

O objetivo desta pesquisa foi avaliar a aplicabilidade de redes neurais artificiais (RNAs) do tipo Multilayer Perceptron para previsão da profundidade da água de forma espacializada na planície urbana de Lages/SC, no escopo de um sistema de alerta a inundações para a região. Os hidrogramas dos eventos foram obtidos por simulação hidrológica no HEC-HMS 4.6, e os dados de profundidade de água foram obtidos de simulação hidrodinâmica no HEC-RAS 5.0.6. Os vetores de entrada da rede foram compostos por séries de precipitação, vazão e profundidade de água. Os modelos de RNA foram utilizados para prever a profundidade da água entre 3 e 20 horas a frente em oito locais de monitoramento distribuídos na planície de inundação urbana. Foram testados modelos de RNAs de saídas simples ou saídas múltiplas. Previsões realizadas com RNAs de saídas simples para alcances de 3, 8, 14 e 20 horas apresentaram, em média, coeficientes de Nash-Sutcliffe (NS) de 0,99; 0,98; 0,89; 0,77; média do erro absoluto (MAE) de 4; 11; 28; 40 cm, e PBIAS de -0,50; -0,61; 1,12; 2,03%, respectivamente. Utilizar dados gerados por um modelo hidrodinâmico mostrou-se viável para treinamento e verificação dos modelos de RNAs. Os resultados das RNAs de saídas múltiplas apresentaram variações menos drásticas nos erros dos modelos, conferindo maior estabilidade e confiabilidade aos resultados. Realizar a previsão da profundidade da água em locais de monitoramento distribuídos dentro da área urbana inundada, pode ser, portanto, uma alternativa para aumentar a capacidade de resposta operacional da defesa civil e proporcionar uma maior eficiência nos processos de tomada de decisão durante eventos de inundação.

Orientador: Prof. Dr. Silvio Luís Rafaeli Neto
Coorientador: Prof. Dr. Olavo Correa Pedrollo

Lages, 2021

ANO
2021

RENATA BULLING MAGRO | APLICAÇÃO DE REDES NEURAS ARTIFICIAIS PARA
PREVISÃO DE INUNDAÇÃO EM UMA ÁREA URBANA



UDESC

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS AGROVETERINÁRIAS - CAV
PROGRAMA DE PÓS GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS

DISSERTAÇÃO DE MESTRADO

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS PARA PREVISÃO DE INUNDAÇÃO EM UMA ÁREA URBANA

RENATA BULLING MAGRO

LAGES, 2021

UNIVERSIDADE DO ESTADO DE SANTA CATARINA – UDESC
CENTRO DE CIÊNCIAS AGROVETERINÁRIAS – CAV
PÓS – GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS – PGCAMB

RENATA BULLING MAGRO

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE
INUNDAÇÃO EM UMA ÁREA URBANA

LAGES

2021

RENATA BULLING MAGRO

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE
INUNDAÇÃO EM UMA ÁREA URBANA**

Dissertação apresentada ao Curso de Pós-graduação em Ciências Ambientais do Centro de Ciências Agroveterinárias, da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do grau de Mestre em Ciências Ambientais.

Orientador: Prof. Dr. Sílvio Luís Rafaeli Neto

Coorientador: Prof. Dr. Olavo Correa Pedrollo

LAGES

2021

**Ficha catalográfica elaborada pelo programa de geração automática da
Biblioteca Setorial do CAV/UEDESC,
com os dados fornecidos pelo(a) autor(a)**

Magro, Renata Bulling

Aplicação de redes neurais artificiais para previsão de
inundação em uma área urbana / Renata Bulling Magro. -- 2021.
133 p.

Orientador: Silvio Luis Rafaeli Neto

Coorientador: Olavo Correa Pedrollo

Dissertação (mestrado) -- Universidade do Estado de Santa
Catarina, Centro de Ciências Agroveterinárias, Programa de
Pós-Graduação em Ciências Ambientais, Lages, 2021.

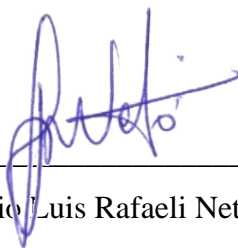
1. Inundações urbanas. 2. Simulação hidrodinâmica. 3. Redes
neurais artificiais. 4. Sistema de alerta. I. Luis Rafaeli Neto, Silvio .
II. Correa Pedrollo, Olavo. III. Universidade do Estado de Santa
Catarina, Centro de Ciências Agroveterinárias, Programa de
Pós-Graduação em Ciências Ambientais. IV. Título.

RENATA BULLING MAGRO

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA PREVISÃO DE
INUNDAÇÃO EM UMA ÁREA URBANA**

Dissertação apresentada ao Curso de Pós-graduação em Ciências Ambientais do Centro de Ciências Agroveterinárias, da Universidade do Estado de Santa Catarina, como requisito parcial para obtenção do grau de Mestre em Ciências Ambientais.

BANCA EXAMINADORA



Prof. Dr. Silvio Luis Rafaeli Neto – UDESC
Orientador

Membros:



Prof. Dr. Masato Kobayama
IPH - UFRGS



Prof. Dr. Guilherme Garcia de Oliveira
IPH - UFRGS

Lages, 17 de dezembro de 2021

AGRADECIMENTOS

Agradeço aos meus pais, Irineu e Adriana, por me incentivarem nessa jornada de estudos e por abrirem todos os caminhos possíveis para o meu desenvolvimento, sempre apoiando minhas decisões e demonstrando a importância do conhecimento para nossa evolução. Agradeço também à minha irmã, Júlia, que com seu senso de humor singular, sempre me ajudou a rir da vida.

Ao meu orientador, Prof. Dr. Silvio Luis Rafaeli Neto, por toda atenção e paciência ao longo da jornada de graduação e mestrado e pelos imensuráveis ensinamentos acadêmicos, que reverberaram, de uma forma ou de outra, na minha vida pessoal e me fizeram amadurecer.

Ao meu coorientador, Prof. Dr. Olavo Correa Pedrollo, pela atenção dedicada à esta pesquisa e à minha orientação. Por não medir esforços para passar o conhecimento à diante, e por ser um grande incentivador e entusiasta da ciência, sendo fonte de inspiração ao longo desse tempo.

Aos amigos que foram pontos de apoio e segurança durante esse período. Aos que me acompanharam desde a graduação, Mariana Gomes Oliveira, Emili Schutz e Eduardo Duminelli, Máisa Koch, Camila Rufino e, em especial, às amigas Mariana Bonella e Isabella Branco por conseguirem me trazer de volta à clareza em momentos de escuridão, e por transformarem vários momentos de estresse em gargalhadas.

Aos colegas, ou ex-colegas, do Laboratório de Hidrologia, principalmente ao Eder Alexandre Sá, Daiane Schier, Dayane Medeiros, Victor Hugo Primo e Willian Malkwoski, que sempre estiveram presentes e contribuíram de alguma forma.

À Universidade do Estado de Santa Catarina (UDESC) pelo ensino público e de qualidade.

À Fundação de Amparo à Pesquisa e Extensão de Santa Catarina (FAPESC) pela concessão da bolsa de mestrado.

