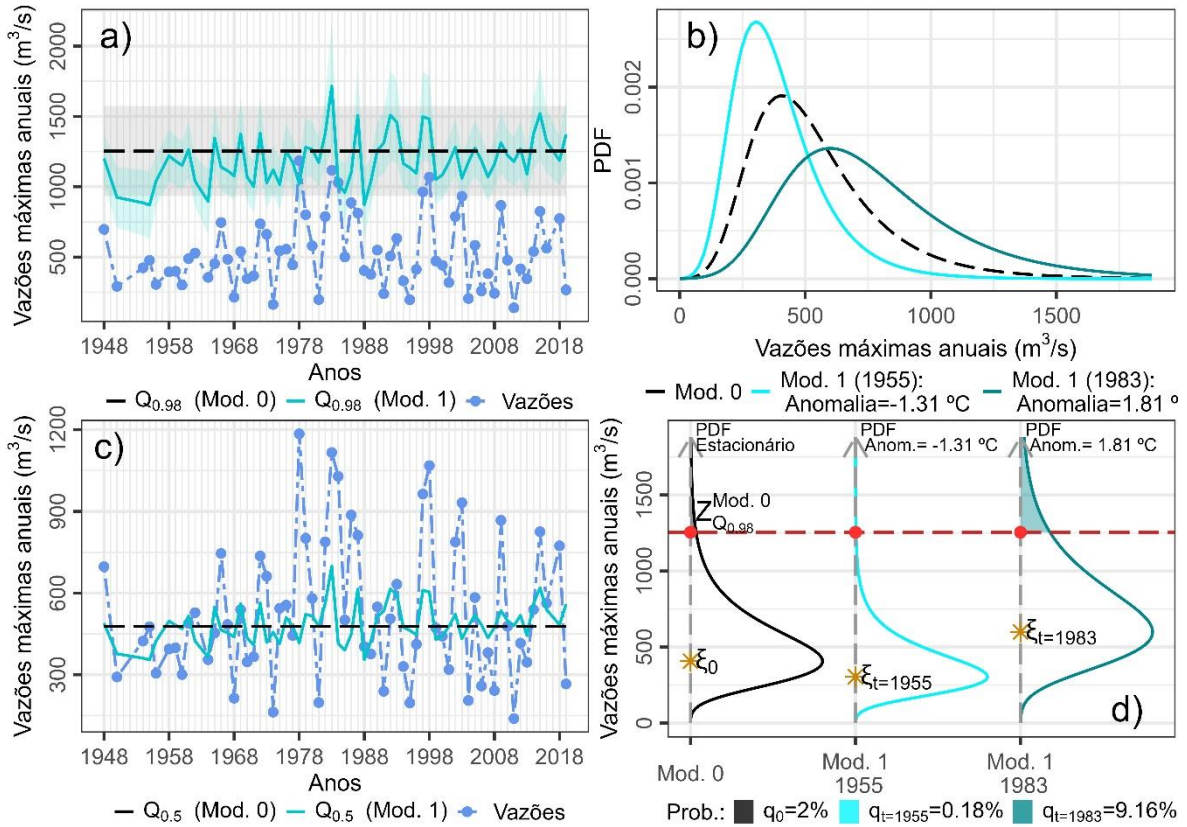
Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 76460000(31), n=61 anos, $\kappa=-0.104$, p-valor=0.00153, $r_1=(0.132,0.466)$



Anomalia AMJ do ENOS na TSM na Região do Niño 3

Estação: 76650000(32), n=65 anos, $\kappa=-0.0285$, p-valor=0.00492, $r_1=(0.0776,0.365)$



