

MARIA LUISA SILVA BONIMANI

**A ATUALIZAÇÃO DO VALOR CRÍTICO INTERFERE NA PERFORMANCE DO
PROCEDIMENTO DATA SNOOPING?**

Dissertação apresentada ao Programa de Pós-Graduação em
Agricultura e Informações Geoespaciais da Universidade
Federal de Uberlândia, Campus Monte Carmelo como parte
das exigências para obtenção do título de “Mestre”.

Orientador

Prof. Dr. Marcelo Tomio Matsuoka

Coorientador

Prof. Dr. Vinicius Francisco Rofatto

**MONTE CARMELO
MINAS GERAIS - BRASIL
2022**

MARIA LUISA SILVA BONIMANI

**A ATUALIZAÇÃO DO VALOR CRÍTICO INTERFERE NA PERFORMANCE DO
PROCEDIMENTO DATA SNOOPING?**

Dissertação apresentada ao Programa de Pós-Graduação em
Agricultura e Informações Geoespaciais da Universidade
Federal de Uberlândia, Campus Monte Carmelo como parte
das exigências para obtenção do título de “Mestre”.

APROVADA em 28 de fevereiro de 2022.

Banca Examinadora

Prof. Dr. Marcelo Tomio Matsuoka – Instituto de Geografia (UFU)

Prof. Dr. Vinicius Francisco Rofatto – Instituto de Geografia (UFU)

Prof. Dr. Ivandro Klein – Departamento Acadêmico de Construção Civil (IFSC)

Prof. Dr. Marcelo Tomio Matsuoka
Instituto de Geografia (UFU)
(Orientador)

**MONTE CARMELO
MINAS GERAIS - BRASIL
2022**

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

B715 2022	<p>Bonimani, Maria Luisa Silva, 1997- A atualização do valor crítico interfere na performance do procedimento Data Snooping? [recurso eletrônico] / Maria Luisa Silva Bonimani. - 2022.</p> <p>Orientador: Marcelo Tomio Matsuoka. Coorientador: Vinicius Francisco Rofatto. Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Agricultura e Informações Geoespaciais. Modo de acesso: Internet. Disponível em: http://doi.org/10.14393/ufu.di.2022.149 Inclui bibliografia. Inclui ilustrações.</p> <p>1. Agronomia. I. Matsuoka, Marcelo Tomio, 1978-, (Orient.). II. Rofatto, Vinicius Francisco, 1986-, (Coorient.). III. Universidade Federal de Uberlândia. Pós-graduação em Agricultura e Informações Geoespaciais. IV. Título.</p> <p style="text-align: right;">CDU: 631</p>
--------------	---

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Agricultura e Informações Geoespaciais

Rodovia LMG 746, Km 01, s/nº, Bloco 1AMC, Sala 1A202, Monte Carmelo-MG, CEP 38.500-000
Telefone: (34) 3810-1033 - ppgaig@iciag.ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agricultura e Informações Geoespaciais				
Defesa de:	Dissertação de Mestrado Acadêmico				
Data:	28/02/2022	Hora de início:	19:00	Hora de encerramento:	21:00
Matrícula do Discente:	32012AIG009				
Nome do Discente:	Maria Luísa Silva Bonimani				
Título do Trabalho:	A atualização do valor crítico interfere na performance do procedimento Data Snooping?				
Área de concentração:	Informações geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Aplicações e desenvolvimento de métodos em informações espaciais				

Reuniu-se na sala virtual webconf/marcelo-tomio-matsuoka a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Dr. Vinícius Francisco Rofatto (UFU), Dr. Ivandro Klein (Instituto Federal de Santa Catarina), Dr. Marcelo Tomio Matsuoka (UFU) – orientador(a) do(a) candidato(a).

Iniciando os trabalhos o presidente da mesa, Dr. Marcelo Tomio Matsuoka, apresentou a Comissão Examinadora e a candidata, agradeceu a presença do público e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovada.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Marcelo Tomio Matsuoka, Professor(a) do Magistério Superior**, em 01/03/2022, às 21:03, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Ivandro Klein, Usuário Externo**, em 02/03/2022, às 14:58, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Vinicius Francisco Rofatto, Professor(a) do Magistério Superior**, em 04/03/2022, às 16:30, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3406313** e o código CRC **6AC13013**.

*Dedico
À minha mãe Cristina.*

*“Eu andarei vestido e armado com as armas
de São Jorge...” Oração à São Jorge.*

AGRADECIMENTOS

Agradeço a minha mãe Cristina, minha referência de amor e força, por toda a educação, carinho, incentivo e pelo amor incondicional que destinou sempre a mim. Obrigada por sempre me dar forças para continuar, me ajudar a superar as fases ruins, a vencer os desafios e nunca soltar a minha mão, me mostrando que eu nunca estaria sozinha, mesmo o quão difícil fosse o caminho para chegar até aqui. Essa conquista não é apenas minha, é nossa.

Gratidão ao meu pai, Rafael que sempre me apoiou e as minhas irmãs Ana Laura e Julia, que estiveram sempre ao meu lado e foram fonte de alegria e risadas diariamente.

Ao meu orientador Prof. Dr. Marcelo Tomio Matsuoka e ao meu coorientador Prof. Dr. Vinicius Francisco Rofatto pelo estímulo, apoio e orientação durante toda a minha jornada, desde a Iniciação Científica até ao mestrado. Espero ter honrado a confiança depositada em mim e os ensinamentos transmitidos incansavelmente durante estes anos.

Obrigada ao Prof. Dr. Ivandro Klein por gentilmente ter aceitado o convite para contribuir neste trabalho.

Agradeço o apoio do grupo de pesquisa “Controle de Qualidade e Inteligência Computacional em Geodésia” (dgp.cnpq.br/dgp/espelhogrupo/0178611310347329).

Ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais e a Universidade Federal de Uberlândia por todo o suporte durante a minha formação. Muito obrigada!

O presente trabalho foi realizado com o apoio financeiro da Coordenação de Aperfeiçoamento de Pessoa de Nível Superior – Brasil (CAPES) – código de financiamento 001. Sem o apoio do CAPES ao me conceder a bolsa de mestrado, talvez esta conquista não seria possível pelas dificuldades do discente para se dedicar integralmente a fazer ciência, no atual cenário econômico e político do Brasil.

BIOGRAFIA

Maria Luísa Silva Bonimani nasceu em Uberlândia, Minas Gerais, Brasil, 1997. Graduada em Engenharia de Agrimensura e Cartográfica pela Universidade Federal de Uberlândia (UFU) – Campus Monte Carmelo, Minas Gerais, Brasil em dezembro de 2019. Em março de 2020 ingressou no Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da Universidade Federal de Uberlândia – Campus Monte Carmelo, onde foi orientada pelo Prof. Dr. Marcelo Tomio Matusoka e coorientada pelo Prof. Dr. Vinicius Francisco Rofatto. Seus interesses de pesquisa incluem o estudo da teoria da confiabilidade e o desenvolvimento de técnicas para o controle de qualidade em redes geodésicas.

SUMÁRIO

RESUMO	i
ABSTRACT	ii
1. INTRODUÇÃO	13
2. UMA ABORDAGEM BASEADA EM MONTE CARLO PARA O CONTROLE DA TAXA DE ERRO TIPO I.....	15
3. OBTENÇÃO DO VALOR CRÍTICO POR MEIO DA CORREÇÃO ŠIDÁK.....	19
4. UMA ABORDAGEM BASEADA EM REDES NEURAIIS PARA O CONTROLE DA TAXA DE ERRO TIPO I.....	20
5. EXPERIMENTOS E RESULTADOS	22
5.1 Avaliação da atualização dos valores críticos obtidos por meio dos métodos Monte Carlo, SBPNN e correção ŠIDÁK.....	23
5.2 Avaliação da taxa de sucesso do <i>Data Snooping</i> com base nos valores críticos atualizados obtidos através dos métodos Monte Carlo, SBPNN e correção ŠIDÁK	27
6. CONSIDERAÇÕES FINAIS	29
REFERÊNCIAS	30

BONIMANI, MARIA LUÍSA SILVA. **A atualização do valor crítico interfere na performance do procedimento Data Snooping?** 2022, 31p. Dissertação (Mestrado em Agricultura e Informações Geoespaciais) – Universidade Federal de Uberlândia, Campus Monte Carmelo, Minas Gerais, Brasil. Disponível em: <http://doi.org/10.14393/ufu.di.2022.149>