“Oh! não deixeis apagar a chama! Mantida de século em século nesta escura caverna, em seus templos sagrados! Sustentada por puros ministros do amor! Não deixeis apagar esta divina chama!”
(Edward Carpenter, O CAIBALION)

RESUMO

A previsão confiável de eventos de inundação em áreas urbanas é essencial para aplicação, em tempo hábil, de medidas de preparação e resposta eficientes para mitigação de danos e prejuízos. O objetivo desta pesquisa foi avaliar a aplicabilidade de redes neurais artificiais (RNAs) do tipo *Multilayer Perceptron* (MLP) para previsão da profundidade da água de forma espacializada na planície urbana de Lages/SC, no escopo de um sistema de alerta a inundações para a região. Os eventos de inundação utilizados para o estudo foram os ocorridos na cidade em 2005, 2011 e 2017. Os hidrogramas dos eventos foram obtidos por simulação hidrológica no HEC-HMS 4.6, e os dados de profundidade de água foram obtidos de simulação hidrodinâmica no HEC-RAS 5.0.6. Os vetores de entrada da rede foram compostos por séries de precipitação, vazão e profundidade de água. Os modelos de RNA foram utilizados para prever a profundidade da água entre 3 e 20 horas a frente em oito locais de monitoramento distribuídos na planície de inundação urbana. Foram testados modelos de RNAs de saídas simples ou saídas múltiplas. O período de verificação foi o evento de 2011. Previsões realizadas com RNAs de saídas simples para alcances de 3, 8, 14 e 20 horas apresentaram, em média, coeficientes de Nash-Sutcliffe (NS) de 0,99; 0,98; 0,89; 0,77; média do erro absoluto (MAE) de 4; 11; 28; 40 cm, e PBIAS de -0,50; -0,61; 1,12; 2,03%, respectivamente. Utilizar dados gerados por um modelo hidrodinâmico mostrou-se viável para treinamento e verificação dos modelos de RNAs, o que possibilita realizar previsões em regiões que carecem de dados de níveis fluviais observados. Os resultados das RNAs de saídas múltiplas apresentaram variações menos drásticas nos erros dos modelos, conferindo maior estabilidade e confiabilidade aos resultados. Realizar a previsão da profundidade da água em locais de monitoramento distribuídos dentro da área urbana inundada, pode ser, portanto, uma alternativa para aumentar a capacidade de resposta operacional da defesa civil e proporcionar uma maior eficiência nos processos de tomada de decisão durante eventos de inundação.

Palavras-chave: Inundações urbanas; Simulação hidrodinâmica; Redes neurais artificiais; Sistema de alerta.

ABSTRACT

Reliable flood forecasting in urban areas is essential for timely application of efficient preparedness and response measures to mitigate damages and losses. The aim of this research was to evaluate the applicability of *Multilayer Perceptron* artificial neural networks (ANNs) (MLP) to forecast water depth in a spatialized way in the urban floodplain of Lages/SC, within the scope of a flood warning system for the region. The flood events used for the study were those that occurred in the city in 2005, 2011 and 2017. The events hydrographs were obtained by hydrological simulation in HEC-HMS 4.6, and water depth data were obtained from hydrodynamic simulation in HEC- RAS 5.0.6. The input vectors of the network were composed by series of precipitation, flow, and water depth. ANN models were used to forecast water depth between 3 and 20 hours ahead at eight monitoring sites distributed across the urban floodplain. Single-output or multiple-output ANN models were tested. The verification data was the 2011 event. Single-output ANNs results for the lead times of 3, 8, 14 and 20 hours presented, on average, Nash-Sutcliffe coefficients (NS) of 0.99; 0.98; 0.89; 0.77; mean absolute error (MAE) of 4; 11; 28; 40 cm, and PBIAS of -0.50; -0.61; 1.12; 2.03%, respectively. Using data generated by a hydrodynamic model proved to be viable for ANN model training and verification, which allows performing forecasts in regions lacking observed river level data. The results of multiple-output ANNs indicated a reduction of drastic variations in the errors of these models, which provides more reliability to the results. Simultaneously forecasting water depth in monitoring sites distributed within the flooded urban area can be an alternative to increase the operational response capacity of civil defense and provide greater efficiency in decision-making process during flood events.

Keywords: Urban flooding; Hydrodynamic simulation; Artificial neural networks; Warning system.

LISTA DE ILUSTRAÇÕES

Figura 1- Ciclo de Gerenciamento de Desastres Naturais.....	26
Figura 2- Características importantes do hidrograma e definição dos tempos.....	36
Figura 3-Arquitetura da rede MLP (Multilayer Perceptron)	40
Figura 4-Mapa de localização da área de estudo.....	50
Figura 5- Hidrograma observado na estação fluviométrica Ponte Velha durante o evento de inundação de 2005.	53
Figura 6- Hidrograma observado na estação fluviométrica Ponte Velha durante o evento de inundação de 2011.	53
Figura 7- Hidrograma observado na estação fluviométrica Caveiras Montante 1 durante o evento de inundação de 2017.	53
Figura 8 – Fluxograma do delineamento da pesquisa.	54
Figura 9 - Distribuição espacial das estações utilizadas.....	56
Figura 10- Diagrama sintetizando as informações sobre as estações utilizadas na simulação hidrológica e locais de monitoramento.	57
Figura 11- Elementos que compõem o modelo conceitual de bacia hidrográfica utilizado para a simulação dos eventos hidrológicos extremos de 2005, 2011 e 2017.	59
Figura 12- Detalhe do modelo conceitual nas bacias urbanas dos rios Ponte Grande e Carahá.....	59
Figura 13-Geometria da simulação hidrodinâmica com destaque para as condições de contorno do modelo.....	63
Figura 14- Espacialização dos locais de monitoramento.....	64
Figura 15- Hidrogramas dos eventos de 2005, 2011 e 2017 obtidos por simulação hidrológica no HEC-HMS.....	68
Figura 16- Hidrogramas simulados correspondentes às junções de interesse (J4, J8 e J13) para a área de simulação hidrodinâmica (domínio do problema) com relação aos eventos de 2005, 2011 e 2017.....	70
Figura 17- Detalhamento nos canais com malhas de 30 m (A), 10 m (B) e 5 m (C).	72
Figura 18 -Exemplificação da distribuição do Courant Number com a malha de 5 m durante a simulação do evento de 2005.....	73
Figura 19-Representação da evolução da inundação com relação aos locais de monitoramento no evento de 2005.	74

Figura 20- Representação da evolução da inundação com relação aos locais de monitoramento no evento de 2011.	75
Figura 21 - Representação da evolução da inundação com relação aos locais de monitoramento no evento de 2017.	76
Figura 22- Profundidades máximas atingidas durante os eventos simulados.	78
Figura 23 - Profundidades de água (m) geradas pelo modelo hidrodinâmico ao longo do tempo nos locais de monitoramento para o evento de 2005.....	79
Figura 24- Profundidades de água (m) geradas pelo modelo hidrodinâmico ao longo do tempo nos locais de monitoramento para o evento de 2011.....	79
Figura 25- Profundidades de água (m) geradas pelo modelo hidrodinâmico ao longo do tempo nos locais de monitoramento para o evento de 2017.....	80
Figura 26-Ilustração da rna_CAV4, referente ao modelo de previsão da profundidade de água no local de monitoramento (LM) CAV-4, com as variáveis de entrada e defasagens temporais utilizadas.	83
Figura 27-Ilustração do modelo rna_CAV3, referente à previsão da profundidade de água no local de monitoramento (LM) CAV-3, com as variáveis de entrada e defasagens temporais utilizadas.	83
Figura 28- Ilustração do modelo rna_CH1, referente à previsão da profundidade de água no local de monitoramento (LM) CH1-1, com as variáveis de entrada e defasagens temporais utilizadas.	84
Figura 29- Ilustração do modelo rna_CH2, referente à previsão da profundidade de água no local de monitoramento (LM) CH-2, com as variáveis de entrada e defasagens temporais utilizadas.	84
Figura 30- Ilustração do modelo rna_CH3, referente à previsão da profundidade de água no local de monitoramento (LM) CH-3, com as variáveis de entrada e defasagens temporais utilizadas.	85
Figura 31- Ilustração do modelo rna_PG1, referente à previsão da profundidade de água no local de monitoramento (LM) PG-1, com as variáveis de entrada e defasagens temporais utilizadas.	87
Figura 32- Ilustração do modelo rna_PG2, referente à previsão da profundidade de água no local de monitoramento (LM) PG-2, com as variáveis de entrada e defasagens temporais utilizadas.	87