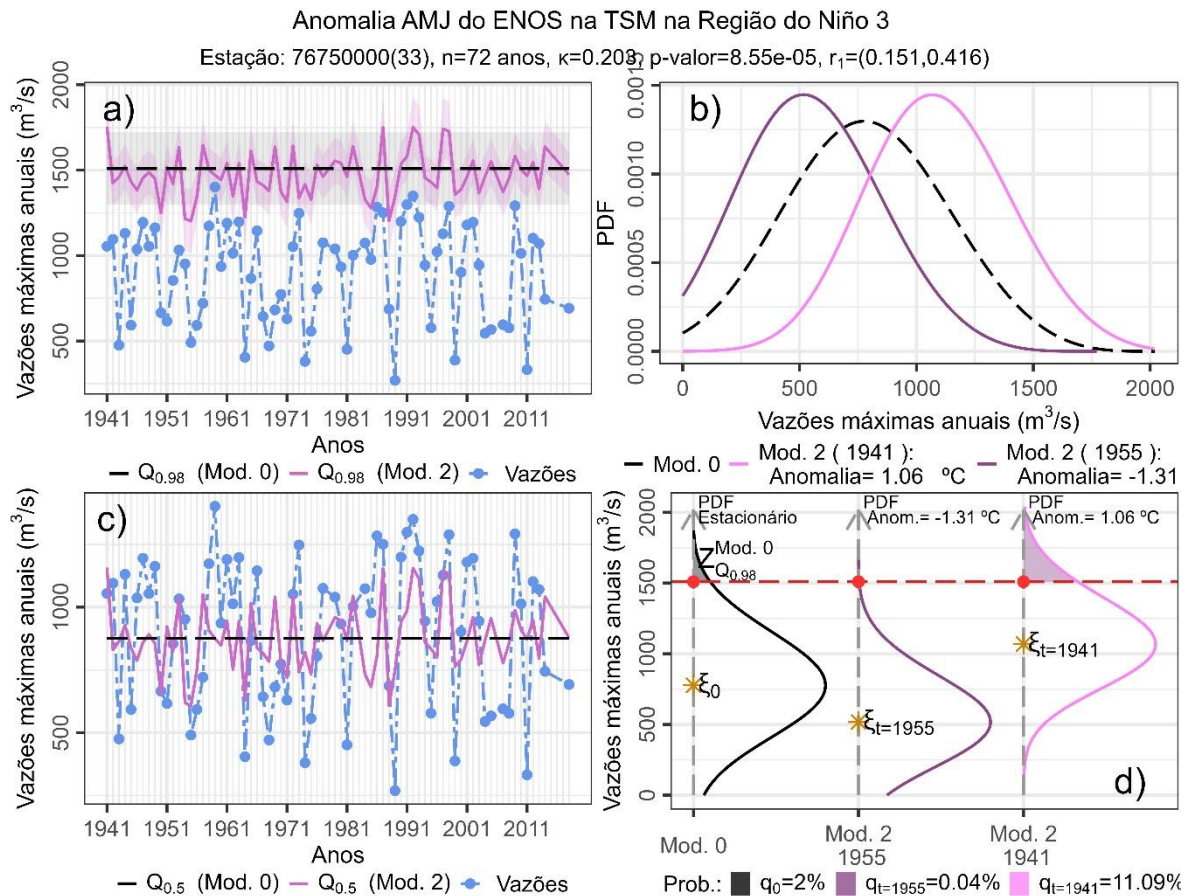
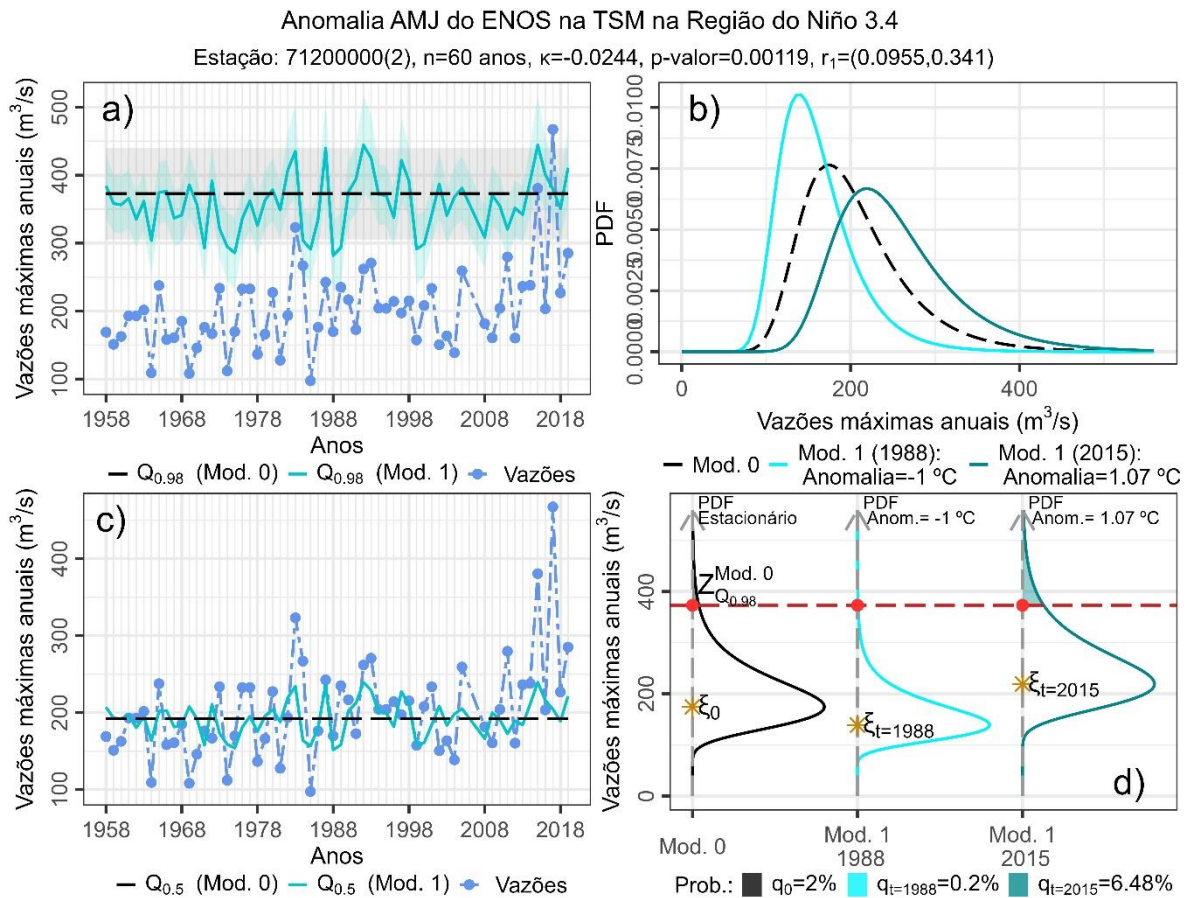
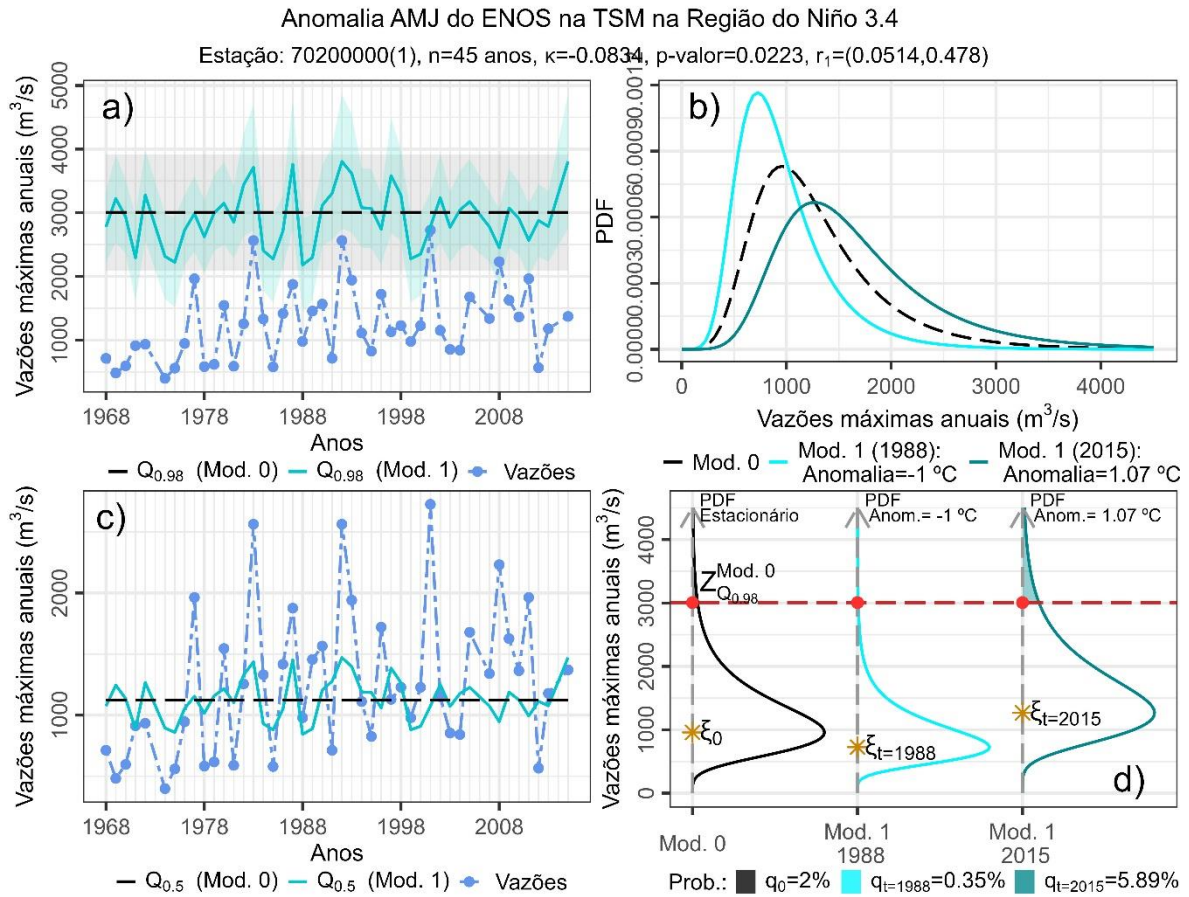
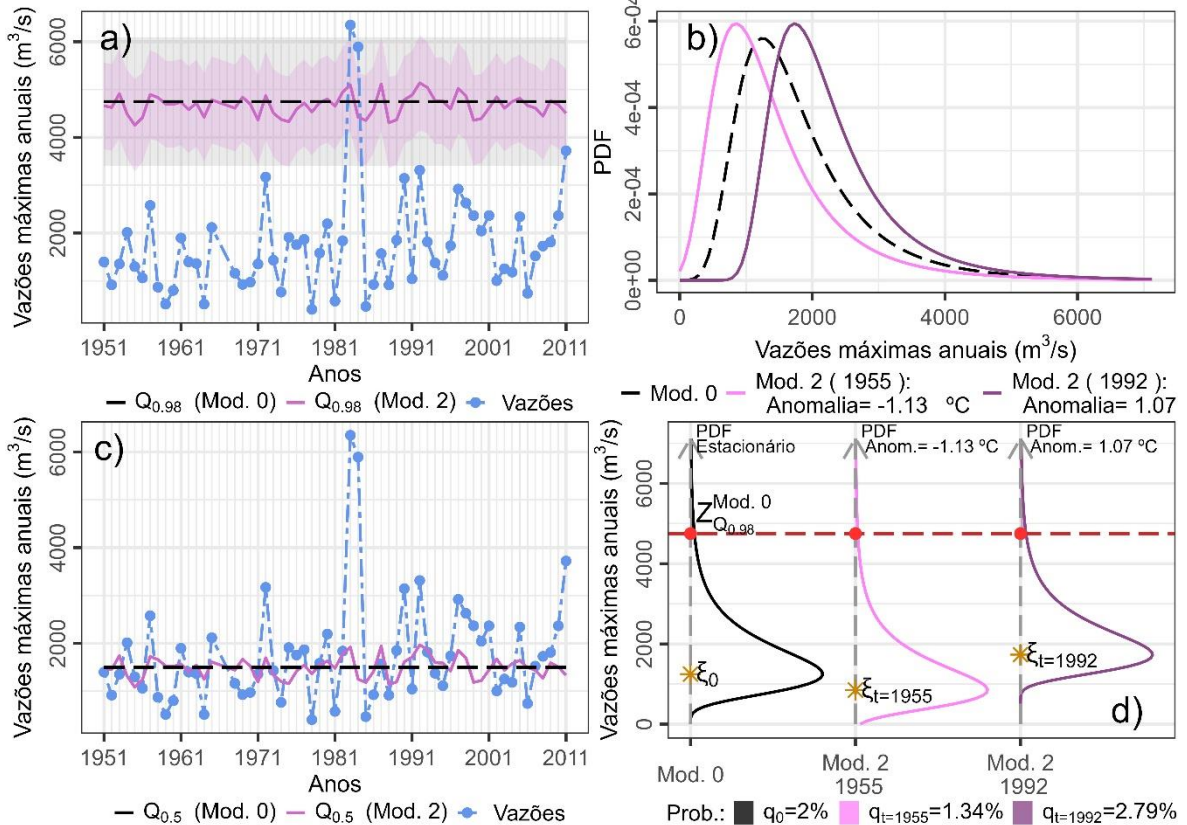


Figura 0.8 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável ENOS na região El Niño 3. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em azul-claro), Modelo 2 (não estacionário, em rosa-claro), ou Modelo 3 (não estacionário, em roxo-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 1: azul-claro; Modelo 2: rosa-claro, Modelo 3: roxo-claro) e a maior anomalia (Modelo 1: azul-escuro; Modelo 2: rosa- escuro, Modelo 3: roxo- escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (azul-claro), Modelo 2 (em rosa-claro), ou Modelo 3 (roxo-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.



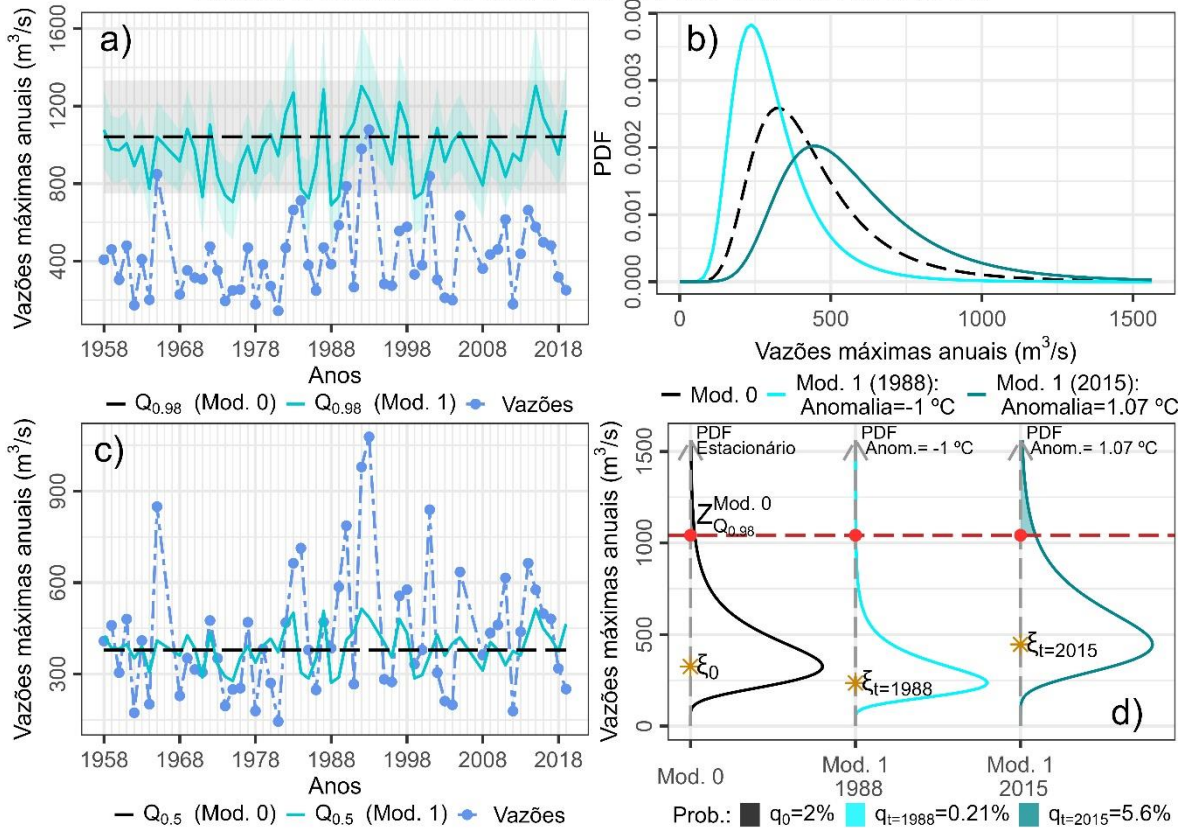
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 71550000(6), n=59 anos, $\kappa=-0.167$, p-valor=0.0223, $r_1=(0.0546, 0.563)$