RESUMO

Na era do Big Data detectar *outlier* no conjunto de dados se tornou uma das atividades mais importantes. Na Geodésia o *Data Snooping* é o procedimento mais utilizado para identificação de *outliers*. Para o controle da taxa de erro tipo I, isto é, falsos positivos, os valores críticos devem ser obtidos por meio do método Monte Carlo. No entanto, até agora os estudos foram realizados sem considerar a atualização do valor crítico no processo iterativo do *Data Snooping*. Uma vez que para realizar o controle efetivo da taxa de erro tipo I o valor crítico deve ser atualizado todas as vezes que uma observação for identificada como *outlier* e removida do conjunto de dados. Aqui investigamos se a atualização do valor crítico interfere na performance do procedimento *Data Snooping* e calculamos o valor crítico por meio dos métodos Monte Carlo, Rede Neural Artificial e correção Šidák. Para esse experimento consideramos uma rede fechada de nivelamento com correlação máxima entre os resíduos de 41,46%. Considerando níveis de significância menores ou iguais a 10% ($\alpha' \leq 10\%$), a atualização do valor crítico não apresenta diferenças significativas quando comparados com os valores críticos não atualizados, apresentando uma diferença máxima de $\Delta K_{SBPNN}=0,0389$ ($\alpha = 0,001$), $\Delta K_{sid}=0,0507$ ($\alpha = 0,001$) e $\Delta K_{MC}=0,0256$ ($\alpha = 0,1$) para o caso de uma exclusão e uma diferença máxima de $\Delta K_{SBPNN}=0,1023$ ($\alpha = 0,001$), $\Delta K_{sid}=0,1353$ ($\alpha = 0,001$) e $\Delta K_{MC}=0,0773$ ($\alpha = 0,001$) para o caso de 2 exclusões. A atualização do valor crítico também não causa diferenças significativas nas taxas de correta identificação de *outliers* apresentando um ΔP_{CI} máximo de $< 0,5\%$. Desta forma, os experimentos mostraram que a atualização do valor crítico não causa efeitos significativos na performance do *Data Snooping* para níveis de significância menores ou iguais a 10% ($\alpha' \leq 10\%$).

Palavras-chave: Confiabilidade, Controle de Qualidade, Data Snooping, Detecção de outliers, Monte Carlo, Rede Neural Artificial.

¹ Orientador: Prof. Dr. Marcelo Tomio Matsuoka

BONIMANI, MARIA LUÍSA SILVA. **Does updating the critical value interfere with the performance of the Data Snooping procedure?** 2022, 31p. Dissertation (Master Program Agriculture and Geospacial Information) – Federal University of Uberlândia, Monte Carmelo, Minas Gerais, Brazil. Available in: <http://doi.org/10.14393/ufu.di.2022.149>.

ABSTRACT

In the age of Big Data, detecting outlier in the data set has become one of the most important activities. In Geodesy, Data Snooping is the most widely used procedure for identifying outliers. To control the type I error rate, that is, false positives, critical values must be obtained using the Monte Carlo method. However, so far, studies have been conducted without considering the update of the critical value of the iterative process of Data Snooping. Since to effectively control the type I error rate the critical value must be updated every time an observation is identified as an outlier and removed from the data set. Here we investigate whether updating the critical value interferes with the performance of the *Data Snooping* procedure and calculate the critical value using the Monte Carlo, Artificial Neural Network and Šidák correction methods. For this experiment, we considered a closed leveling network with a maximum correlation between residuals of 41.46%. Considering significance levels less than or equal to 10% ($\alpha' \leq 10\%$), updating the critical value does not show significant differences when compared to the non-updated critical values, presenting a maximum difference of $\Delta K_{SBPNN}=0,0389$ ($\alpha = 0,001$), $\Delta K_{sid}=0,0507$ ($\alpha = 0,001$) e $\Delta K_{MC}=0,0256$ ($\alpha = 0,1$) for the case of 1 exclusion, and a maximum difference of $\Delta K_{SBPNN}=0,1023$ ($\alpha = 0,001$), $\Delta K_{sid}=0,1353$ ($\alpha = 0,001$) e $\Delta K_{MC}=0,0773$ ($\alpha = 0,001$) for the case of 2 exclusions. Updating the critical value also does not cause significant differences in the correct outlier identification rates showing a maximum $\Delta P_{CI} < 0,5\%$. In this way, the experiments showed that updating the critical value does not cause significant effects on the performance of *Data Snooping* for significance levels less than or equal to 10% ($\alpha' \leq 10\%$).

Keywords: Artificial Neural Network. Data Snooping. Monte Carlo. Outlier Detection. Quality Control. Reliability.

¹ Advisor: Prof. Dr. Marcelo Tomio Matsuoka

1. INTRODUÇÃO

Na era do Big Data, detectar *outliers* no conjunto de dados se tornou uma das atividades mais importantes. *Outlier* é uma observação que se afastou do seu valor provável, a ponto de não pertencer ao modelo matemático (funcional e estocástico) estipulado (ROFATTO *et al.*, 2020a). Os *outliers* devem ser apropriadamente tratados, pois a não identificação desses *outliers* no conjunto de dados pode comprometer o nível de confiabilidade de um sistema (ROFATTO *et al.*, 2020a).

Para o tratamento de dados contendo *outliers* o procedimento estatístico *Data Snooping* (DS) – proposto por Baarda (1968) – vem sendo utilizado na Geodésia como uma prática padrão para remoção de possíveis *outliers* no conjunto de dados (ROFATTO *et al.*, 2020b). Esse procedimento de teste é frequentemente empregado em sua forma iterativa, ou seja, após a identificação e a remoção de um *outlier*, o teste é repetido até que nenhum *outlier* possa ser detectado (TEUNISSEN, 2006). A estatística de teste empregada no *Data Snooping* é dada pelo máximo valor absoluto do vetor dos resíduos padronizados (resíduos na mesma escala de valores) conhecida como *w-test* (BAARDA, 1968).

Inicialmente, o *w-test* somente faz a decisão entre a hipótese nula (H_0) e uma única hipótese alternativa (H_a), os sistemas de equações sob a hipótese nula são formulados sem a presença de *outlier*, enquanto a hipótese alternativa descreve um modelo com uma das observações sendo um *outlier*.

A fim de verificar se a hipótese alternativa é significativa ou não (ou seja, se rejeitamos ou aceitamos a hipótese nula), a estatística *w-test* é comparada com seus valores críticos (ou seja, o percentil de sua distribuição de probabilidade), podendo ser obtida por meio da distribuição normal padrão. Nesse caso, a rejeição da hipótese nula (H_0) implica na aceitação da hipótese alternativa (H_a) e vice-versa (IMPARATO; TEUNISSEN; TIBERIUS, 2019).

Considerando apenas uma hipótese alternativa (H_a), os níveis de probabilidade associado ao *Data Snooping* são restritos ao erro tipo I (rejeição de uma hipótese nula verdadeira) e erro tipo II (aceitação de uma falsa hipótese nula). A probabilidade de cometer o erro tipo I é denominada nível de significância ou taxas de falsos positivos (conhecido como α_0), controlada pelo usuário. Baarda (1968) se limitou a descrever a teoria da confiabilidade com base em cometer os erros tipo I e tipo II, porém, o *Data Snooping* é um procedimento que envolve múltiplos testes de hipóteses (TEUNISSEN; IMPARATO; TIBERIUS, 2017;

ZAMINPARDAZ; TEUNISSEN, 2019). A fim de identificar o *outlier* presente no conjunto de dados são formuladas várias hipóteses alternativas (n hipóteses alternativas), todas elas são testadas individualmente contra a hipótese nula, ou seja, testa-se H_0 contra $H_a^{(1)}, H_a^{(2)}, \dots, H_a^{(n)}$, ocorrendo o problema de múltiplos testes de hipóteses (LEHMANN, 2012).

Quando assumimos que os testes individuais são independentes e o nível de significância para cada teste (α_i) seja α_0 , então a probabilidade de que um dos testes rejeite a hipótese nula é dada em (1) (LEHMANN; LÖSLER, 2016):

$$\alpha' = 1 - \prod_{i=1}^n (1 - \alpha_i) = 1 - (1 - \alpha_0)^n \quad (1)$$

onde α' é a probabilidade de cometer um ou mais erros do tipo I ao realizar vários testes de hipóteses, conhecido como taxa de erro familiar (do inglês *family-wise error rate* – FWER). Nesse caso o nível de significância ou taxa de erro tipo I de testes individuais (α_0) não representa mais a taxa de erro do conjunto combinado de testes (denotado por α'). Quando testamos várias hipóteses alternativas, a probabilidade de rejeitar incorretamente uma hipótese nula (cometer o erro do tipo I) aumenta (MITTELHAMMER; JUDGE; MILLER, 2000).