Figura 33- Ilustração do modelo rna_PG3, referente à previsão da profundidade de água no local de monitoramento (LM) PG-3, com as variáveis de entrada e defasagens temporais utilizadas.	87
Figura 34- Efeito da retirada dos dados de precipitação da estação Paineira (P1), representado pelo conjunto MP1 (modelos parciais 1) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre a métrica NS para todos os alcances.	93
Figura 35- Efeito da retirada dos dados de precipitação da estação Lages/Lages Coral (P2), representado pelo conjunto MP2 (modelos parciais 2) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre métrica NS para todos os alcances.	93
Figura 36- Efeito da retirada dos dados de vazão QJ4, representado pelo conjunto MP3 (modelos parciais 3) em relação ao modelo completo (MC) para os locais CAV-3, CH-3 e PG-3 sobre a métrica NS para todos os alcances.....	94
Figura 37- Efeito da retirada dos dados de vazão QJ13, representado pelo conjunto MP4 (modelos parciais 4) em relação ao modelo completo (MC) para os locais CAV-3, CH-3 e PG-3 sobre métrica NS para todos os alcances.....	95
Figura 38- Efeito da retirada dos dados de vazão QJ8, representado pelo conjunto MP5 (modelos parciais 5) em relação ao modelo completo (MC) para os locais CAV-3, CH-3 e PG-3 sobre a métrica NS para todos os alcances.....	95
Figura 39- Efeito da retirada dos dados de vazão QPV, representado pelo conjunto MP6 (modelos parciais 6) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre a métrica NS para todos os alcances.....	96
Figura 40- Efeito da retirada dos dados de profundidade da água (LM), representado pelo conjunto MP7 (modelos parciais 7) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre a métrica NS para todos os alcances. .	96
Figura 41-Efeito da retirada dos dados de profundidade da água (LM), representado pelo conjunto MP8 (modelos parciais 8) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre a métrica NS para todos os alcances. .	97
Figura 42-Ilustração da rna_CAV, referente ao modelo de previsão da profundidade de água nos locais de monitoramento CAV-4 e CAV-3 com as variáveis de entrada e defasagens temporais utilizadas.....	99

Figura 43- Ilustração da rna_CH, referente ao modelo de previsão da profundidade de água nos locais de monitoramento CH-1, CH-2 e CH-3 com as variáveis de entrada e defasagens temporais utilizadas.	99
Figura 44- Ilustração da rna_PG, referente ao modelo de previsão da profundidade de água nos locais de monitoramento PG-1, PG-2 e PG-3 com as variáveis de entrada e defasagens temporais utilizadas.	99
Figura 45- Comparação das métricas de desempenho na etapa de verificação dos modelos de saídas simples e saídas múltiplas para os locais do monitoramento no rio Caveiras (CAV-3 e CAV-4) com variação do alcance de previsão.	100
Figura 46- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CAV-4 considerando diferentes alcances para o evento de 2011 (evento de verificação).	101
Figura 47- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CAV-3 considerando diferentes alcances para o evento de verificação (evento de 2011).	102
Figura 48- Comparação das métricas de desempenho na etapa de verificação dos modelos de saídas simples e saídas múltiplas para os locais do monitoramento no rio Carahá (CH-1; CH-2; CH-3) com variação do alcance de previsão.	103
Figura 49- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CH-1 considerando diferentes alcances para o evento de verificação (evento de 2011).	104
Figura 50- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CH-2 considerando diferentes alcances para o evento de verificação (evento de 2011).	105
Figura 51- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CH-3 considerando diferentes alcances para o evento de verificação (evento de 2011).	105

Figura 52- Comparação das métricas de desempenho na etapa de verificação dos modelos de saídas simples e saídas múltiplas para os locais do monitoramento no rio Ponte Grande (PG-1; PG-2; PG-3) com variação do alcance de previsão. ..	106
Figura 53- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento PG-1 considerando diferentes alcances para o evento de verificação (evento de 2011).	107
Figura 54- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento PG-2 considerando diferentes alcances para o evento de verificação (evento de 2011).	108
Figura 55- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento PG-3 considerando diferentes alcances para o evento de verificação (evento de 2011).	108

LISTA DE TABELAS

Tabela 1- Sumário das probabilidades (P) e tempos de retornos (TR) das chuvas máximas anuais de 1 dia e acumuladas de 2 a 5 dias para a cidade de Lages (SC), de acordo com o modelo de Distribuição de Probabilidades de Gumbel para os anos de ocorrência de inundação utilizados nesta pesquisa.	51
Tabela 2- Detalhamento dos eventos e períodos utilizados.....	52
Tabela 3 - Informações das estações utilizadas.	57
Tabela 4 - Defasagens temporais avaliadas para cada variável de entrada do modelo de previsão.....	65
Tabela 5-Apresentação dos modelos de RNAs de saídas simples ou saídas múltiplas utilizados para previsão da profundidade de água nos locais de monitoramento.	65
Tabela 6- Malhas testadas para simulação dos eventos de inundação e respectivos parâmetros. Δt = passo de tempo da simulação; ΔX = tamanho da célula da malha.	71
Tabela 7- Combinação de defasagens temporais das variáveis de entrada do modelo de previsão.....	81
Tabela 8- Número de neurônios internos escolhidos para cada local de monitoramento.	82
Tabela 9-Métricas de avaliação do desempenho na verificação para a rna_CAV4. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.	83
Tabela 10-Métricas de avaliação do desempenho na verificação para a rna_CAV3. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.	84
Tabela 11- Métricas de avaliação do desempenho na verificação para a rna_CH1. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.	85
Tabela 12-Métricas de avaliação do desempenho na verificação para a rna_CH2. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto;	

NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.	86
Tabela 13- Métricas de avaliação do desempenho na verificação para a rna_CH3. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.	86
Tabela 14-Métricas de avaliação do desempenho na verificação para a rna_PG1. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.	88
Tabela 15- Métricas de avaliação do desempenho na verificação para a rna_PG2. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.	88
Tabela 16- Métricas de avaliação do desempenho na verificação para a rna_PG3. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.	88
Tabela 17- Apresentação dos modelos desenvolvidos nesta pesquisa para análise da importância de cada variável de entrada nas previsões. MC – Modelo completo; MP – Modelos parciais.	92

LISTA DE ABREVIATURAS E SIGLAS

ANA	Agência Nacional de Águas e Saneamento Básico
AVADAN	Formulário de Avaliação de Danos
BC	Boundary Conditions
CFL	Courant-Friedrichs-Lewy
CN	Curve Number
COMPDEC	Coordenadoria Municipal de Proteção e Defesa Civil
E90	Percentil 90% da distribuição dos erros (cm)
GDN	Gerenciamento de Desastres Naturais
HEC-HMS	Hydrologic Engineering Center – Hydrologic Modeling System
HEC-RAS	Hydrologic Engineering Center – River Analysis System
LiDAR	Light Detection and Ranging
MAE	Mean Absolute Error (cm)
MC	Modelo Completo
MDT	Modelo Digital de Terreno
MLP	Multilayer Perceptron
MP#	Modelo Parcial número #
NS	Nash-Sutcliffe
PBIAS	Percentage bias (cm)
PLACON	Plano de Contingência de Proteção e Defesa Civil
RNA	Rede Neural Artificial
S2iD	Sistema Integrado de Informações sobre Desastres
SADE	Sistema de Apoio à Decisão Espacial
SDS	Secretaria de Estado da Defesa Civil
SEDEC	Secretaria Nacional de Proteção e Defesa Civil
SIG	Sistema de Informação Geográfica
SVM	Support Vector Machine
SVR	Support Vector Regression