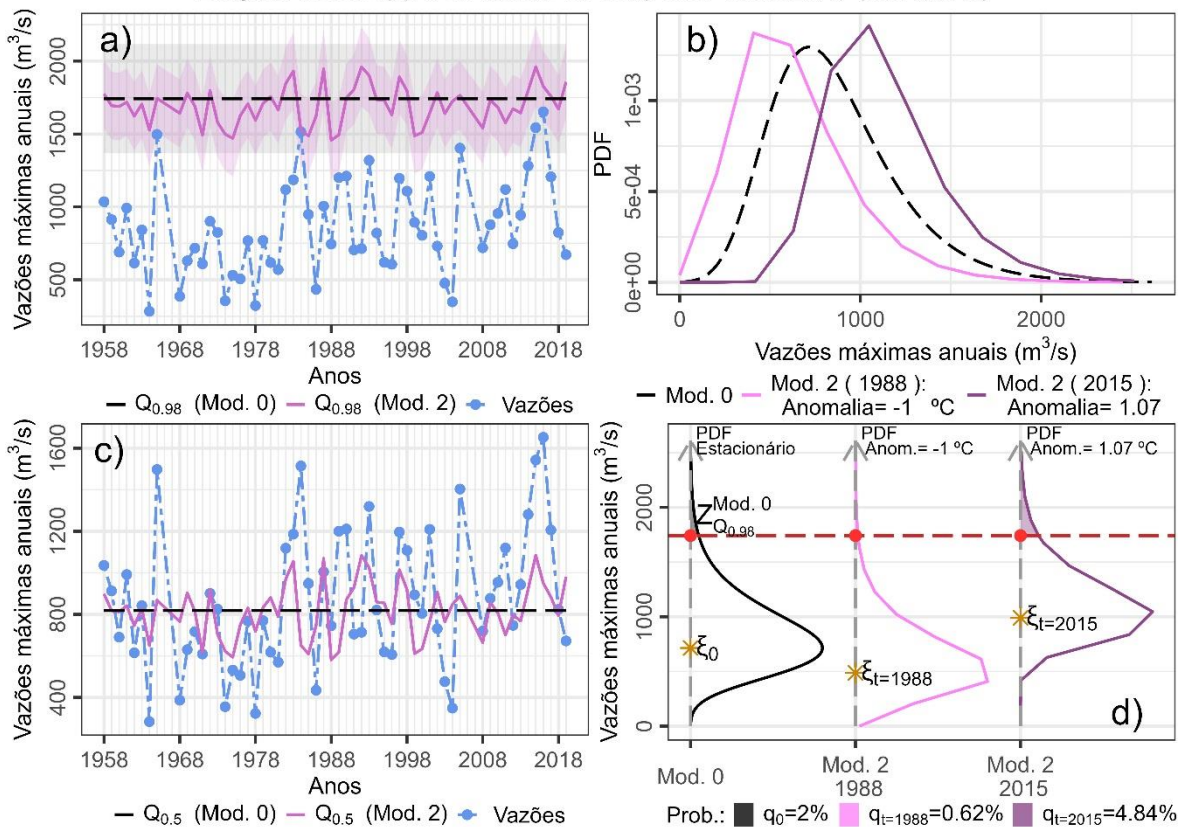
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 72430000(7), n=57 anos, $\kappa=-0.0946$, p-valor=0.00252, $r_1=(0.122, 0.479)$



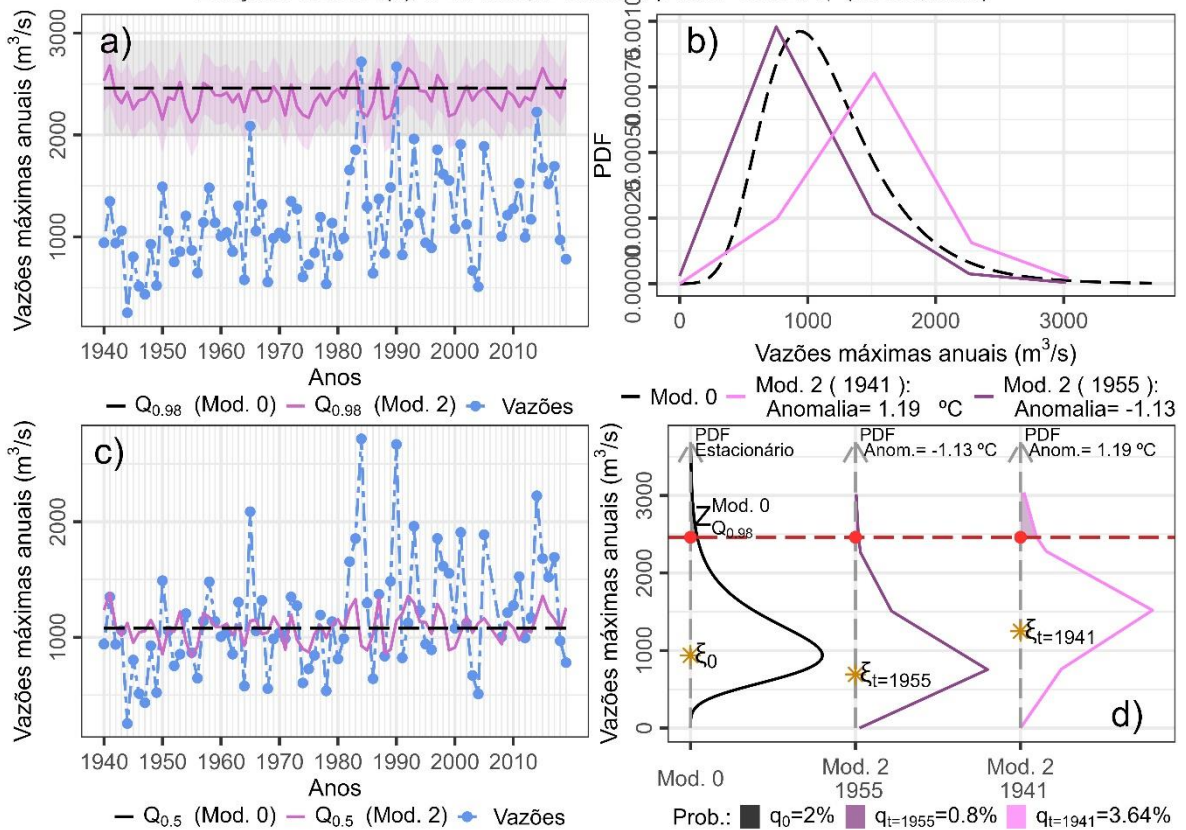
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 72630000(8), n=58 anos, $\kappa=0.0129$, p-valor=0.000826, $r_1=(0.151,0.514)$



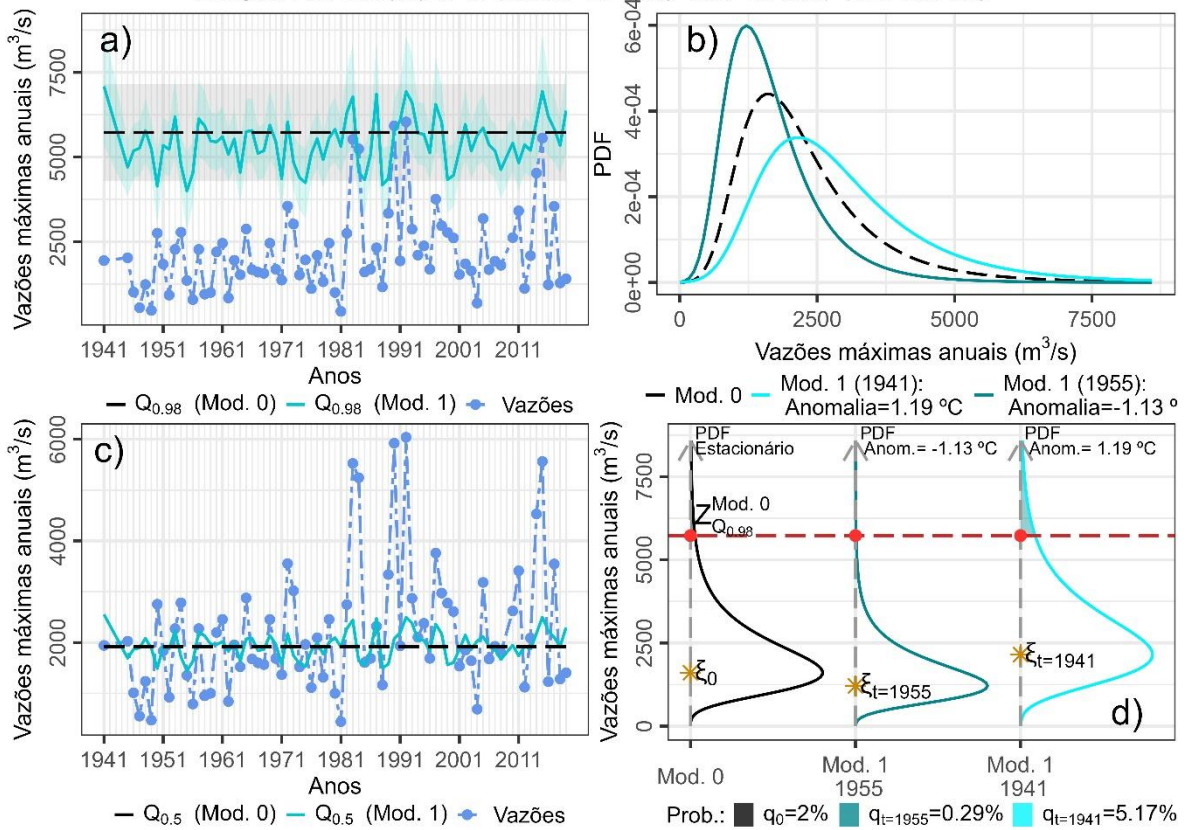
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 72680000(9), n=78 anos, $\kappa=0.0050$, p-valor=0.0108, $r_1=(0.0632,0.435)$