Portanto, estamos interessados em controlar o α' . A correção Šidák (ŠIDÁK, 1967) é um dos métodos mais simples empregados para o controle da taxa de erro familiar, onde o objetivo é ajustar o nível de significância α_0 de modo que o nível de significância para toda a série de testes α' é garantido. Esse método produz uma taxa de erro familiar de exatamente α' quando os testes são independentes. Porém, na prática, o modelo matemático promove a correlação entre as estatísticas do *w-test*, ou seja, sempre teremos algum grau de correlação entre os testes (ROFATTO *et al.*, 2021). Quando negligenciamos as correlações entre as estatísticas do *w-test* (em outras palavras, entre os resíduos das observações) superestimamos os valores críticos calculados por meio da correção Šidák.

Desse modo, Rofatto *et al.* (2020a) mostraram que para controlar efetivamente o erro tipo I do *Data Snooping*, as dependências entre os resíduos estimados devem ser consideradas. Forneceram uma rotina baseada em Monte Carlo para capturar essas dependências e obter o valor crítico correspondente à probabilidade do erro tipo I fornecida pelo usuário. A desvantagem é que toda vez que o *Data Snooping* é executado, o método Monte Carlo é utilizado para realizar o cálculo dos valores críticos (ROFATTO *et al.*, 2020a).

Para solucionar esse problema, Rofatto *et al.* (2021) propuseram uma arquitetura de Rede Neural de Retropropagação Supervisionada (SBPNN) para suprimir o uso do método

Monte Carlo quando o procedimento *Data Snooping* é utilizado. Eles forneceram um tipo de rede neural (SBPNN.mat) que permite que qualquer usuário obtenha os valores críticos com rapidez e facilidade, garantindo um controle da taxa de erro tipo I ao aplicar o procedimento de teste *Data Snooping*.

No entanto, até agora os estudos foram realizados sem considerar a atualização do valor crítico no processo iterativo do *Data Snooping*, visto que para realizar o controle efetivo da taxa de erro tipo I o valor crítico deve ser atualizado todas as vezes que uma observação for identificada como *outlier* e removida do conjunto de dados, gerando uma nova matriz de correlação entre as estatísticas de teste a cada vez que o procedimento *Data Snooping* for executado.

Aqui avaliamos os efeitos da atualização do valor crítico no controle da taxa de erro tipo I no procedimento *Data Snooping* iterativo. Os valores críticos foram obtidos através de três métodos: correção Šidák (ŠIDÁK, 1967), Monte Carlo (proposto por ROFATTO *et al.*, 2020a) e SBPNN (proposto por ROFATTO *et al.*, 2021). Os experimentos foram realizados considerando uma rede fechada de nivelamento com baixa correlação entre os resíduos (correlação máxima entre os resíduos de 41,46%).

O trabalho está apresentado da seguinte forma: tópico 2, descrevemos o procedimento para obtenção do valor crítico a partir do método Monte Carlo; no tópico 3 explicamos o funcionamento da obtenção do valor crítico a partir da correção Šidák; no tópico 4 descrevemos o procedimento para obtenção do valor crítico a partir do método baseado em Redes Neurais de Retropropagação Supervisionada (SBPNN); no tópico 5 descrevemos os experimentos realizados e apresentamos os resultados e, por fim; destacamos as conclusões do trabalho.

2. UMA ABORDAGEM BASEADA EM MONTE CARLO PARA O CONTROLE DA TAXA DE ERRO TIPO I

O procedimento *Data Snooping* é frequentemente utilizado para identificação e remoção de *outliers* do conjunto de dados. A estatística de teste do *Data Snooping* (com suas múltiplas hipóteses alternativas correlacionadas) possui sua própria distribuição de probabilidade e os valores críticos não estão disponíveis. Diante dessa limitação, o DS é frequentemente aplicado usando valores críticos baseados em nível de significância para uma única hipótese alternativa, e usa esse mesmo valor para o caso de múltiplas hipóteses alternativas, impedindo que haja um controle real do nível de significância, ou seja, da taxa de erro tipo I.

Considerando o caso de múltiplas hipóteses alternativas e assumindo que os inevitáveis erros aleatórios presentes no conjunto de dados são normalmente distribuídos com expectativa zero e dispersão dada pela matriz de covariância (Q_e), a hipótese nula é dada por Eq. (2) (ROFATTO *et al.*, 2020a):

$$H_0: e \sim N(0, Q_e) \quad (2)$$

No entanto, quando o conjunto de dados está contaminado por *outliers* a hipótese nula não é válida. Não sabemos qual observação é um *outlier*, uma hipótese alternativa mais apropriada é: existe pelo menos um *outlier* no conjunto de dados (LEHMANN, 2012). Portanto, o modelo dado em Eq. (2) torna-se Eq. (3):

$$H_a^{(i)}: e_i \sim N(c_i \nabla_i, Q_e) \quad \forall i = 1, \dots, n \quad (3)$$

em que e é o vetor dos erros aleatórios; $c_i \in \mathbb{R}^{n \times 1}$ um vetor canônico que consiste exclusivamente em elementos com valores de 0 e 1, onde 1 significa que o i -ésimo *outlier* de magnitude ∇_i afeta as observações e ; 0 significa o contrário.

Estamos interessados em saber qual das hipóteses alternativas em Eq. (3) podem levar à rejeição da hipótese nula em Eq. (2) dada certa probabilidade, ou seja, testar H_0 contra $H_a^{(1)}$, $H_a^{(2)}$, ..., $H_a^{(n)}$, caracterizando um caso de múltiplas hipóteses alternativas. Neste caso, a máxima estatística de teste ($\max |w_i|$) revela a hipótese alternativa provável, o valor provável é o máximo valor absoluto entre as estatísticas de teste. Em que w_i é conhecido como *w-test* de Baarda (BAARDA, 1968) sendo definido como Eq. (4):

$$w_i = \frac{c_i^T Q_e^{-1} \hat{e}}{\sqrt{c_i^T Q_e^{-1} Q_{\hat{e}} Q_e^{-1} c_i}}, \quad \forall i = 1, \dots, n \quad (4)$$

onde $\hat{e} \in \mathbb{R}^{n \times 1}$ é o vetor advindo da solução dos mínimos quadrados para os erros de observações estimados, dado em Eq. (5):

$$\hat{e} = y - A\hat{x} \quad (5)$$

em que $y \in \mathbb{R}^{n \times 1}$ é o vetor das observações, $A \in \mathbb{R}^{n \times u}$ é a matriz design e $\hat{x} \in \mathbb{R}^{u \times 1}$ é a solução dos mínimos quadrados para o vetor dos parâmetros estimados, dado em Eq. (6):

$$\hat{x} = (A^T W A)^{-1} (A^T W y) \quad (6)$$

onde $W \in \mathbb{R}^{n \times n}$ é a matriz peso, dada por $W = \sigma_0^2 Q_e^{-1}$, em que σ_0^2 é o fator de variância. A matriz de covariância dos erros de observações estimados ($Q_{\hat{e}} \in \mathbb{R}^{n \times n}$) presente em Eq. (4) é

dada por Eq. (7):

$$Q_{\hat{e}} = \sigma_0^2 R W^{-1} \quad (7)$$

em que $R \in \mathbb{R}^{n \times u}$ é a matriz redundância obtida em Eq. (8):

$$R = I - A(A^T W A)^{-1} A^T W \quad (8)$$

sendo $I \in \mathbb{R}^{n \times u}$ a matriz identidade.

Nesse caso, aceita-se a hipótese nula se $\max|w_i| \leq k$ e rejeita-se a hipótese nula se $\max|w_i| > k$. Considerando que a hipótese nula é verdadeira, existe a probabilidade de rejeitá-la em pelo menos um teste, conhecido como taxa de erro familiar, definido como Eq. (9) (ROFATTO *et al.*, 2021):

$$FWER = \alpha' = \rho(\max|w_i| > k \mid H_0: \text{verdadeira}), \forall i = 1, \dots, n \quad (9)$$

Uma das maneiras de controlar a taxa de erro familiar é através da correção Šidák (apresentada na seção 3), porém esse método negligencia as dependências entre as estatísticas do w -test. Esse problema já foi resolvido por Lehmann (2012). Para garantir a taxa de erro de decisão tipo I (α') o valor crítico deve ser calculado por Monte Carlo, conforme demonstrado abaixo (ROFATTO *et al.*, 2020a).