Tc	Tempo de concentração
Tf	Tempo de antecedência máximo de previsão
Tp	Tempo de pico
TR	Tempo de retorno
Tr	Tempo de propagação da onda de cheia ao longo do canal principal
USACE	U. S. Army Corps of Engineers

SUMÁRIO

1 INTRODUÇÃO	20
2 OBJETIVOS	23
3 REVISÃO BIBLIOGRÁFICA	24
3.1 DESASTRES POR INUNDAÇÕES	24
3.2 GERENCIAMENTO DE DESASTRES NATURAIS	25
3.3 O GDN EM LAGES	27
3.4 SISTEMAS DE ALERTA	32
3.5 PREVISÃO DE INUNDAÇÃO	34
3.6 MODELOS HIDRODINÂMICOS	37
3.7 REDES NEURAIS ARTIFICIAIS	39
3.8 MÉTRICAS PARA AVALIAÇÃO	47
4 MATERIAS E MÉTODOS	49
4.1 ÁREA DE ESTUDO	49
4.2 EVENTOS SELECIONADOS	51
4.3 DELINEAMENTO DA PESQUISA	54
4.4 DADOS OBSERVADOS UTILIZADOS	55
4.5 SIMULAÇÃO HIDROLÓGICA	57
4.6 SIMULAÇÃO HIDRODINÂMICA	61
4.7 FORMULAÇÃO E ASPECTOS DA APLICAÇÃO DOS MODELOS DE PREVISÃO	64
5 RESULTADOS E DISCUSSÃO	68
5.1 SIMULAÇÃO HIDROLÓGICA	68
5.2 SIMULAÇÃO HIDRODINÂMICA	71
5.2.1 Ajuste da configuração da malha de simulação hidrodinâmica	71
5.2.2 Análise das manchas de inundação e profundidades da água dos eventos simulados	74
5.3 DEFINIÇÃO DOS MODELOS DE RNA PARA OS LOCAIS DE MONITORAMENTO	80
5.3.1 Análise de combinações de diferentes defasagens temporais das variáveis de entrada	80
5.3.2 Análise da complexidade interna	81
5.4 MODELOS DE PREVISÃO COM SAÍDAS SIMPLES	82
5.4.1 Locais de monitoramento no rio Caveiras – CAV-4 e CAV-3	82
5.4.2 Locais de monitoramento no rio Carahá – CH-1, CH-2, CH-3	84
5.4.3 Locais de monitoramento no rio Ponte Grande – PG-1, PG-2, PG-3	86

5.4.4	Análise dos resultados dos modelos de previsão de saídas simples.....	89
5.4.5	Análise da sensibilidade das variáveis de entrada para a previsão	91
5.5	MODELOS DE PREVISÃO COM SAÍDAS MÚLTIPLAS	98
5.5.1	Aspectos gerais da formulação dos modelos de saídas múltiplas.....	98
5.5.2	Locais de monitoramento no rio Caveiras – Modelo rna_CAV.....	100
5.5.3	Locais de monitoramento no rio Carahá – Modelo rna_CH.....	102
5.5.4	Locais de monitoramento no rio Ponte Grande – Modelo rna_PG	106
5.5.5	Análise dos resultados dos modelos de previsão de saídas múltiplas	109
6	CONCLUSÕES.....	111
7	RECOMENDAÇÕES.....	113
	REFERÊNCIAS	114
	APÊNDICE A – RESULTADO DA PESQUISA DE COMPLEXIDADE	
	INTERNA.....	124
	APÊNDICE B – DISTRIBUIÇÃO ESPACIAL DA CHUVA PARA A VAZÃO DE	
	PICO DOS EVENTOS DE INUNDAÇÃO	125
	APÊNDICE C – PARÂMETROS UTILIZADOS PARA SIMULAÇÃO	
	HIDROLÓGICA NO HEC-HMS	128

1 INTRODUÇÃO

A história do desenvolvimento da civilização está marcada pela ocupação das adjacências dos cursos d'água, principalmente devido à necessidade de utilizar esse recurso, direta ou indiretamente, para os processos que norteiam a vida humana (TUCCI, 1997). A crescente urbanização e a ocupação desordenada pela população das áreas de planície inundável, somadas aos impactos das mudanças climáticas, têm consequências sobre os processos hidrológicos que ocorrem na superfície terrestre (MILLER; HUTCHINS, 2017). Nesse contexto, eventos de inundação representam uma ameaça em diversas regiões do mundo, de modo que implementar um sistema de previsão e alerta em áreas suscetíveis a desastres pode auxiliar na redução dos danos e prejuízos (KOBIYAMA *et al.*, 2006).

No âmbito do gerenciamento de desastres naturais (GDN), os sistemas de previsão e alerta integram a etapa de preparação, na qual são realizadas atividades de planejamento anteriores à ocorrência de um evento extremo, com o objetivo de melhorar a capacidade de resposta operacional (NETO, 2000). Para cumprirem com os objetivos da etapa de preparação, os sistemas de previsão e alerta exigem a implementação de ferramentas que permitam prever eventos de inundação com razoável tempo de antecedência, pois quando um evento extremo está em curso o tempo de resposta disponível é pequeno. Devido às diversas interações hidrológicas envolvidas em áreas urbanas, à escassez ou insuficiência de dados observados de eventos passados e à ausência de equipes técnicas qualificadas a respeito do domínio do problema, a previsão de inundações nesses ambientes continua sendo um desafio (NEAL *et al.*, 2009; PAQUIER; BAZIN, 2014).

Especificamente na cidade de Lages (SC) não há qualquer sistema operacional de previsão e alerta a eventos hidrológicos extremos, apesar de haver 20 eventos críticos já registrados desde 1970 (LIZ, 2018). A exemplo de Lages, há inúmeras outras cidades do estado de Santa Catarina que há anos convivem com os desastres provocados por inundações, sem que medidas eficazes de previsão e alerta de curto prazo sejam implementadas para auxiliar nas ações preparação e de resposta imediata no nível local.

O estabelecimento de medidas efetivas frente à eventos de inundação requer a identificação dos principais fatores causais e, em seguida a adoção de ferramentas e estratégias cabíveis (ŠPITALAR *et al.*, 2014). Os modelos matemáticos são ferramentas que permitem a representação do domínio do problema e possibilitam a análise e a compreensão dos diversos processos envolvidos. Além de fornecer informações

importantes sobre esses eventos, como a extensão, profundidade, duração e velocidade da onda de cheia, de modo que os níveis de perigo, de exposição e de vulnerabilidade possam ser estimados (BELLOS; TSAKIRIS, 2016; COSTABILE; MACCHIONE, 2015; MONTE *et al.*, 2016)

Os modelos de base física (unidimensionais e bidimensionais) são amplamente utilizados para a análise de processos hidrológicos, pois são capazes de produzir representações adequadas do fluxo da água nos canais dos rios e planícies inundáveis (ALFIERI, L. *et al.*, 2013; TENG *et al.*, 2017). Esses modelos tendem a possuir estruturas formais complexas quando o objetivo é representar os diferentes estados das variáveis de sistemas não-lineares. Por isso, dependem de inúmeros parâmetros e, conseqüentemente, demandam demasiado tempo computacional para simulação (TENG *et al.*, 2015). A utilização de modelos de base física simplificados poderia resultar em uma melhoria computacional. No entanto, isso ainda seria insuficiente para utilizá-los operacionalmente para previsão de inundações em tempo real (HENONIN *et al.*, 2013).