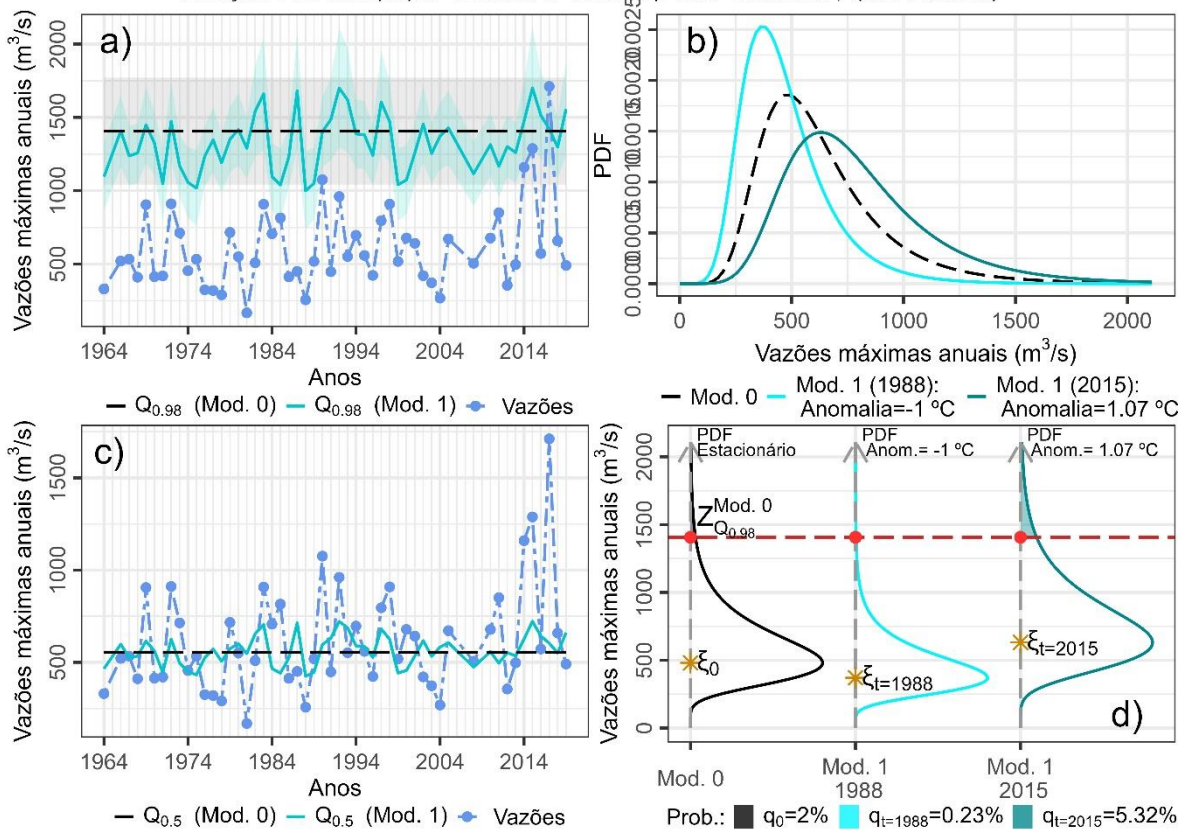
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 74270000(15), n=75 anos, $\kappa=-0.0762$, p-valor=0.013, $r_1=(0.0642,0.421)$



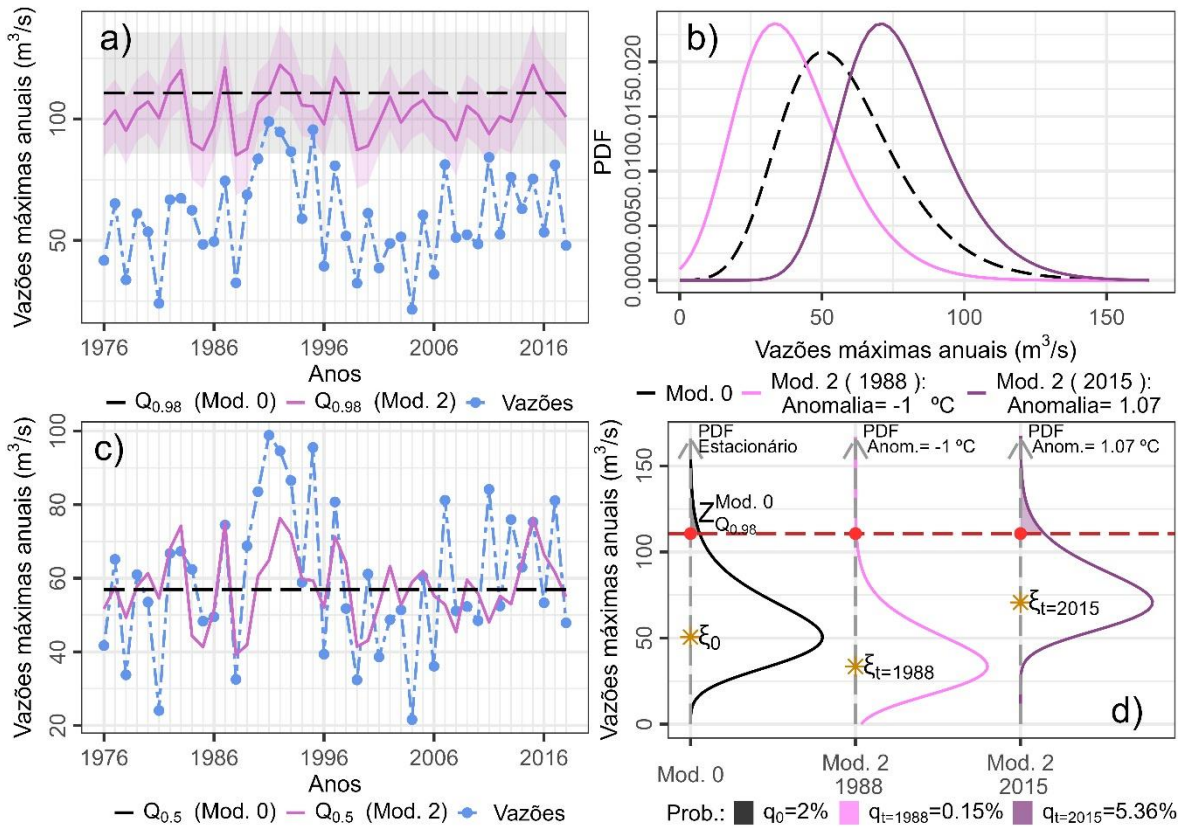
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 74370000(16), n=52 anos, $\kappa=-0.0526$, p-valor=0.00986, $r_1=(0.0735,0.432)$



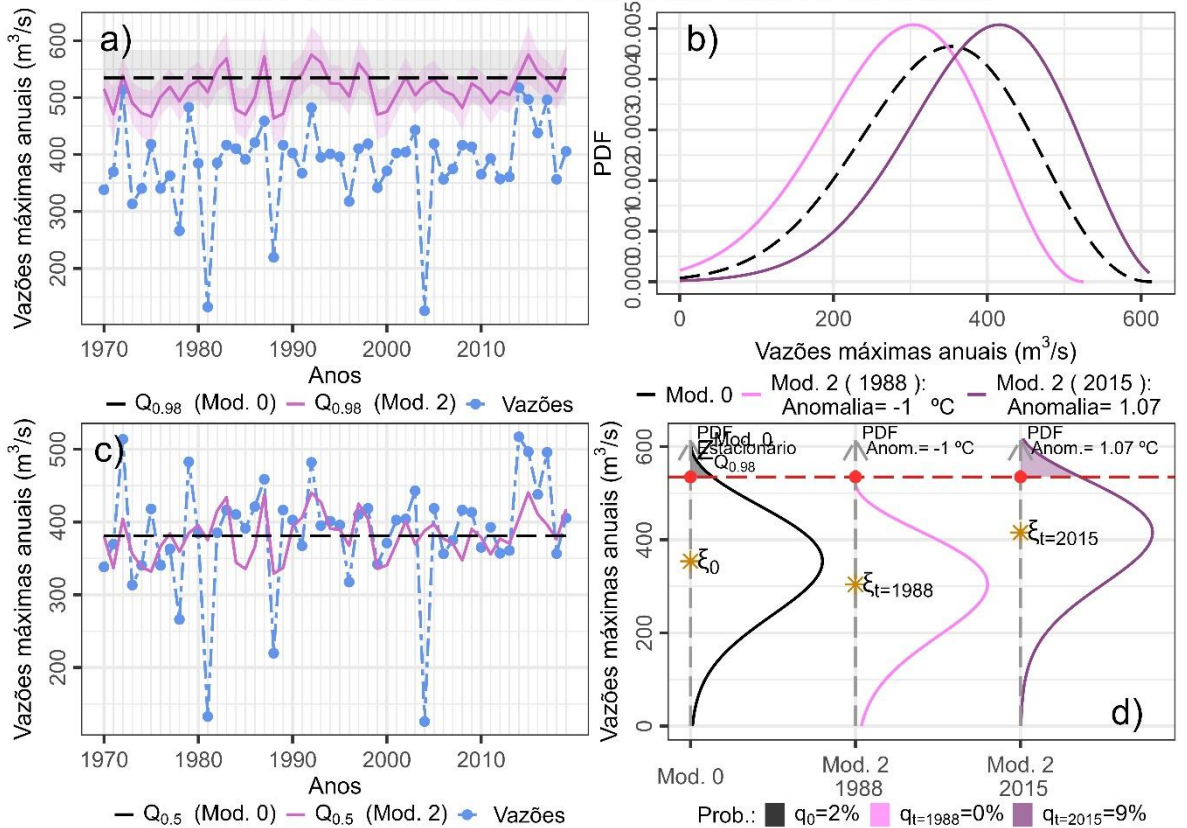
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