- A matriz de correlação para as estatísticas de teste deve ser calculada a partir dos dados de entrada do procedimento Monte Carlo, as matrizes A e Q_e , Eq. (10):

$$R_w = \begin{pmatrix} \rho_{w1,w1} & \rho_{w1,w2} & \cdots & \rho_{w1,wn} \\ \rho_{w2,w1} & \rho_{w2,w2} & \cdots & \rho_{w2,wn} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{wn,w1} & \rho_{wn,w2} & \cdots & \rho_{wn,wn} \end{pmatrix} \quad (10)$$

onde $R_w \in \mathbb{R}^{n \times n}$ é a matriz de correlação entre as estatísticas de teste e ρ_{w_i, w_j} o coeficiente de correlação entre os pares de estatísticas do teste w , conforme apresentado em Eq. (11) (FÖRSTNER, 1981). Os elementos da diagonal da matriz R_w sempre serão iguais a 1, e os elementos fora da diagonal podem assumir valores dentro do intervalo de $[-1, 1]$ (KNIGHT *et al.*, 2010; YANG; SHEN; RIZOS, 2017);

$$\rho_{w_i, w_j} = \frac{c_i^T Q_e^{-1} Q_{\hat{e}} Q_e^{-1} c_j}{\sqrt{c_i^T Q_e^{-1} Q_{\hat{e}} Q_e^{-1} c_i} \sqrt{c_j^T Q_e^{-1} Q_{\hat{e}} Q_e^{-1} c_j}} \quad (11)$$

- Deve-se definir a distribuição de probabilidade da estatística w -test. A função densidade de probabilidade (f.d.p) atribuída para as estatísticas do w -test, sob a hipótese nula (H_0), é descrita conforme Förstner (1981), Yang; Shen; Rizos (2017) e Imparato; Teunissen; Tiberius (2019), Eq. (12):

$$(w_1, w_2, w_3, \dots, w_n)^T \sim N(0, R_w) \quad (12)$$

- Para ter as estatísticas do w -test sob a hipótese nula (H_0), emprega-se o algoritmo Mersenne Twister (MATSUMOTO; NISHIMURA, 1998) para gerar sinteticamente as sequências de números aleatórios uniformemente distribuídos no intervalo de 0 a 1 e, em seguida, é utilizado o método de transformação Box-Muller (BOX; MULLER, 1958) para transformar os números em uma distribuição normal Eq. (13):

$$(w_1, w_2, w_3, \dots, w_n)^{T(1)}, (w_1, w_2, w_3, \dots, w_n)^{T(2)} \dots, (w_1, w_2, w_3, \dots, w_n)^{T(m)} \quad (13)$$

- Para cada sequência (amostra de w_i) descrita na equação acima, deve-se calcular o valor da máxima estatística do teste w -test, conforme Eq. (14):

$$\left(\max_{i \in \{1, \dots, n\}} |w_i|^{(1)}, \max_{i \in \{1, \dots, n\}} |w_i|^{(2)}, \dots, \max_{i \in \{1, \dots, n\}} |w_i|^{(m)} \right) \quad (14)$$

- Os valores de $\max |w_i|$ dados na etapa acima são classificados em ordem crescente, conforme Eq. (15). Denota-se \tilde{w} essa sequência ordenada e fornece uma representação discreta da função de densidade cumulativa de $\max |w_i|$:

$$\tilde{w}^{(1)} < \tilde{w}^{(2)}, \tilde{w}^{(3)}, \dots, < \tilde{w}^{(m)} \quad (15)$$

- E, por fim, determina-se o valor crítico \hat{k} por Eq. (16):

$$\hat{k} = \tilde{w}_{[(1-\alpha) \times m]} \quad (16)$$

O procedimento para obtenção do valor crítico baseado em simulação Monte Carlo considera a correlação entre as estatísticas do w -test. A desvantagem é que toda vez que o

procedimento *Data Snooping* é executado, o método Monte Carlo é usado para calcular os valores críticos (ROFATTO *et al.*, 2020a) gerando um aumento do computacional.

Para o controle efetivo da taxa de erro de decisão tipo I, o valor crítico deve ser atualizado todas as vezes que uma observação for identificada como *outlier* e removida do conjunto de dados, gerando uma nova matriz de correlação entre as estatísticas de teste, dada na Eq. (10), e o procedimento para o cálculo do valor crítico será realizado novamente, calculando um novo valor crítico até que todos os *outliers* sejam removidos do conjunto de dados.

Até aqui nenhum trabalho investigou quais são os efeitos da atualização do valor crítico na atuação do procedimento *Data Snooping*, portanto, realizamos a atualização do valor crítico e avaliamos os seus efeitos no desempenho do procedimento *Data Snooping*.

3. OBTENÇÃO DO VALOR CRÍTICO POR MEIO DA CORREÇÃO ŠIDÁK

A correção Šidák (ŠIDÁK, 1967) é um dos métodos mais simples empregado para controlar a taxa de erro familiar ou também conhecido como erro de decisão tipo I. A correção Šidák é derivada assumindo que os testes individuais são independentes como segue na Eq. (17):

$$\alpha_0 = 1 - (1 - \alpha')^{\frac{1}{n}} \quad (17)$$

O objetivo da correção Šidák é ajustar α_0 para que o nível de significância para toda a série de testes α' seja garantido. A correção Šidák produz uma taxa de erro familiar de exatamente α' quando os testes são independentes e todas as hipóteses nulas são verdadeiras. Nesse caso, os valores críticos para as estatísticas de teste podem ser calculados conforme Eq. (18).

$$k_{sid} = \Phi_N^{-1} \left[\left(1 - \frac{\alpha'}{2} \right)^{\frac{1}{n}} \right] \quad (18)$$

onde Φ_N^{-1} é o inverso da distribuição cumulativa normal padrão. O número dois no denominador é porque o *w-test* é um teste bilateral. Esses valores críticos podem ser facilmente obtidos em qualquer software que tenha a tabela normal implementada em sua rotina.

O cálculo do valor crítico dado em Eq. (18) superestima os valores críticos, negligenciando a correlação entre as estatísticas de teste. Na prática, sempre existe algum grau de correlação entre os testes (LEHMANN, 2013). Portanto, os valores críticos calculados por

meio da correção Šidák são superestimados, pois a correlação entre as estatísticas de teste é negligenciada, não sendo um bom método para cálculo do valor crítico considerando redes com alta correlação entre as estatísticas de teste.

4. UMA ABORDAGEM BASEADA EM REDES NEURAIS PARA O CONTROLE DA TAXA DE ERRO TIPO I

Rofatto *et al.* (2021) desenvolveram um modelo para cálculo do valor crítico baseado em redes neurais artificiais. O modelo proposto foi criado considerando como entrada o nível de significância geral (α'), o número de observações (n) e a correlação entre os testes ($|\rho_{w_i, w_j}|$) e como saída os valores críticos (\hat{k}) calculados conforme o método Monte Carlo. A Figura 1 apresenta a topologia da rede neural construída.

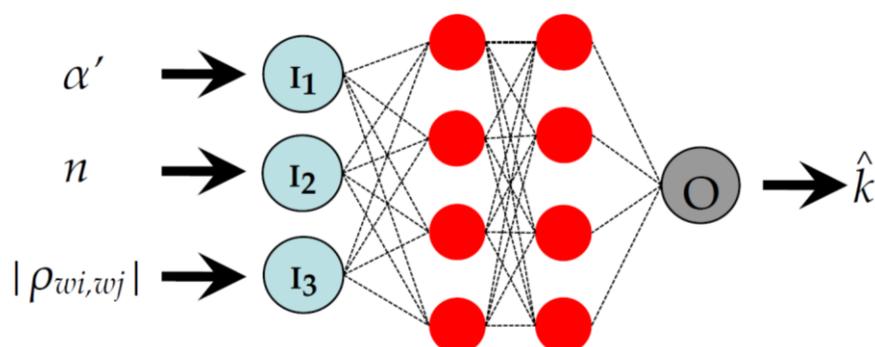


FIGURA 1. Topologia da Rede Neural para cálculo do valor crítico dada por Rofatto *et al.* (2021).

No total, 1.200 valores críticos para o procedimento de teste *Data Snooping* foram calculados e armazenados. Por exemplo, a Figura 2 apresenta um exemplo do comportamento dos valores críticos para os casos extremos $\alpha'=0,001$ e $\alpha'=0,5$ em função do número de observações (n) e a correlação entre os testes ($|\rho_{w_i, w_j}|$).