Alternativamente, as redes neurais artificiais (RNAs) são modelos estritamente numéricos, que apresentam benefícios devido à simplicidade de sua estrutura formal, à relativa facilidade de aplicação e à sua capacidade de resposta célere. Esses modelos são capazes de representar relações bastante complexas, como a associação entre dados atuais e futuros de um sistema, tornando-se úteis para previsão (ZHANG; PATUWO; HU, 1998). Além disso, as RNAs provaram-se capazes de emular os resultados dos modelos físicos, de modo que o desenvolvimento delas a partir de dados simulados por modelos unidimensionais/bidimensionais vem sendo investigado na literatura (BERMÚDEZ *et al.*, 2018; CHU *et al.*, 2020).

Apesar dos modelos físicos possuírem limitações técnicas e computacionais para aplicação direta no âmbito de sistemas de previsão e alerta, a natureza física de representação desses modelos pode ser explorada como sendo o fenômeno real - com um certo grau de confiança-, e fornecer dados para desenvolvimento de RNAs. Desse modo, procura-se associar os melhores atributos de cada abordagem de modelagem. Os dados relevantes gerados pelos modelos físicos podem ser aplicados no aprendizado dos modelos de RNAs, os quais passam a ser utilizados nas atividades operacionais dos sistemas (BERMÚDEZ *et al.*, 2018; JHONG; WANG; LIN, 2017). Essa abordagem pode viabilizar o desenvolvimento de modelos de previsão e alerta a inundações para regiões que possuem pouco ou nenhum monitoramento hidrológico (DIKSHIT; PRADHAN; ALAMRI, 2020).

Tradicionalmente, a previsão de inundações por RNAs tem sido realizada a partir do monitoramento dos níveis dos rios em seções fluviais localizadas a montante da área inundada (domínio do problema), sendo essa a abordagem mais antiga aplicada ao gerenciamento de desastres (HAPUARACHCHI; WANG; PAGANO, 2011). Contudo, essa forma de monitoramento pode acarretar incertezas ao se buscar relacionar os níveis previstos nas seções fluviais com as profundidades de água atingidas dentro do domínio do problema (ALFIERI *et al.*, 2012). Além disso, pode existir a necessidade de que a previsão ocorra sobre diversos pontos distribuídos na área inundada, de forma espacializada, uma vez que esses pontos costumam ser utilizados como referências da evolução do evento pelas agências e instituições envolvidas com as atividades de resposta (PAN *et al.*, 2011).

Para previsão em locais distribuídos espacialmente, o modelo de RNA pode ser estruturado de saídas múltiplas, ou seja, um único modelo é capaz de produzir o vetor de resposta para diversos pontos no domínio do problema. Alguns estudos utilizaram RNAs para previsão simultânea do nível da água em diferentes pontos, configurando um modelo de saídas múltiplas (KABIR *et al.*, 2020; RJEILY *et al.*, 2017). No entanto, o possível ganho ou perda dessa estratégia em comparação à de modelos de RNAs de saídas simples carece de mais análises. Busca-se com este trabalho aprofundar a investigação dessas questões a partir da previsão da profundidade da água em locais de monitoramento distribuídos em uma planície inundável urbana, utilizando dados simulados por um modelo hidrodinâmico para treinamento das RNAs.

2 OBJETIVOS

Objetivo Geral

Avaliar a aplicabilidade de redes neurais artificiais para previsão da profundidade da água em uma planície inundável urbana, no escopo de um sistema de previsão e alerta a inundações.

Objetivos específicos

- Realizar a simulação hidrológica a fim obter os hidrogramas de vazões máximas dos eventos extremos de 2005, 2011 e 2017 ocorridos em Lages.
- Realizar a simulação hidrodinâmica para determinar as regiões inundadas nos eventos de 2005, 2011 e 2017.
- Definir os pontos de monitoramento de profundidade da água na planície inundada.
- Determinar uma arquitetura de RNA capaz de realizar previsões com diversas antecedenças nos pontos de monitoramento.
- Treinar e verificar a RNA para previsão da profundidade da água nos pontos de monitoramento.
- Experimentar modelos de RNAs com saídas simples ou saídas múltiplas.

3 REVISÃO BIBLIOGRÁFICA

3.1 DESASTRES POR INUNDAÇÕES

O termo desastre é utilizado para nomear o resultado de uma perturbação séria na atividade de uma comunidade causada pela interação entre um evento adverso e as condições de vulnerabilidade presentes, que culmina em perdas ou impactos humanos, materiais, econômicos e ambientais (UNISDR, 2009). As inundações são fenômenos naturais intrínsecos ao regime hidrológico dos rios. Quando esse fenômeno entra em contato com a sociedade, causando danos e prejuízos, passa a ser visto como desastre (MACEDO, 1987; MONTE *et al.*, 2021).

Os desastres não são considerados apenas como um produto de origem natural, mas um produto resultante de uma sociedade que opera no ambiente (MONTE *et al.*, 2021). Assim, podem ser classificados de acordo com sua origem: tecnológica, social, natural ou híbrida. Desastres por inundações são desastres naturais, conforme a Classificação e Codificação Brasileira de Desastres (COBRADE) (UFSC, 2013), relacionados a eventos críticos do ciclo hidrológico (GUHA-SAPIR; VOS; BELOW, 2012). Suas consequências variam de acordo com o nível de interação entre o evento e as condições de exposição e de vulnerabilidade humanas, e também está relacionado com a capacidade de resposta da sociedade (COPPOLA, 2015).

O processo de inundação acontece a partir da enchente (elevação do nível d'água em decorrência do acréscimo da descarga) de um canal. Quando a vazão escoada em determinado curso d'água é superior à capacidade de descarga de sua calha natural, ocorre o extravasamento da água para além de suas margens e a consequente ocupação das áreas marginais ou do seu leito maior, também chamado de planície topográfica de inundação (TUCCI, 1993; LEOPOLD, 1994; GONTIJO, 2007).

A ocorrência de inundações depende das características físicas e climatológicas da bacia hidrográfica – especialmente da distribuição espacial e temporal da chuva (TUCCI, 1993). As inundações, em geral, são provocadas por chuvas persistentes de grande magnitude e abrangência espacial, que levam ao aumento do escoamento da bacia hidrográfica e à elevação do nível d'água nos canais, em especial do seu curso principal. Consequentemente, a população que reside nas áreas próximas aos corpos hídricos pode ser atingida diretamente, em virtude do grau de exposição e vulnerabilidade a que está sujeita (REGO; BARROS, 2014).

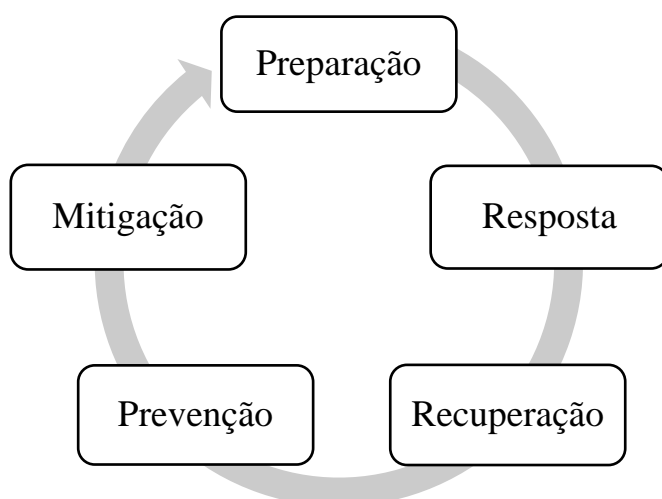
Os principais eventos relacionados a desastres naturais que atingem o Brasil incluem, em primeiro lugar, as inundações (39,10%), seguido das secas (13,53%), tempestades (12,78%) e deslizamentos de massa (12,03%) (EM-DAT, 2020). Entre os anos de 1991 e 2012 aproximadamente 40,19% da população brasileira sofreu com inundações e enxurradas, correspondendo a 61,82% das mortes relacionadas a desastres (CEPED-UFSC, 2013). No mesmo período, o estado de Santa Catarina registrou 449 registros oficiais de inundações excepcionais caracterizadas como desastres. Isso significa que mais da metade dos municípios do estado catarinense, cerca de 67%, foi afetada por inundações pelo menos uma vez nesse período. Esses eventos deixaram milhares de pessoas desabrigadas e causaram prejuízos à economia local.