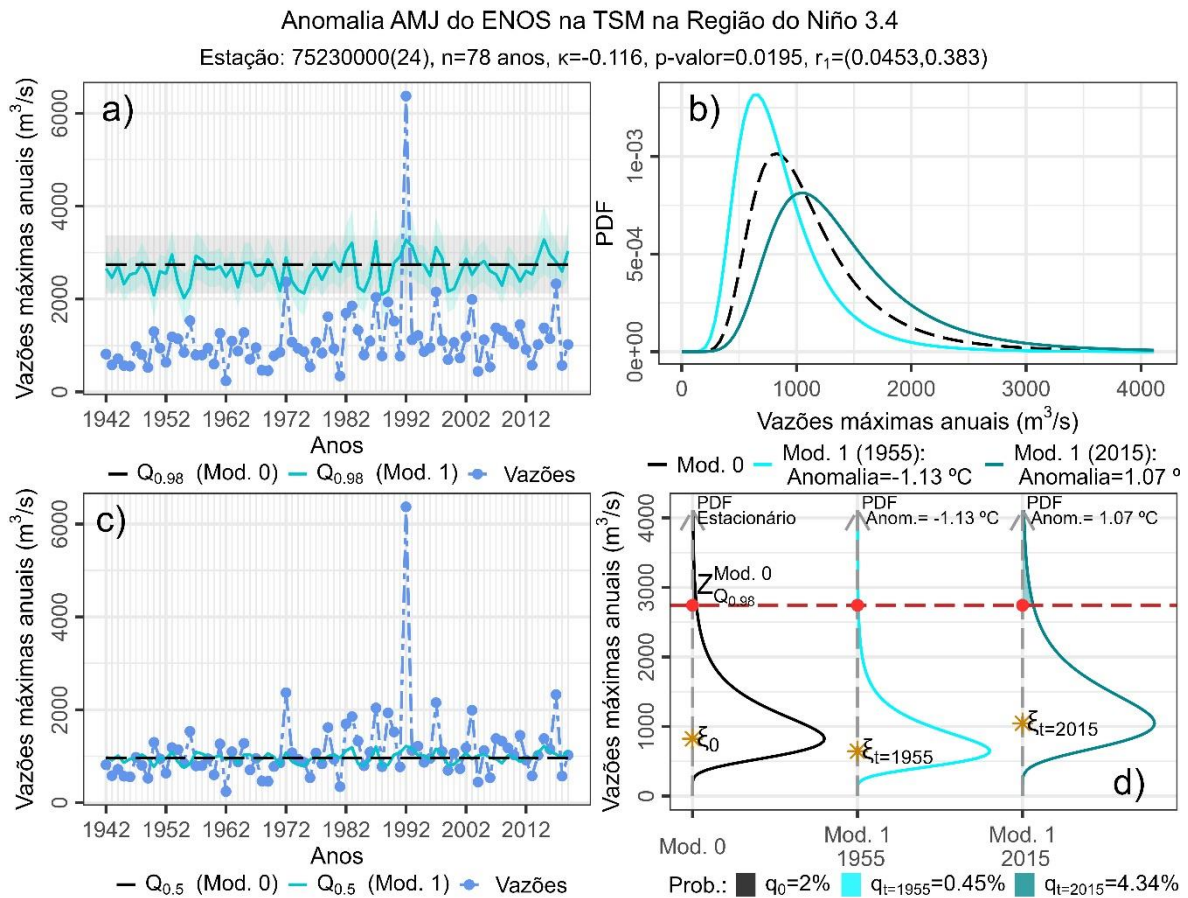
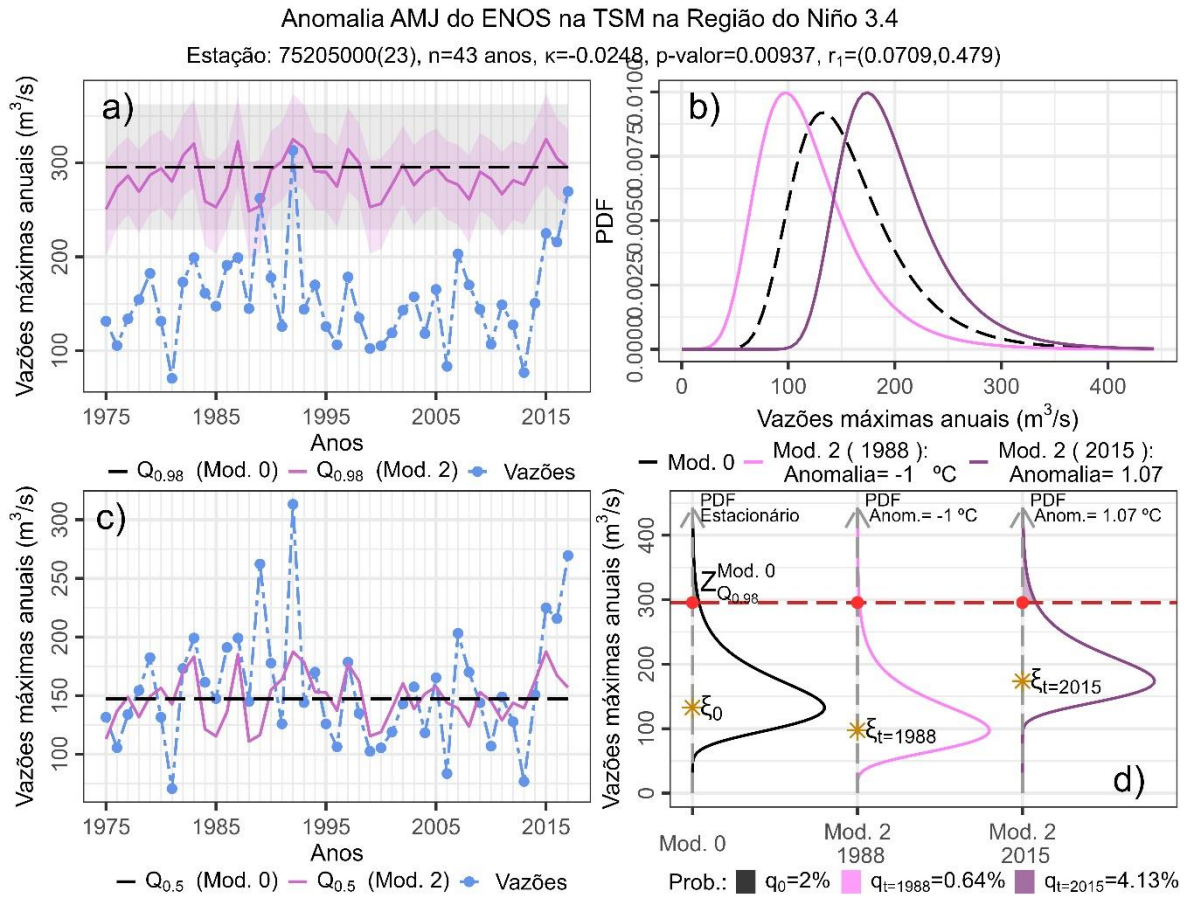
Estação: 74460000(17), n=43 anos, $\kappa=0.0906$, p-valor=0.00104, $r_1=(0.147,0.55)$



Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

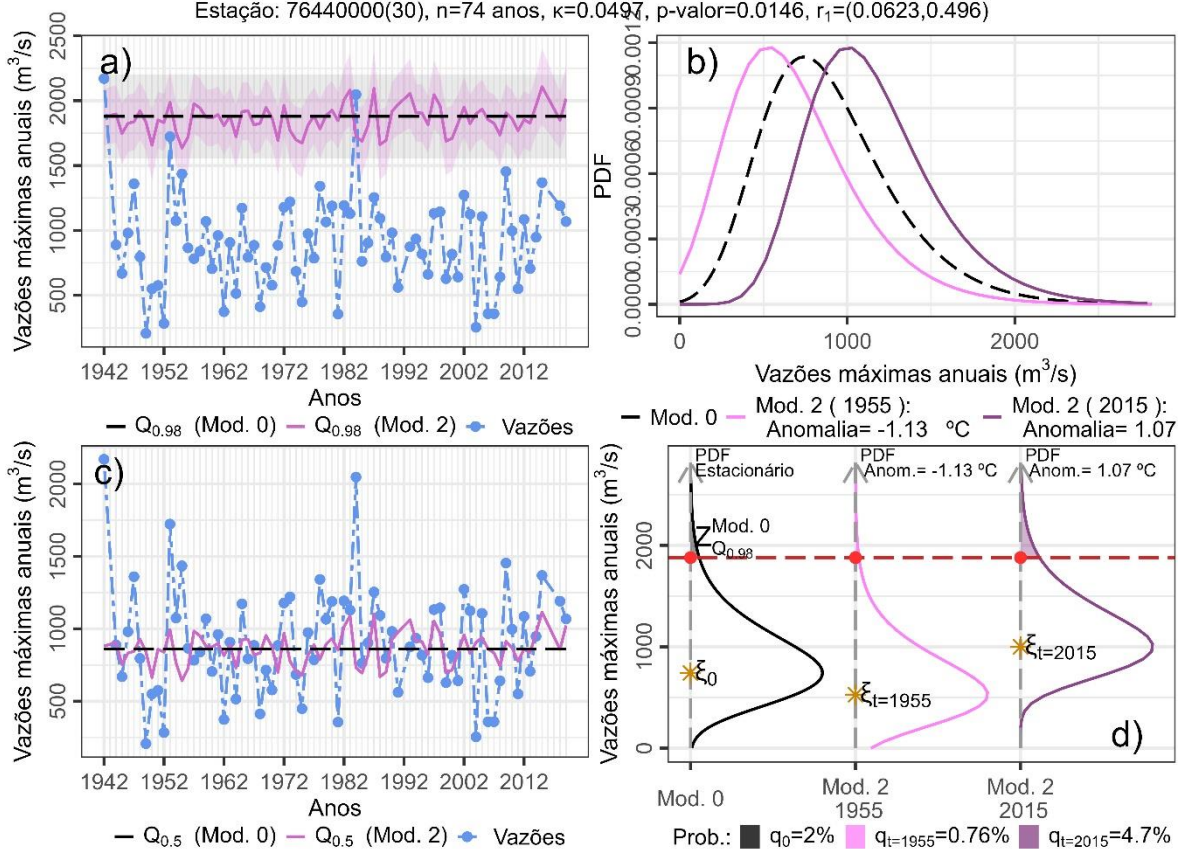
Estação: 74900000(20), n=50 anos, $\kappa=0.328$, p-valor=0.00572, $r_1=(0.0495,0.251)$