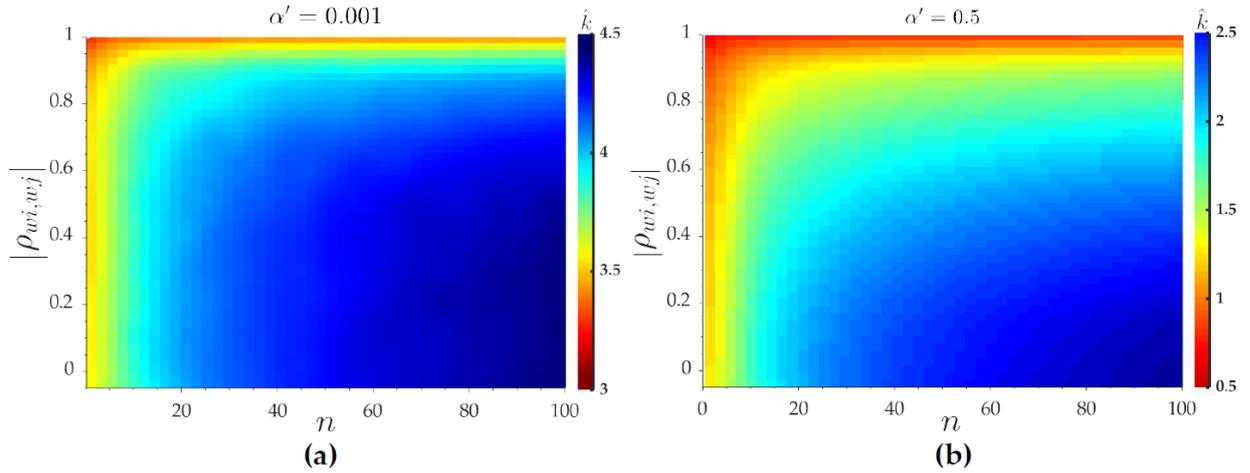


FIGURA 2. Valores Críticos do procedimento *Data Snooping* calculados por meio do método Monte Carlo para $\alpha'=0,001$ (a) e $\alpha' =0,5$ (b) dado por Rofatto *et al.* (2021).

Em geral, tem-se a seguinte relação, dada em Eq. (19) e Eq. (20), entre o número de observações (n), a correlação entre os testes ($|P_{wi}, w_j|$) e os valores críticos (ROFATTO *et al.*, 2021), onde \uparrow significa aumento e \downarrow significa decréscimo.

$$\uparrow \rho_{wi,wj} \rightarrow \downarrow \hat{k} \text{ e } \uparrow n \rightarrow \uparrow \hat{k} \text{ or } \downarrow \rho_{wi,wj} \rightarrow \uparrow \hat{k} \text{ e } \downarrow n \rightarrow \downarrow \hat{k} \quad (19)$$

$$\downarrow \rho_{wi,wj} \text{ e } \uparrow n \rightarrow \uparrow \hat{k} \text{ or } \uparrow \rho_{wi,wj} \text{ e } \downarrow n \rightarrow \downarrow \hat{k} \quad (20)$$

Conforme a Figura 2 nota-se que os valores críticos independem do número de observações (n) quando a correlação entre os testes é maior que 0,99 ($|P_{wi}, w_j| > 0,99$), fato este também apresentado por Yang *et al.* (2013). Quando o número de observações é maior que 30 ($n > 30$) e para uma dada correlação entre os testes, os valores críticos se tornam constantes (ROFATTO *et al.*, 2021).

A rede neural foi construída a partir de um conjunto de dados, sendo utilizados os níveis de significância geral ($\alpha'=0,001$, $\alpha'=0,01$, $\alpha'=0,05$, $\alpha'=0,1$ e $\alpha'=0,5$), número de observações ($n=5$ a $n=100$, com um incremento de 5) e correlação entre as estatísticas de teste $|P_{wi}, w_j|=0,0$ a $|P_{wi}, w_j|=1,0$ com incremento de 0,1 e como resultados os valores críticos calculados por meio do método Monte Carlo.

Os valores críticos baseados em SBPNN foram obtidos conforme a Eq. (21) e Eq. (22) dada por Rofatto *et al.* (2021).

$$k_{SBPNN(max_{eig})} = k_{SBPNN(pc)} \quad (21)$$

$$pc = \sqrt{\frac{max_{eig}(R_w)}{n}} \quad (22)$$

onde $k_{SBPNN}(\cdot)$ é o valor crítico geral baseado na rede neural e max_{eig} o valor crítico baseado em SBPNN obtido da raiz quadrada da razão entre os maiores autovalores da matriz de correlação (R_w) e o número de observações (n). O maior autovalor representa a quantidade máxima de informações da matriz de correlação (R_w) e pode ser facilmente obtido usando o comando “eigs” do software *Matlab*.

As expressões acima são calculadas para um dado nível de significância (α') e número de observação (n). Rofatto *et al.* (2021) mostraram que o critério baseado no próprio valor máximo (max_{eig}), dado pela Eq. (21), é o que melhor se aproxima do Monte Carlo, ou seja, é mais adequado para descrever a correlação geral das redes geodésicas, uma vez que as redes geodésicas possuem várias correlações entre as estatísticas de teste, representadas pela matriz de correlação R_w .

Portanto, o critério max_{eig} é apropriado para ser utilizado como um critério de entrada para correlação entre as estatísticas da rede neural e foi o critério utilizado aqui para o cálculo do valor crítico utilizando redes neurais. A rede neural foi construída para calcular os valores críticos para qualquer matriz de correlação (R_w), mais detalhes sobre a rede neural podem ser encontrados em Rofatto *et al.* (2021).

5. EXPERIMENTOS E RESULTADOS

Os experimentos foram realizados com o objetivo de analisar o impacto da atualização dos valores críticos a cada rodada do procedimento *Data Snooping*, calculados com base nos modelos SBPNN (apresentado na seção 4), correção Šidák (apresentado na seção 3) e Monte Carlo (apresentado na seção 2). Em seguida, aplicamos o método desenvolvido por Rofatto *et al.* (2020a) para analisar a taxa de identificação de *outliers* do *Data Snooping* com base nos valores críticos calculados pelos três métodos.

Os experimentos foram realizados considerando uma rede fechada de nivelamento (Figura 3) com 10 observações ($n = 10$), 4 parâmetros ($u = 4$) e baixa correlação entre os resíduos, apresentando uma correlação mínima entre os resíduos de 2,23% e uma correlação máxima entre os resíduos de 41,46%.

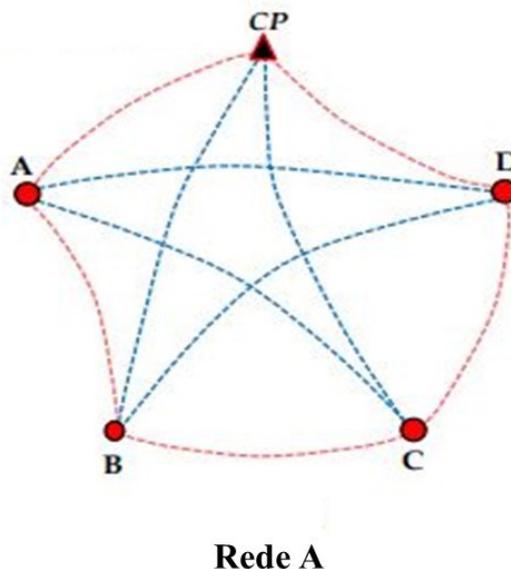


FIGURA 3. Configuração da rede de nivelamento utilizada dada em Rofatto; Matsuoka; Klein (2018).

5.1 Avaliação da atualização dos valores críticos obtidos por meio dos métodos Monte Carlo, SBPNN e correção ŠIDÁK

O objetivo é investigar os efeitos da atualização dos valores críticos, calculados por meio do modelo SBPNN, correção Šidák e Monte Carlo em cada iteração do procedimento *Data Snooping*, visto que para o controle efetivo do erro tipo I o valor crítico deve ser atualizado sempre que uma observação for identificada como *outlier* e removida do conjunto de dados.

Para isso, os valores críticos atualizados foram calculados por meio de três métodos: modelo SBPNN da Rede Neural de Retropropagação Supervisionada (K_{SBPNN}), Correção Šidák (K_{Sid}) e Monte Carlo (K_{MC}). Consideramos as taxas de erro de decisão Tipo I de $\alpha=0,001$ (0,1%), $\alpha=0,01$ (1%) e $\alpha=0,1$ (10%).