3.2 GERENCIAMENTO DE DESASTRES NATURAIS

O gerenciamento de desastres naturais (GDN) é um conjunto de ações que se desenrolam em diferentes momentos com relação ao evento propriamente dito. Essas ações visam prover a sociedade de mecanismos capazes de minimizarem os impactos causados por desastres, uma vez que não é possível eliminar completamente sua ocorrência (GOERL *et al.*, 2017). O GDN abrange especialidades de diversas disciplinas e origens científicas, isso levou a diferentes interpretações e definições dos conceitos que caracterizam o ciclo do GDN, permitindo sua evolução ao longo do tempo (COETZEE; VAN NIEKERK, 2012; NETO, 2000; RANA *et al.*, 2021).

O ciclo do GDN tem como função ser um guia para compreensão das fases do gerenciamento de desastres naturais. Assim, as ações que o compõem podem ser organizadas em: prevenção, mitigação, preparação, resposta e recuperação (CARTER, 2008) (Figura 1). De certa maneira, as fases de prevenção, mitigação e preparação correspondem a etapas anteriores à ocorrência do evento; a resposta corresponde ao durante; e a recuperação ao depois. Embora o diagrama indique um ciclo com etapas sequenciais, a prática tem demonstrado que as ações são inter-relacionadas e são realizados em algum grau antes, durante e após o desastre.

Figura 1- Ciclo de Gerenciamento de Desastres Naturais.



Fonte: Adaptado de Carter (2008).

As ações de prevenção são projetadas para impedir a ocorrência de um desastre e/ou evitar que tal ocorrência tenha impactos negativos sobre as comunidades (CARTER, 2008). De forma semelhante, a etapa de mitigação objetiva diminuir a vulnerabilidade ao perigo de longo prazo (NETO, 2000), podendo ser adotadas medidas que propiciem maior segurança às comunidades, como realocação de atividades, políticas de zoneamento para controle do uso do solo, regulamentação e controle de construções, programas educativos de conscientização e atividades de evacuação da população das áreas vulneráveis.

Na preparação são realizadas atividades de planejamento anteriores à ocorrência do evento, objetivando aumentar a capacidade de resposta operacional durante uma emergência para redução de danos e prejuízos (NETO, 2000). Contemplam a etapa de preparação, medidas estruturais como a construção de barragens, diques, reservatórios de detenção e cortes de meandros, e medidas não estruturais como a elaboração de planos de contingências, a coleta e o monitoramento de dados. Dentre as medidas não-estruturais, os sistemas de alerta têm a função de prever o estado do sistema hidrológico em tempo suficiente para as ações de resposta ocorrerem com eficiência.

A etapa de resposta se caracteriza quando um evento está em curso visando reduzir perdas materiais e de vidas. Abrange diversas ações emergenciais como a alocação de recursos imediatamente antes, durante ou após uma emergência, avaliação de necessidades emergenciais imediatas, evacuação e atendimento de vítimas e levantamento do evento (registro). A recuperação visa a restauração dos sistemas afetados e o retorno às atividades no nível anterior ao desastre (NETO, 2000).

Normalmente, a sociedade está mais preparada para responder aos desastres naturais menos extremos, em virtude de sua elevada frequência (KOBAYAMA *et al.*, 2006). Os sistemas de previsão e alerta podem ser fundamentais para eventos de inundação de grande magnitude, os quais possuem baixa probabilidade ou frequência de ocorrência e atingem as cotas maiores, locais em que as pessoas se sentem seguras (TUCCI, 1997).

É necessário que os órgãos responsáveis pelo GDN, priorizem o desenvolvimento de uma cultura de mitigação e de preparação, ao invés de se apoiar apenas nas etapas pós evento, de resposta e de recuperação (ALFIERI, *et al.*, 2012; CASTRO, 1999). A mitigação e a preparação para eventos futuros são elementos-chaves para proteção da sociedade e aumento da eficiência de resposta, já que eventos anteriores auxiliam no aprendizado e na previsão de novos desastres (ALFIERI *et al.*, 2013; MONTE *et al.*, 2021). O aprendizado se refere à incorporação de experiências vividas durante os eventos no modelo de decisão para eventos futuros.

A complexidade dos fenômenos hidrológicos que causam os desastres por inundações torna o processo decisório no GDN complexo e difícil, pois envolve variáveis de natureza espacial e com relações não lineares de difícil modelagem. As inundações são fenômenos hidrológico-hidráulicos e sua análise deve considerar componentes de natureza morfológica – posição, geometria e atributos – e componentes dinâmicos – fluxo de água (NETO, 2000). Neste sentido, as características positivas das RNAs, aplicadas para previsão e alerta a inundações, podem contribuir para reduzir as incertezas e riscos no processo decisório, proporcionando relatórios sintéticos e confiáveis para a tomada de decisão.

3.3 O GDN EM LAGES

Aproximadamente 19,6% dos desastres naturais registrados em Santa Catarina entre os anos de 1980 e 2010 foram episódios de inundações (CEPED-UFSC, 2013). Como consequência, deixaram milhares de pessoas desabrigadas e causaram prejuízos à economia. Nessa estatística, o município de Lages encontra-se em terceiro lugar em termos de frequência de inundações em Santa Catarina, permanecendo atrás apenas dos municípios de Blumenau e Canoinhas.

A Secretaria Nacional de Proteção e Defesa Civil (SEDEC) e também a Coordenação Municipal de Proteção e Defesa Civil de Lages (COMPDEC-LAGES)

mantêm os registros desses episódios com o número de habitantes e de casas atingidas, registro dos desabrigados, dos bairros mais afetados e das características dos eventos. A Tabela 1 apresenta os dados de alguns eventos de inundação ocorridos em Lages nos últimos 40 anos e traz, de maneira resumida, a forma como foram registrados nos documentos arquivados pela Defesa Civil e nos formulários de avaliação de danos (AVADAN), disponíveis no Sistema Integrado de Informações sobre Desastres (S2iD) (<https://s2id-search.labtrans.ufsc.br/>).

Tabela 1 - Resumo dos principais eventos de cheias em Lages, desde 1979 até 2020.