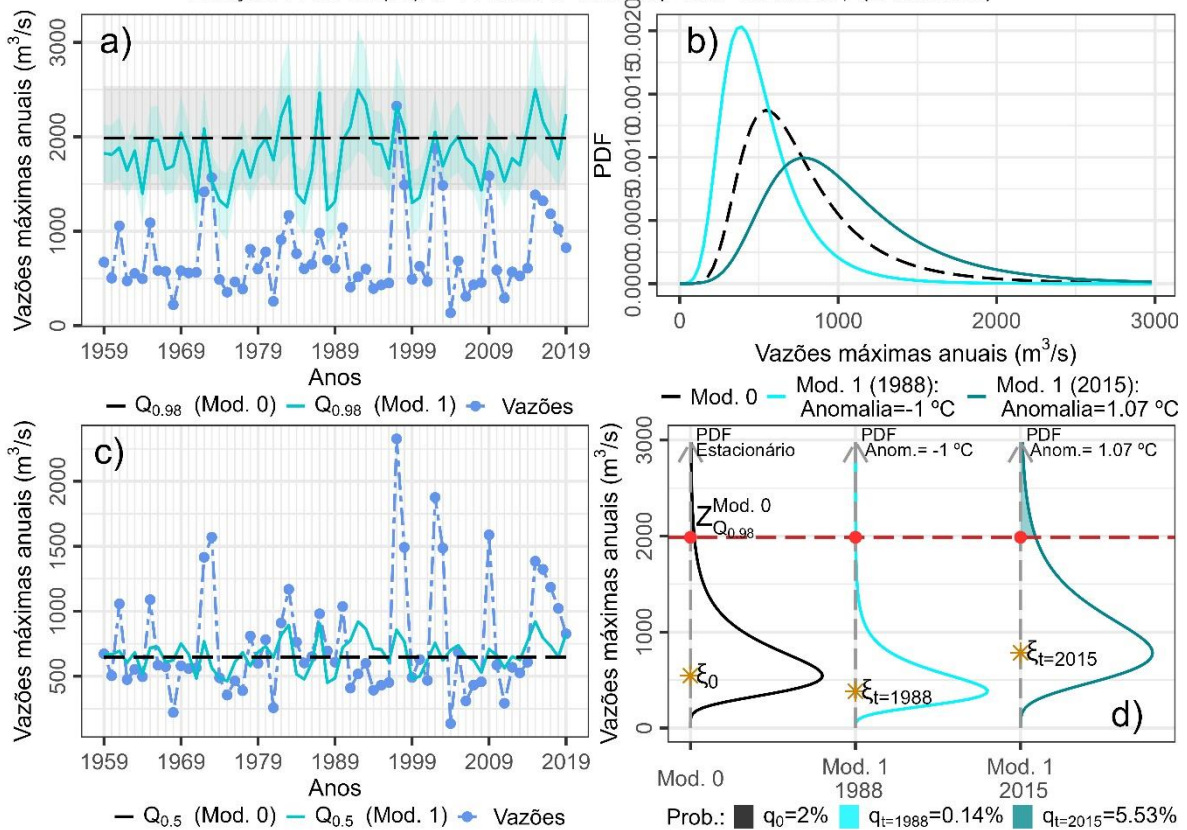
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 76440000(30), n=74 anos, $\kappa=0.0497$, p-valor=0.0146, $r_1=(0.0623,0.496)$



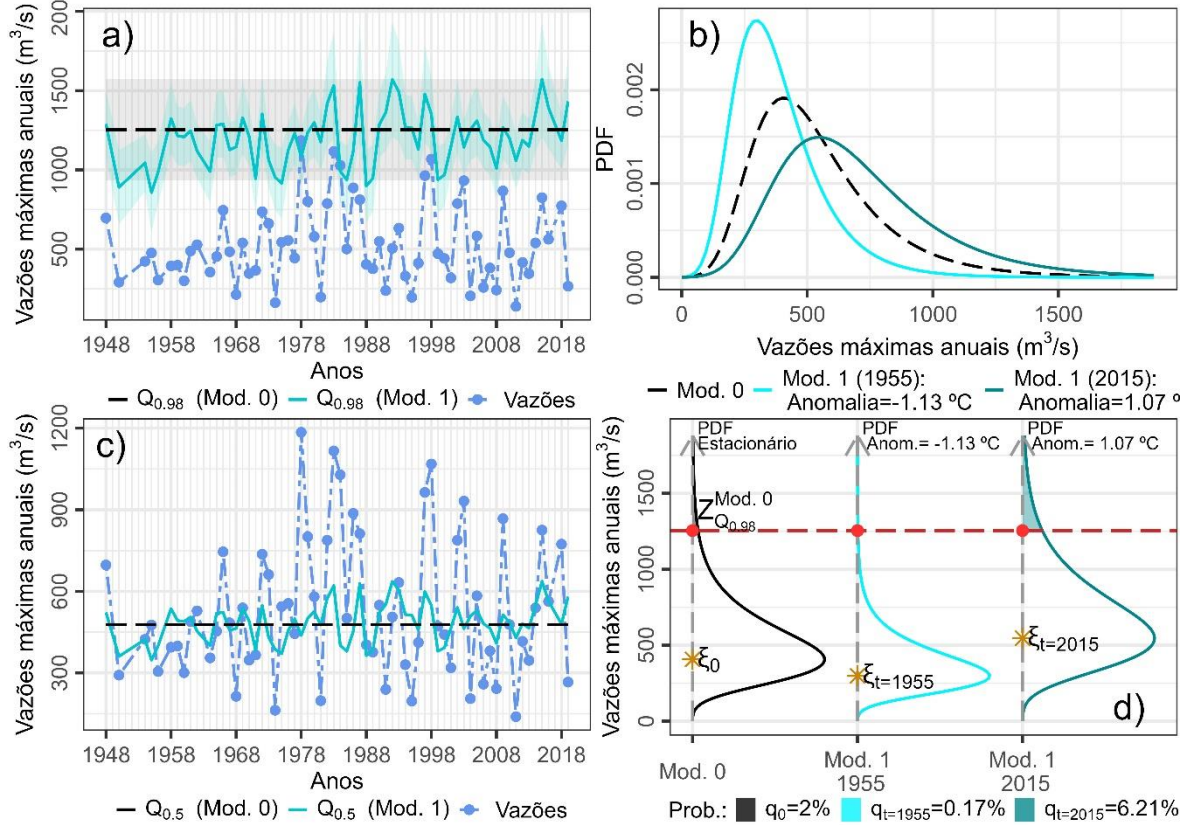
Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 76460000(31), n=61 anos, $\kappa=-0.0874$, p-valor=0.00292, $r_1=(0.137,0.533)$



Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 76650000(32), n=65 anos, $\kappa=-0.0331$, p-valor=0.00593, $r_1=(0.0918, 0.439)$



Anomalia AMJ do ENOS na TSM na Região do Niño 3.4

Estação: 76750000(33), n=72 anos, $\kappa=0.174$, p-valor=3.16e-07, $r_1=(0.254, 0.514)$