Primeiramente os valores críticos foram calculados considerando os três métodos (modelo SBPNN, correção Šidák e Monte Carlo) sem considerar a atualização do valor crítico, conforme apresentado na Tabela 1.

TABELA 1. Valores críticos não atualizados.

α'	Rede A		
	K_{SBPNN}	K_{Sid}	K_{MC}
0,001	3,8600	3,8905	3,8835
0,01	3,2500	3,2899	3,2805
0,1	2,4600	2,5679	2,5186

Em seguida os valores críticos foram calculados considerando a sua atualização para o caso de uma exclusão (Tabela 2) e duas exclusões (Tabela 3). As exclusões foram realizadas de forma proposital considerando todas as combinações possíveis. Assim, para uma exclusão obtivemos 10 combinações, e para duas exclusões obtivemos 45 combinações possíveis sem repetição.

TABELA 2. Valores críticos atualizados para o caso de uma exclusão

	Caso de 1 exclusão								
	$\alpha = 0,001$			$\alpha = 0,01$			$\alpha = 0,1$		
	K_{SBPNN}	K_{Sid}	K_{MC}	K_{SBPNN}	K_{Sid}	K_{MC}	K_{SBPNN}	K_{Sid}	K_{MC}
Máximo	3,8400	3,8649	3,8623	3,2200	3,2601	3,2446	2,4200	2,5312	2,4685
Mínimo	3,8400	3,8649	3,8542	3,2100	3,2601	3,2399	2,4100	2,5312	2,4672
Média	3,8400	3,8649	3,8593	3,2151	3,2601	3,2416	2,4150	2,5312	2,4679

TABELA 3. Valores críticos atualizados para o caso de duas exclusões

	Caso de 2 exclusões								
	$\alpha = 0,001$			$\alpha = 0,01$			$\alpha = 0,1$		
	K_{SBPNN}	K_{Sid}	K_{MC}	K_{SBPNN}	K_{Sid}	K_{MC}	K_{SBPNN}	K_{Sid}	K_{MC}
Máximo	3,8100	3,8361	3,8330	3,1800	3,2266	3,2019	2,3600	2,4898	2,4065
Mínimo	3,8361	3,8361	3,7899	3,1700	3,2266	3,1639	2,3500	2,4898	2,3708
Média	3,8100	3,8361	3,8062	3,1767	3,2266	3,1782	2,3567	2,4898	2,3833

As figuras 4, 5 e 6 apresentam a atualização dos valores críticos de acordo com as combinações e exclusões realizadas, considerando os níveis de significância de 0,001 (0,1%), 0,01 (1%) e 0,1 (10%). Nota-se que para os valores críticos calculados por meio da correção Šidák são constantes, pois dependem somente do número de observações. E também não

existem diferenças significativas entre os valores críticos considerando o caso de 1 exclusão e 2 exclusões.

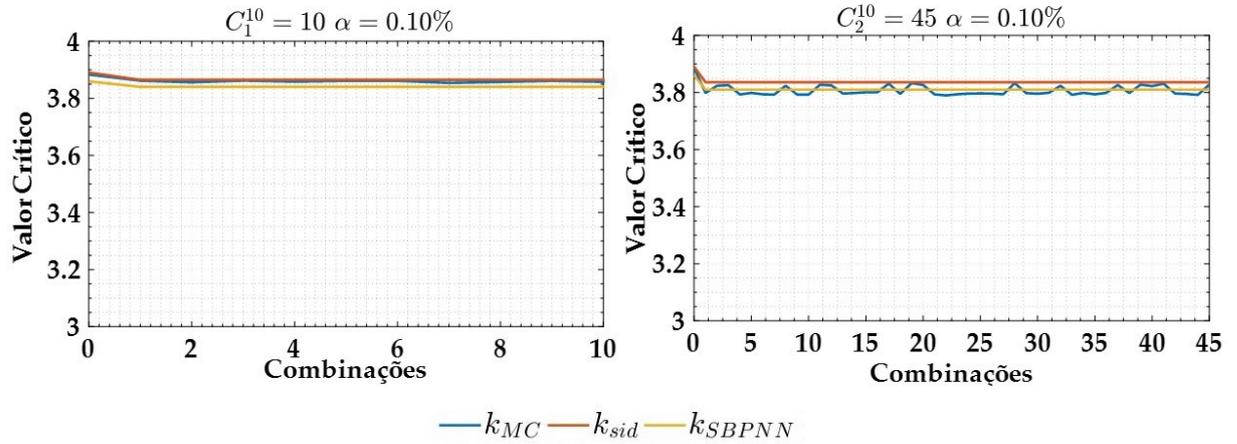


FIGURA 4. Valores críticos atualizados considerando 1 exclusão (10 combinações) e 2 exclusões (45 combinações) para o nível de significância de 0,1%.

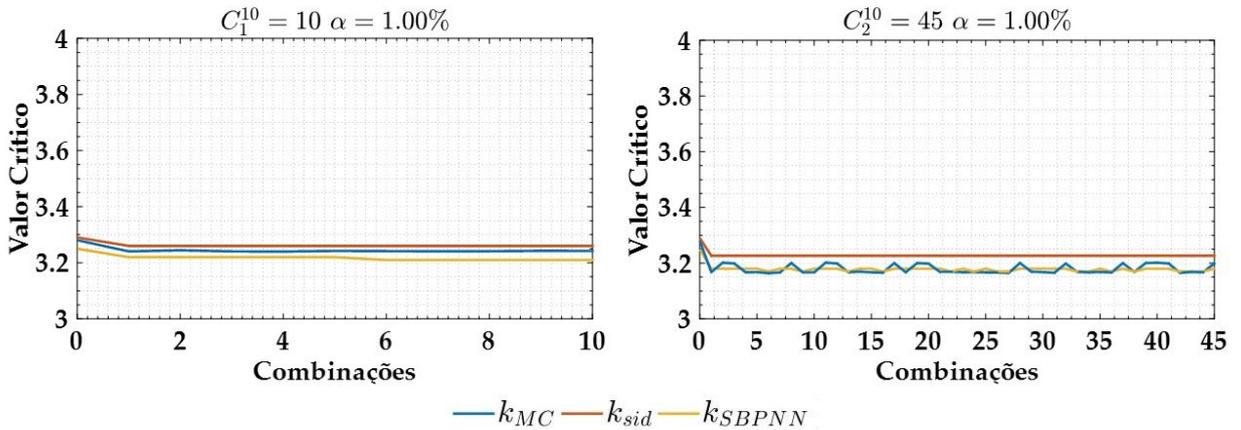


FIGURA 5. Valores críticos atualizados considerando 1 exclusão (10 combinações) e 2 exclusões (45 combinações) para o nível de significância de 1%.

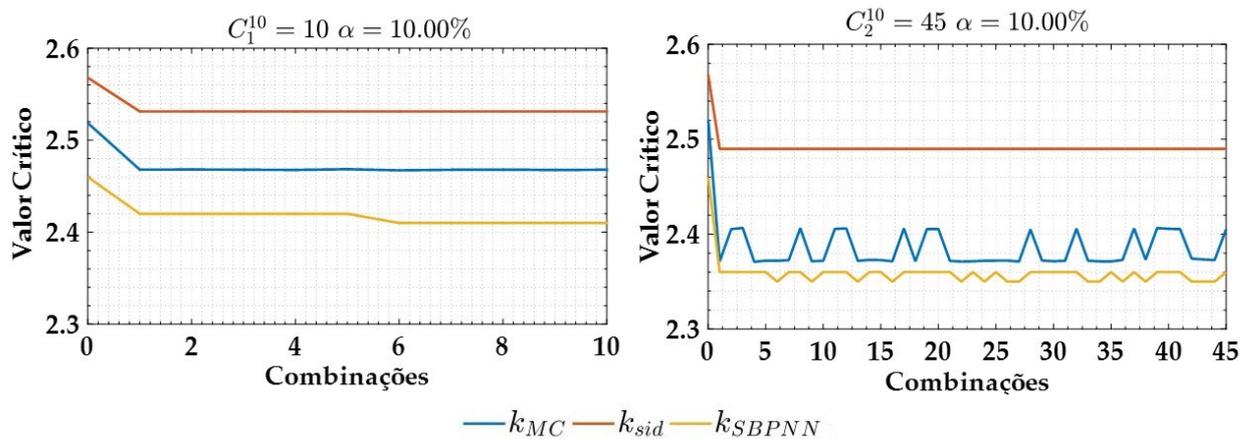


FIGURA 6. Valores críticos atualizados considerando 1 exclusão (10 combinações) e 2 exclusões (45 combinações) para o nível de significância de 10%.