Data de ocorrência	Descrição do evento
23 a 29 de outubro de 1979	Enchente lenta que provocou alagamento de centenas de residências, gerando aproximadamente 400 desabrigados. Houve interrupção do fornecimento de água potável à parte da população. Ocorrência de uma vítima fatal. O represamento de dois afluentes do rio Caveiras, que cortam o centro da cidade, é apontado como fator maximizador do evento.
29 e 30 de julho de 1980	Evento definido como enchente lenta. Houve transbordamento dos rios da região, com inundação das áreas mais baixas. Evacuação de várias famílias e alagamento das residências. Danos na agricultura e no sistema viário. Em Lages, a ocorrência de ventos fortes destelhou casas no interior
05 de dezembro de 1980	Enchente brusca que provocou danos em residências, prejuízos no comércio, no sistema viário e uma vítima fatal.
11 de fevereiro de 1981	Enchente brusca que provocou o transbordamento dos rios Carahá e Passo Fundo, inundou grande parte do centro da cidade, provocando elevados danos materiais, 296 pessoas ficaram desalojadas.
05 de julho de 1983	Inundação histórica ocorrida em todo o estado de Santa Catarina, que gerou aproximadamente 200 mil desabrigados em 135 municípios. A precipitação mensal acumulada para o mês de julho atingiu 671,4 mm no pluviômetro de Lages na estação experimental da Epagri.
06 de agosto de 1984	Decretado estado de Calamidade Pública em Lages, devido ao transbordamento de diversos rios. A precipitação acumulada para o mês foi de 297,8 mm.
31 de maio de 1990	Decretado estado de Calamidade Pública em Lages, decorrente de fortes chuvas que inundaram a cidade e deixaram desabrigados
28 de maio de 1992	A precipitação acumulada para o mês atingiu 343,1 mm, o que provocou a danificação de habitações, do sistema viário e desalojou diversas pessoas.
02 e 04 de julho de 1993	Três dias de chuvas intensas produziram um acumulado de 261 mm. O transbordamento dos rios produziu uma morte, e também dezenas de desabrigados.
31 de janeiro de 1997	O total de chuva acumulado neste mês atingiu 348,8 mm, sendo 169 mm precipitados apenas neste evento. 100 residências foram atingidas e mais de 1000 pessoas ficaram desabrigadas em 15 bairros
10 de outubro de 1997	Este evento teve uma altura de precipitação menor, se comparado aos outros, porém permaneceu em torno de 80 mm. 104 residências foram atingidas, e também prédios públicos.
27 de abril de 1998	O município teve os rios Carahá e Passo Fundo transbordados, o que rendeu ao evento o Decreto de Situação de Emergência.
30 de setembro de 2001	O evento provocou grandes enxurradas nas partes mais altas da cidade, afetando de maneira rápida diversas residências, e também provocou o consequente acúmulo de água nas partes mais baixas da cidade.

Data de ocorrência	Descrição do evento
27 de setembro de 2004	O mês de setembro acumulou um total de 278,3 mm. No dia do evento a precipitação foi de 74,4 mm, em poucas horas, deixando 628 pessoas desabrigadas.
18 e 19 de maio de 2005	O AVADAN deste evento indicou grandes proporções, visto que tanto os núcleos urbano e rural foram atingidos. 5.140 pessoas ficaram desalojadas, reconhecendo-se a sua Situação de Emergência.
15 de fevereiro de 2008	Inundação provocada por chuvas intensas e concentradas no núcleo urbano, entre às 20h às 22h, registrando 104 mm de chuva, acima da média histórica para o mês de fevereiro que é de 149 mm. Houve transbordamento do rio Carahá.
09 de agosto de 2011	Evento de inundação de grandes proporções, atingiu tanto a região urbana quanto a rural. Entre os dias 08 e 09 de agosto, houve precipitação acumulada de 142 mm. Ocorreram alagamentos, enxurrada e inundação em parte da cidade. Foi decretado Situação de Emergência.
23 de setembro de 2013	Inundações ocorridas tanto na área urbana quanto na rural. A precipitação esteve distribuída entre os dias 20, 21 e 22, com índices superiores a 69 mm acumulados em 24 horas, até o dia 21. E índices superiores a 143,3 mm acumulados em 72 horas até o dia 22.
12 de outubro de 2015	Evento que apresentou um acumulado de 99 mm em 24 horas, contou com diversos alagamentos. Os rios Carahá, Passo Fundo e Ponte Grande extravasaram suas calhas, provocando inundações.
27 de maio a 4 de junho de 2017	O episódio de inundações foi causado por dois eventos consecutivos de chuvas, o primeiro deles com máxima diária de 72,4 mm, e o segundo com máxima diária de 149,8 mm. Este evento foi um dos maiores contabilizados no município desde a grande enchente de 1983.
10 de novembro de 2019	Tempestade local/convectiva, caracterizando um evento de chuvas intensas. O nível do rio Carahá alcançou 3,14 metros, de acordo com o órgão. 2044 pessoas afetadas, 511 unidades habitacionais foram danificadas e 4 destruídas
05 de julho de 2020	Tempestade local/convectiva, caracterizado como vendaval. Ao todo 30 pessoas desalojadas, 567 unidades habitacionais danificadas e 9 destruídas.

Fonte: Elaborado pela autora (2021).

Quanto à literatura científica, no caso de Lages, existem alguns estudos direcionados para a avaliação dos eventos de inundação do município. Com relação à análise hidrológica dos eventos, pode-se citar o trabalho de Padilha (2017) que realizou a modelagem hidrológica de três eventos de inundação ocorridos nos anos de 2005, 2008 e 2011 em Lages utilizando o HEC-HMS 4.2. A investigação objetivou avaliar o comportamento dos hidrogramas de cheias desses eventos nas bacias urbanas dos rios Caveiras, Carahá e Ponte Grande, em locais não monitorados por estações fluviométricas. O estudo foi pioneiro ao mostrar as contribuições volumétricas e as taxas máximas provenientes de diferentes regiões da bacia de captação e dos escoamentos afluentes à planície topográfica de inundações do rio Caveiras em Lages.

Em estudo preliminar sobre o comportamento hidrodinâmico das inundações em Lages, NETO *et al.* (2015) utilizaram o modelo físico HEC-RAS 4.1. A simulação foi realizada a partir de um modelo unidimensional e em regime permanente de escoamento

para os rios Caveiras, Carahá e Ponte Grande. Este trabalho produziu um mapa de inundação para o evento de 2011, porém as vazões de entrada foram superestimadas, como consequência obteve-se uma área de inundação maior do que aquela previamente mapeada pela Defesa Civil.

Também no âmbito da análise espacial das inundações, Makrakis (2017) avaliou as áreas com suscetibilidade à inundação dentro do perímetro urbano de Lages. As principais cotas de inundação do evento ocorrido em 2014 foram obtidas utilizando tecnologias GNSS e informações fornecidas pelos órgãos de gestão do município. Esse estudo forneceu indicadores sobre a extensão da inundação e possibilitou identificar quais as regiões e edificações que possivelmente seriam mais atingidas.

A influência do rio Caveiras nas inundações urbanas de Lages foi analisada através de simulação hidrodinâmica, utilizando-se o HEC-RAS 5.0.3, a partir da modelagem bidimensional (LIZ, 2018). Os resultados indicaram que o rio Caveiras é um agente importante nas inundações urbanas, porém não é o único fator interveniente. As bacias urbanas são altamente impermeabilizadas e contribuem para as áreas inundadas nos rios Carahá e Ponte Grande, a montante dos seus exutórios com o rio Caveiras.

Recentemente foi realizado o projeto Hidro-Lages, financiado pela Prefeitura Municipal de Lages e desenvolvido em conjunto com a Universidade do Estado de Santa Catarina (UDESC), que produziu uma análise de viabilidade técnica e ambiental da implementação de medidas estruturais para a minimização dos impactos causados pelas chuvas intensas no município. No âmbito do projeto, foram elaborados estudos técnicos hidrológicos e hidrodinâmicos que permitiram compreender, de forma mais detalhada que os estudos anteriores, o comportamento das inundações na região urbana de Lages. A análise hidrológica indicou que a maioria dos eventos de inundação na cidade estão associados às chuvas máximas diárias, que ocorrem em períodos acumulados de chuvas intensas de 3 a 5 dias (NETO, 2019b). Além disso, o estudo hidrodinâmico confirmou as hipóteses já levantadas por outros autores sobre a influência das bacias urbanas para a ocorrência de inundações da região ao entorno dos rios Caveiras, Carahá e Ponte Grade (LIZ, 2018; NETO, 2019c).