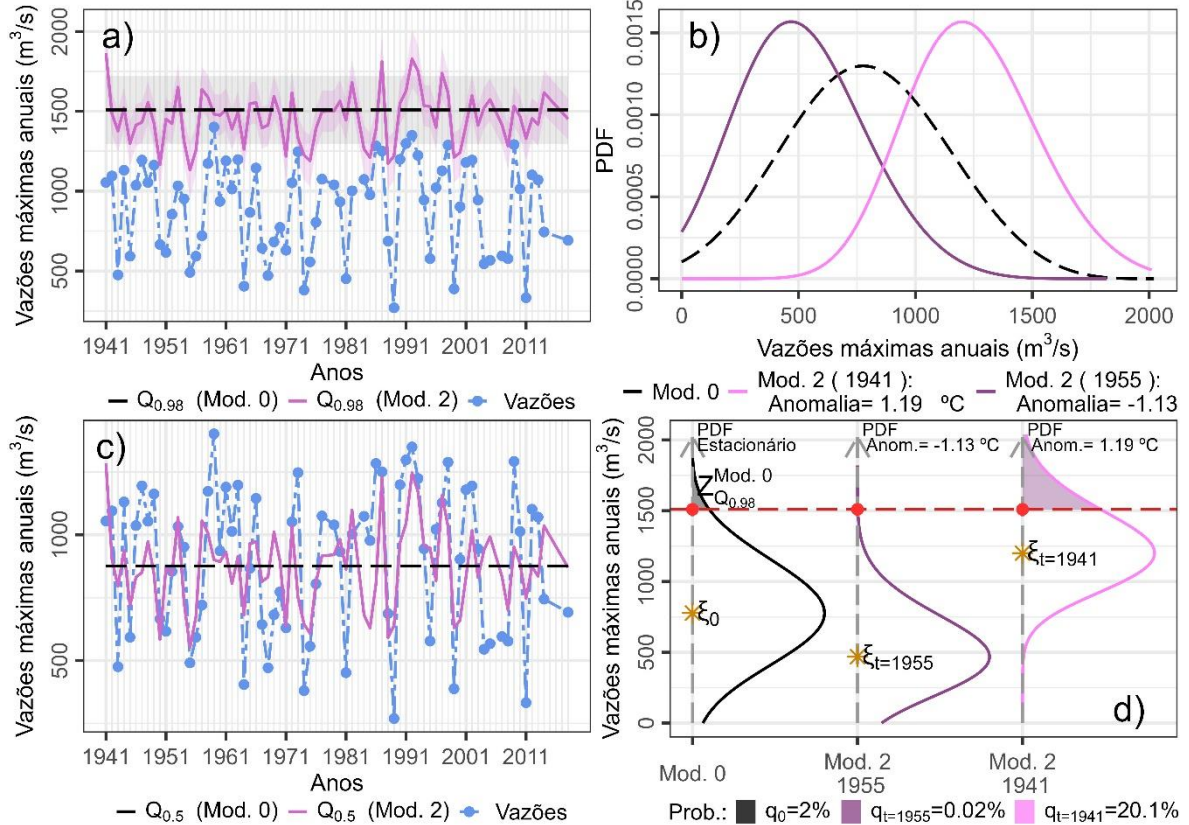


Figura 0.9 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável ENOS na região El Niño 3.4. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 1 (não estacionário, em azul-claro), ou Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 1: azul-claro; Modelo 2: rosa-claro) e a maior anomalia (Modelo 1: azul-escuro; Modelo 2: rosa-escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 1 (azul-claro), ou Modelo 2 (em rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.

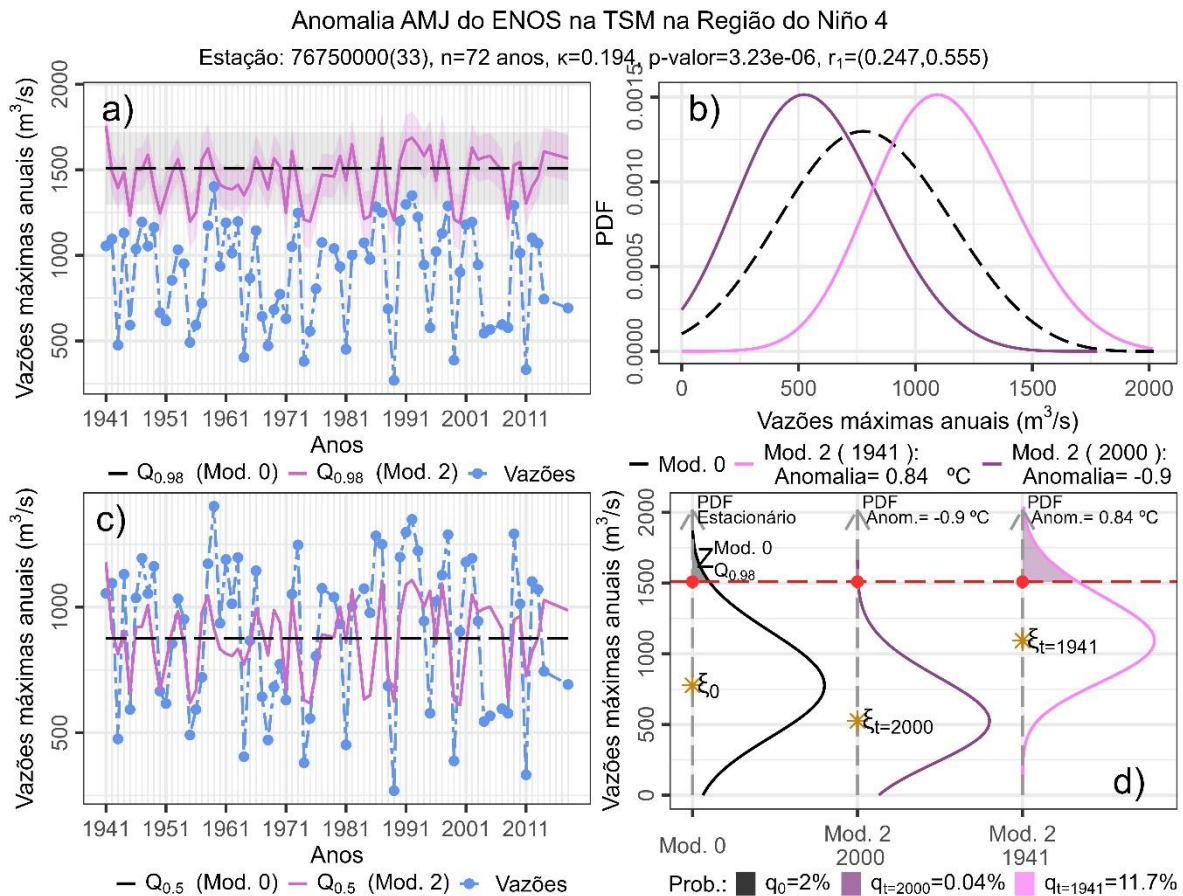


Figura 0.10 - Resultados para as séries temporais das estações modeladas pela não estacionariedade da Região Hidrográfica do Uruguai para a covariável ENOS na região El Niño 4. a) Vazões máximas anuais (azul) e estimativas do $Q_{0.98}$ para o Modelo 0 (estacionário, em preto) e para o Modelo 2 (não estacionário, em rosa-claro) e seus respectivos IC de 95%. b) PDF do Modelo 0 (preto) e do modelo não estacionário considerando a menor anomalia (Modelo 2: rosa-claro) e a maior anomalia (Modelo 2: rosa- escuro) da série histórica. c) Vazões anuais máximas (azul) e estimativas de $Q_{0.5}$ para o Modelo 0 (preto) e para o Modelo 2 (em rosa-claro). d) PDF em b) com seus respectivos p-valores baseados no $Z_{Q_{0.98}Modelo0}$, e o ξ de cada PDF.

APÊNDICE E - ANÁLISE DE FREQUÊNCIA DE CHEIAS NA RH DO URUGUAI PARA AS COVARIÁVEIS OSCILAÇÃO MULTIDECENAL DO ATLÂNTICO (OMA), OSCILAÇÃO DO ÁRTICO (OA) E OSCILAÇÃO DO ATLÂNTICO NORTE (OAN)

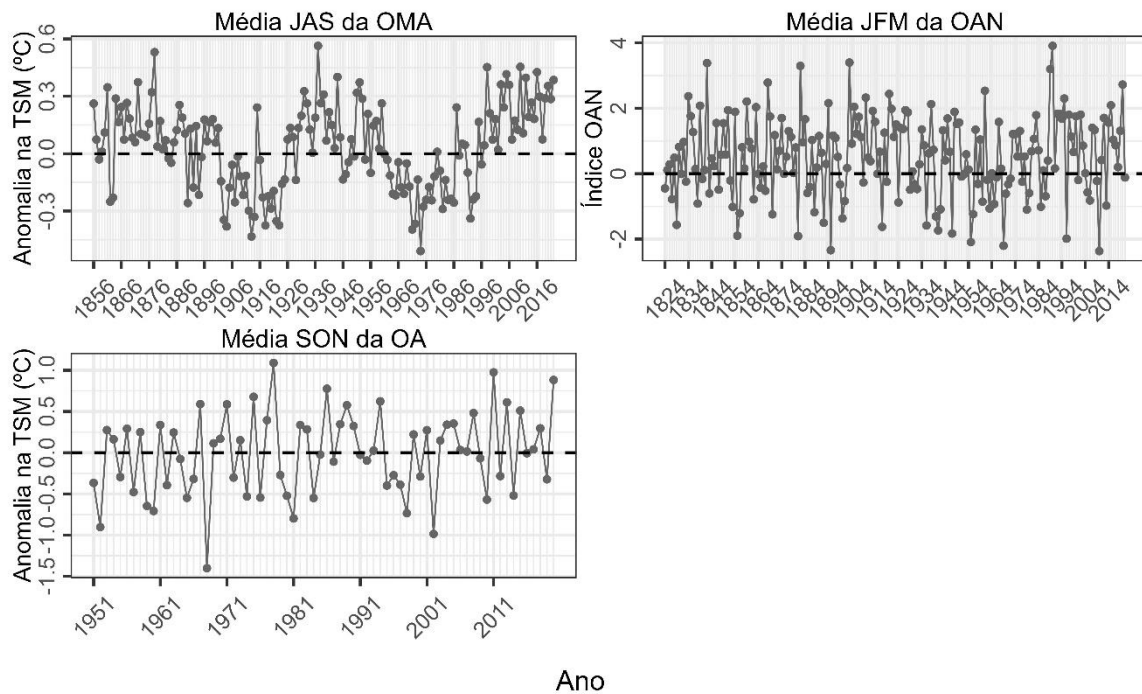


Figura 0.11 - Média dos períodos por ano dos índices climáticos com maior correlação entre as cheias na RH do Uruguai.