Em seguida calculamos a diferença entre os valores críticos não atualizados e os valores críticos atualizados considerando o caso de uma exclusão e duas exclusões, a fim de verificar se existem diferenças significativas, conforme mostrado na Tabela 4.

TABELA 4. Diferença entre os valores críticos não atualizados e atualizados considerando o caso de 1 exclusão e 2 exclusões.

α'	1 exclusão			2 exclusões		
	ΔK_{SBPNN}	ΔK_{Sid}	K_{MC}	ΔK_{SBPNN}	ΔK_{Sid}	K_{MC}
0,001	0,0389	0,0507	0,0242	0,1023	0,1353	0,0773
0,01	0,0349	0,0450	0,0200	0,0733	0,1033	0,0500
0,1	0,0298	0,0367	0,0256	0,0633	0,0781	0,0544

Notamos que considerando as taxas de erro tipo I menores que 0,1% (10%) a atualização do valor crítico considerando uma exclusão (10 combinações possíveis) e duas exclusões (45 combinações possíveis), não apresentam diferenças significativas quando comparados aos valores críticos não atualizados.

Avaliamos também as taxas de correta identificação do *Data Snooping*, a partir dos valores críticos atualizados calculados por meio dos métodos SBPNN, correção Šidák e Monte Carlo.

5.2 Avaliação da taxa de sucesso do *Data Snooping* com base nos valores críticos atualizados obtidos através dos métodos Monte Carlo, SBPNN e correção ŠIDÁK

Avaliamos as taxas de sucesso do *Data Snooping* com base nos valores críticos atualizados calculados por meio dos métodos SBPNN, correção Šidák e Monte Carlo. As probabilidades de correta identificação obtidas por meio dos valores críticos atualizados a partir dos três métodos foram comparadas a essas probabilidades obtidas com base nos valores críticos não atualizados para cada magnitude de *outlier* e taxas de falsos positivos.

As diferenças entre as probabilidades de correta identificação (ΔP_{CI}) obtidas através dos valores críticos atualizados e não atualizados, calculados por meio dos métodos SBPNN, correção Šidák e Monte Carlo, foram calculadas para a rede (Figura 7).

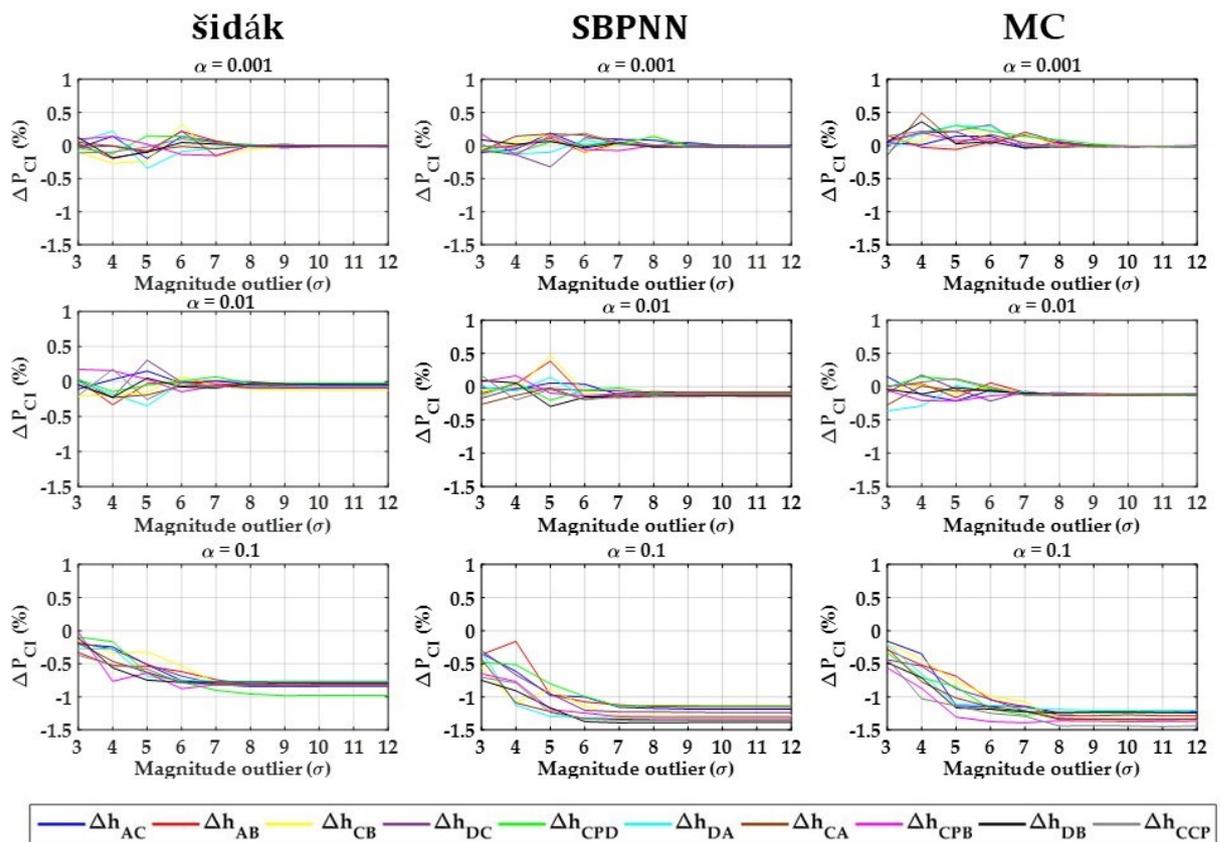


FIGURA 7. Diferenças da probabilidade de correta identificação (P_{CI}) do Data Snooping obtidas por meio dos valores críticos atualizados e não atualizados, calculados pelo método SBPNN (K_{SBPNN}), correção Šidák (K_{Sid}) e Monte Carlo (K_{MC}) para a rede de nivelamento.

Para o caso da rede de nivelamento analisada, as diferenças entre a probabilidade de correta identificação (P_{CI}) obtidas a partir da atualização e não atualização do valor crítico não é significativa ($\Delta P_{CI} < 0,5\%$), considerando os níveis de significância menores que 10%. A seguir são apresentados os valores de MIBs obtidos para cada método considerando os valores críticos não atualizados (Tabela 5) e os valores críticos atualizados (Tabela 6).

TABELA 5. MIB considerando uma taxa de sucesso $\geq 80\%$ e a não atualização do valor crítico.

MIB (σ) – REDE A						
α'	Observações Externas			Observações Internas		
	K_{SBPNN}	K_{Sid}	K_{MC}	K_{SBPNN}	K_{Sid}	K_{MC}
0,001	6,6	6,6	6,6	5,7	5,8	5,8
0,01	5,8	5,8	5,8	5,0	5,3	5,0
0,1	5,4	5,3	5,3	4,6	4,6	4,6

TABELA 6. MIB considerando uma taxa de sucesso $\geq 80\%$ e a atualização do valor crítico.

MIB (σ) – REDE A (σ)						
α'	Observações Externas			Observações Internas		
	K_{SBPNN}	K_{Sid}	K_{MC}	K_{SBPNN}	K_{Sid}	K_{MC}
0,001	6,7	6,7	6,7	5,7	5,8	5,8
0,01	5,8	5,8	5,8	5,0	5,1	5,0
0,1	5,7	5,5	5,4	4,7	4,6	4,7

Em seguida calculamos as diferenças absolutas entres os valores de MIB sem a atualização do valor crítico e considerando a atualização do valor crítico, conforme apresentado na Tabela 7.

TABELA 7. Diferenças entre MIBs considerando uma taxa de sucesso $\geq 80\%$.

ΔMIB (σ) (diferenças absolutas) – Rede A						
α'	Observações Externas			Observações Internas		
	K_{SBPNN}	K_{Sid}	K_{MC}	K_{SBPNN}	K_{Sid}	K_{MC}
0,001	0,1	0,1	0,1	0,0	0,0	0,0
0,01	0,0	0,0	0,0	0,0	0,2	0,0
0,1	0,3	0,2	0,1	0,1	0,0	0,1

Para α' menores que 10% a atualização do valor crítico não causa impactos nas taxas de correta identificação do procedimento *Data Snooping*, conseqüentemente não causa impactos no MIB, apresentando uma máxima diferença absoluta de $0,3\sigma$. Nota-se que em alguns casos a diferença absoluta foi nula.