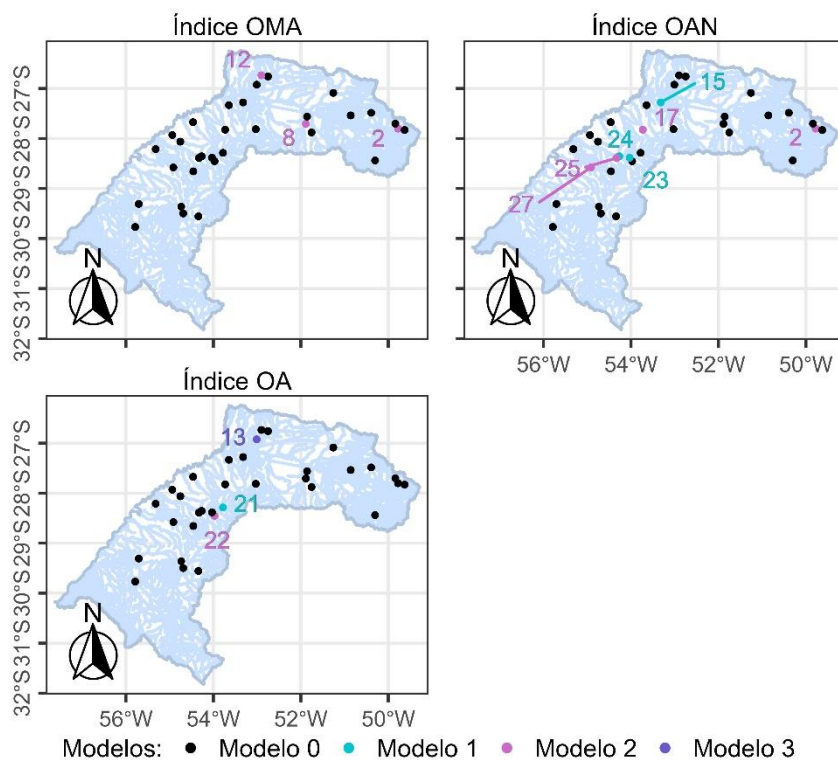


Figura 0.12 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai considerando cada índice da covariável e o modelo escolhido na análise local (BIC): Modelo 0 (preto), Modelo 1 (verde-claro), Modelo 2 (rosa) e Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).




Figura 0.13 - Análise regional empregando False Discovery Rate, com $\alpha_R=5\%$ e $m=33$, considerando cada covariável para as séries temporais que tiveram o modelo não estacionário escolhido na análise local (BIC): Modelo 1 (verde-claro), Modelo 2 (rosa) e

Modelo 3 (roxo). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

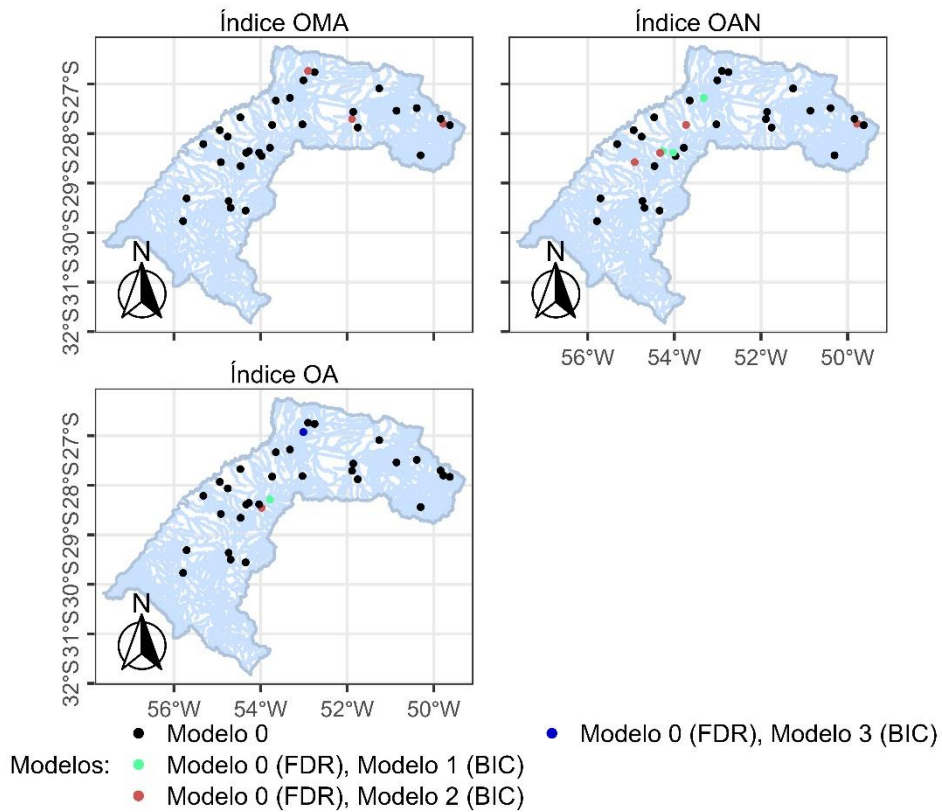


Figura 0.14 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai considerando cada índice da covariável e o modelo escolhido em análise local (BIC) e regional (FDR + IC). O modelo estacionário escolhido na análise local: Modelo 0 (preto); e o modelo não estacionário escolhido na análise local que mudou para um modelo estacionário após a análise regional: de Modelo 1 para 0 (verde), de Modelo 2 para 0 (vermelho), de Modelo 3 para 0 (azul-escuro). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).

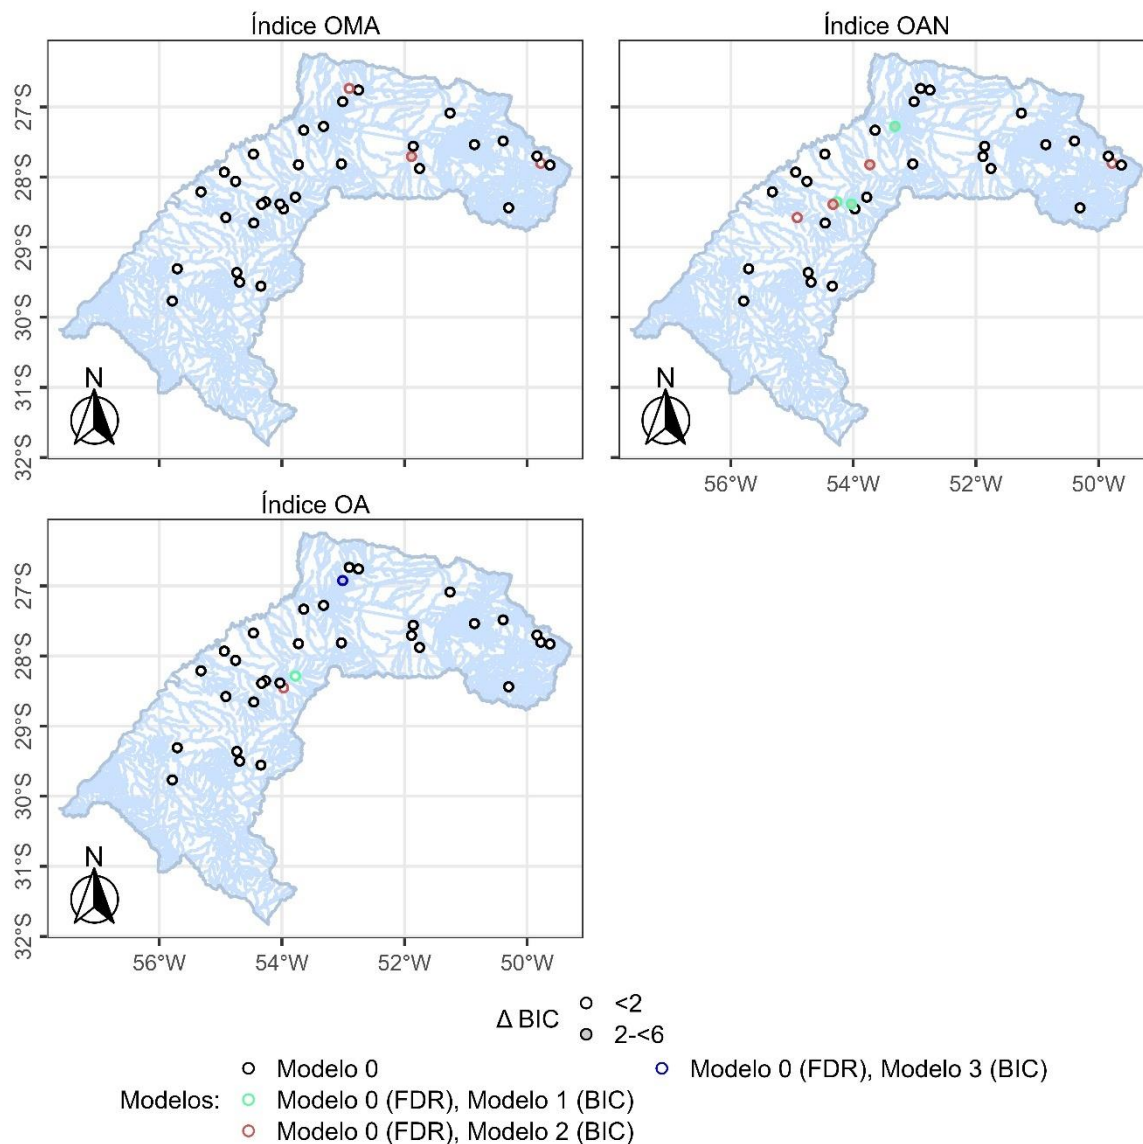


Figura 0.15 - Localização das 33 estações com séries históricas analisadas na RH do Uruguai considerando cada índice da covariável e o modelo escolhido em análise local (BIC) e regional (FDR + IC). O modelo estacionário escolhido na análise local: Modelo 0 (círculo preto); e o modelo não estacionário escolhido na análise local que mudou para um modelo estacionário após a análise regional: de Modelo 1 para 0 (círculo verde), de Modelo 2 para 0 (círculo vermelho), de Modelo 3 para 0 (círculo azul-escuro). O preenchimento dos círculos representa o suporte relativo (ΔBIC) ao uso do Modelo 0 para o BIC, quanto maior o ΔBIC , maior é o suporte contra a estacionariedade: 0 a 2 (branco), 2 a 6 (cinza-claro), 6 a 10 (cinza-escuro), > 10 (preto). Os rótulos indicam o número da estação com a série de dados (Figura 4.3).