Em relação ao custo computacional, considerando o método Monte Carlo, a atualização do valor crítico gera um custo computacional maior, dado que a matriz de correlação é atualizada a cada iteração do procedimento *Data Snooping*, porém Rofatto *et al.* (2021) demonstraram que o valor crítico pode ser obtido por meio das Redes Neurais Artificiais, obtendo resultados de maneira quase instantânea.

Neste trabalho a questão central foi avaliar se a atualização do valor crítico interferiu no procedimento *Data Snooping*, os experimentos realizados e os resultados encontrados mostraram que para $\alpha' < 10\%$ a atualização do valor crítico não causa efeitos significativos, como pode ser observado na Tabela 3 e na Figura 4.

6. CONSIDERAÇÕES FINAIS

Nesta pesquisa avaliamos se a atualização do valor crítico a partir dos métodos SBPNN, correção Šidák e Monte Carlo afetou o procedimento *Data Snooping*, destacamos a seguinte conclusão:

- Considerando níveis de significância menores ou iguais a 10% ($\alpha' \leq 10\%$), a atualização do valor crítico considerando o caso de 1 exclusão e 2 exclusões não apresentam diferenças significativas quando comparados com os valores críticos não atualizados, apresentando uma diferença máxima de $\Delta K_{SBPNN}=0,0389$ ($\alpha = 0,001$), $\Delta K_{sid}=0,0507$ ($\alpha = 0,001$) e $\Delta K_{MC}=0,0256$ ($\alpha = 0,1$) para o caso de uma exclusão e uma diferença máxima de $\Delta K_{SBPNN}=0,1023$ ($\alpha = 0,001$), $\Delta K_{sid}=0,1353$ ($\alpha = 0,001$) e $\Delta K_{MC}=0,0773$ ($\alpha = 0,001$) para o caso de 2 exclusões.

Para a avaliação da taxa de sucesso do *Data Snooping* com base nos valores críticos obtidos por Monte Carlo, SBPNN e correção Šidák, destacamos a seguinte conclusão:

- A atualização do valor crítico não causa diferenças nas taxas de correta identificação de *outliers*, apresentando um ΔP_{CI} máximo $< 0,5\%$ para a rede de nivelamento e conseqüentemente não causa impactos nos valores de MIB, possuindo uma diferença de máxima de $0,3\sigma$.

REFERÊNCIAS

- BAARDA, W. A. Testing Procedure for Use in Geodetic Networks. **Publications on Geodesy**, v. 2, n.5, 97 p., 1968.
- BOX, G.E.P., MULLER, M.E. A note on the generation of random normal deviates. **The annals of mathematical statistics**, v. 29, p. 610–611, 1958. DOI: <https://doi.org/10.1214/aoms/1177706645>.
- FÖRSTNER, W. Reliability and discernability of extended Gauss-Markov models. In: **Proceedings of the International Symposium on Geodetic Networks and Computations**, n. 258. Deutsche Geodätische Kommission, Reihe B, 1981. Disponível em: <<http://www.ipb.uni-bonn.de/pdfs/Forstner1981Reliability.pdf>>. Acesso em: 10 out. 2021.
- IMPARATO, D., TEUNISSEN, P. J. G., TIBERIUS, C. C. J. M., 2019. Minimal detectable and identifiable biases for quality control. **Survey review**, v. 51, p. 289–299. 2019. DOI: <https://doi.org/10.1080/00396265.2018.1437947>
- KLEIN, I.; MATSUOKA, M. T.; GUZATTO, M. P.; NIEVINSKI, F. G. An approach to identify multiple outliers based on sequential likelihood ratio tests. **Survey Review**, v. 49, n. 357, p. 449-457, 2017. DOI. <https://doi.org/10.1080/00396265.2016.1212970>
- KNIGHT, N.L., WANG, J., RIZOS, C. Generalised measures of reliability for multiple outliers. **Journal of geodesy**, v. 84, p. 625– 635, 2010. DOI: <https://doi.org/10.1007/s00190-010-0392-4>
- LEHMANN, R. Improved critical values for extreme normalized and studentized residuals in Gauss Markov models. **Journal of Geodetic Science**, v. 86, n. 12, p. 1137–1146, 2012. DOI: <https://doi.org/10.1007/s00190-012-0569-0>
- LEHMANN, R. On the formulation of the alternative hypothesis for geodetic outlier detection. **Journal of geodesy**, v. 87, p. 373–386, 2013. DOI: <https://doi.org/10.1007/s00190-012-0607-y>
- LEHMANN, R., LÖSLER, M. Multiple outlier detection: hypothesis tests versus model selection by information criteria. **Journal of surveying engineering**, v. 142, 2016. DOI: [https://doi.org/10.1061/\(ASCE\)SU.1943-5428.0000189](https://doi.org/10.1061/(ASCE)SU.1943-5428.0000189)
- MATSUMOTO, M., NISHIMURA, T. Mersene Twister: A 623-dimensionally equidistributed uniform pseudo-random number generator. **ACM Transactions on Modeling and Computer Simulation**, v. 8, n. 1, p. 3-30, 1998. DOI. <https://doi.org/10.1145/272991.272995>
- MITTELHAMMER, R.C., JUDGE, G.G., MILLER, D.J. **Econometric foundations**. 1st ed. New York, NY: Cambridge University Press, 2000.
- ROFATTO, V., MATSUOKA, M., KLEIN, I. Design of geodetic networks based on outlier identification criteria: an example applied to the leveling network. **Bulletin geodetic science**, v. 24, n. 2, p. 152–170, 2018. DOI: <https://doi.org/10.1590/S1982-21702018000200011>

ROFATTO, V. F.; MATSUOKA, M. T.; KLEIN, I.; VERONEZ, M. R., DA SILVEIRA, L. G. A Monte Carlo Based outlier diagnosis method for sensitivity analysis. **Remote Sensing**, v. 12, n. 5, p. 1-41, 2020a. DOI: <https://doi.org/10.3390/rs12050860>. Disponível em: <<https://www.mdpi.com/2072-4292/12/5/860>>. Acesso em: 5 ago. 2021.

ROFATTO, V. F.; MATSUOKA, M. T.; KLEIN, I.; VERONEZ, M. R.; BONIMANI, M. L.; LEHMANN, R. A half-century of Baarda's concept of reliability: a review, new perspectives, and applications. **Survey Review**, v. 52, n. 372, p. 261-277, 2020b. DOI: <https://doi.org/10.1080/00396265.2018.1548118>

ROFATTO, V. F.; MATSUOKA, M. T., KLEIN, I., BONIMANI, M. L. S., RODRIGUES, B. P., CAMPOS, C. C., VERONEZ, M. R., SILVEIRA JR, L. G. An Artificial Neural Network-based Critical Values for Multiple Hypothesis Testing: Data Snooping case. **Survey Review**, v. 53, p. 1-16, 2021. DOI: <https://doi.org/10.1080/00396265.2021.1968176>

ŠIDÁK, Z. Rectangular confidence regions for the means of multivariate normal distributions. **Journal of the american statistical association**, v. 62, n.318, p. 626–633, 1967. DOI: <https://doi.org/10.2307/2283989>

TEUNISSEN, P.J.G., IMPARATO, D., TIBERIUS, C.C.J.M. Does RAIM with correct exclusion produce unbiased positions? **Sensors**, v. 17, n.7, p. 1-16, 2017. DOI: <https://doi.org/10.3390/s17071508>. Disponível em: < <https://www.mdpi.com/1424-8220/17/7/1508/htm> >. Acesso em: 6 nov. 2021

TEUNISSEN, P. **Testing Theory: an introduction**. 2º ed. Delft University Press, 2006.

YANG, L.; WANG, J.; KNIGHT, N. L.; SHEN, Y. Outlier separability analysis with a multiple alternative hypotheses test. **Journal of Geodesy Science**, v. 87, n. 6, p. 591–604, 2013. DOI: <https://doi.org/10.1007/s00190-013-0629-0>

YANG, L., LI, B., SHEN, Y., RIZOS, C. Extension of internal reliability analysis regarding separability analysis. **Journal of surveying engineering**, v. 143, n. 3, 2017. DOI: [https://doi.org/10.1061/\(ASCE\)SU.1943-5428.0000220](https://doi.org/10.1061/(ASCE)SU.1943-5428.0000220)

ZAMINPARDAZ, S., TEUNISSEN, P. DIA-data snooping and identifiability. **Journal of geodesy**, v. 93, p. 85–101, 2019. DOI: <https://doi.org/10.1007/s00190-018-1141-3>