O Plano de Contingência de Proteção e Defesa Civil (PLACON), elaborado pela COMPDEC-LAGES, constitui-se de um conjunto de diretrizes e ações que norteiam o monitoramento e atendimento das situações de risco e emergências desencadeadas por desastres hidrológicos. O PLACON tem como objetivo definir, identificar e relacionar as atividades que devem ser desenvolvidas no âmbito operacional para reduzir os impactos

negativos ocasionados por eventos hidrológicos adversos em Lages. Nele estão descritas as atividades a serem realizadas pela COMPDEC e demais órgão responsáveis do município em eventos de desastre, de forma a auxiliar, especialmente na fase de resposta do GND de Lages (COMPDEC, 2018).

A COMPDEC costuma responder a inundações de grande magnitude com a emissão de decretos de reconhecimento, por parte do município, de Situação de Emergência ou Calamidade Pública. Este mecanismo permite atender com agilidade as necessidades imediatas da população frente aos eventos de caráter excepcional. Consta no PLACON que as ações de resposta também envolvem a assistência aos atingidos e a realocação deles para centros de atendimento (abrigos). O acionamento dos centros de atendimento é realizado na etapa de preparação, sempre que houver a emissão de alerta para as áreas de atenção definidas no PLACON.

As atividades de preparação seguidas pela COMPDEC têm, sobretudo, caráter logístico, a partir da definição de quais regiões devem ser evacuadas ou protegidas e do mapeamento e adequação dos centros de atendimento. Atualmente, os critérios seguidos pela COMPDEC para iniciar as ações são provenientes do acompanhamento da previsão diária de chuva e de boletins informativos emitidos pelo Sistema Estadual de Defesa Civil e pela EPAGRI/CIRAM.

De acordo com o PLACON (COMPDEC, 2018), as ações da fase de mitigação devem ser iniciadas 60 dias antes do período chuvoso da região e são: a desobstrução e manutenção dos bueiros públicos, campanhas de conscientização junto à população para limpeza e conservação de drenagens domésticas, bueiros e entrada de galerias, vistorias técnicas, manutenção das encostas e mapeamento de áreas de risco. A fase de mitigação também contempla ações relacionadas a estudos de natureza técnico-científica, envolvimento de entidades de classe, campanhas educativas de conscientização junto à população para a deposição correta de resíduos, aprovação de leis e normas e estruturação dos órgãos que prestam suporte às ações elencadas nas demais etapas do GDN.

As ações da COMPDEC também ocorrem na etapa de recuperação com o atendimento às necessidades da população atingida, visando a reparação e o reestabelecimento das comunidades. Isso inclui obras de reconstrução, como pavimentação, desobstrução e limpeza das áreas afetadas, distribuição de material de construção civil (telhas e lonas), cestas básicas, kits de limpeza e de higiene pessoal.

Conclui-se, portanto, que a cidade de Lages tem um histórico de ações no âmbito do gerenciamento de desastres causados por inundações provenientes de um conjunto de

iniciativas focadas nas etapas de mitigação, resposta e recuperação. Contudo, a etapa de preparação encontra-se orientada, principalmente, para a logística das ações durante os eventos. Percebe-se a quase inexistência de um sistema de previsão e alerta local, capaz de lidar com as variáveis hidrológicas do domínio do problema e realizar previsões precisas, apesar de já terem sido realizados alguns estudos sobre as inundações que ocorrem na região. Atualmente, as previsões que chegam à COMPDEC são aquelas realizadas em escala estadual, sem as devidas resoluções espacial e temporal exigidas para a tomada de decisão, especialmente acerca da evolução do evento e sua tendência, no curto prazo, sobre as áreas de maior exposição e vulnerabilidade.

Dispor de previsões precisas é importante para o GDN, por possibilitar a ampliação das ações de preparação e, também, das ações emergenciais de resposta. É neste contexto que este trabalho se insere, na medida em que explora a possibilidade de utilização de modelos matemáticos, capazes de produzir resultados rápidos e eficientes, para previsão de profundidades de inundação em locais estratégicos da planície inundável urbana. Dessa forma, contribuir para a configuração de um sistema de previsão eficiente, capaz de fornecer ao decisor um parâmetro tangível (profundidade da água) que tanto o poder público quanto a população são capazes de compreender e analisar. O que favorece o processo de tomada de decisão para que a resposta ocorra de maneira eficiente e em tempo hábil durante um evento de desastre por inundação.

3.4 SISTEMAS DE ALERTA

Os sistemas de alerta são capazes de fornecer informações importantes quanto à iminência de um evento potencialmente danoso em tempo hábil para que medidas de resposta sejam executadas, como a retirada preventiva de bens materiais e evacuação da população de áreas a serem atingidas (PEDROLLO *et al.*, 2011).

Um modelo genérico de sistema de alerta que contempla a possibilidade de previsão de inundação, com antecedência apropriada, foi apresentado por Krzysztofowicz (1993). Neste modelo há três módulos básicos: monitoramento, previsão e decisão. O módulo de monitoramento coleta, trata, armazena e distribui os dados hidrometeorológicos. Esses dados são utilizados, direta ou indiretamente, pelo módulo de previsão, geralmente representado por modelos. O módulo de decisão é representado por uma organização de gerenciamento de emergência (KRZYSZTOFOWICZ, 1993; NETO, 2000).

Apesar do significado geral ser o mesmo, existem abordagens mais detalhadas para a definição da configuração de um sistema de alerta, podendo ser composto por quatro componentes (UNISDR, 2006): (1) conhecimento do risco; (2) Monitoramento técnico e previsão; (3) Comunicação e disseminação do alerta; e (4) Capacidade de resposta. Uma linha semelhante de estruturação básica para um sistema de alerta foi apresentada por Tucci (1997), enfatizando que os itens (1) e (2) representam atividades realizadas antes da ocorrência do evento, seja na etapa de mitigação ou na etapa de preparação e envolvem o estabelecimento de procedimentos técnicos efetivos e a modelagem do domínio do problema.

É o caso do modelo SAISP (Sistema de Alerta a Inundações de São Paulo), operado pela Fundação Centro Tecnológico de Hidráulica (FCTH), que monitora o comportamento hidrológico pela rede telemétrica de hidrologia do Departamento de águas e Energia Elétrica do Estado de São Paulo (DAEE) e pelo radar meteorológico de São Paulo (DAEE/FAPESC). Os principais produtos do SAISP são mapas de chuva observada na área, leituras de níveis fluviais e mapas com previsões de inundação na cidade de São Paulo. Também pode-se citar os sistemas que vêm sendo instalados e operados pela Companhia de Pesquisas de Recursos Minerais/Serviço Geológico Brasileiro (CPRM/SGB). Já foram instalados Sistemas de Alerta de Eventos Críticos (SACE) em dezesseis bacias hidrográficas no Brasil. Os SACE funcionam a partir do monitoramento da bacia, com dados que são recebidos a cada 1 hora por transmissores via satélite ou GSM instalados nas estações de monitoramento automáticas. Esses dados são provenientes das estações da Rede Hidrometeorológica Nacional (RHN), de responsabilidade da Agência Nacional das Águas e Saneamento Básico (ANA), e operada pela CPRM. Os dados são recebidos, consistidos e processados por meio de modelos hidrológicos elaborados pela equipe da CPRM, e consolidados em forma de boletins de monitoramento, enviados às defesas civis estaduais, municipais, ao Centro Nacional de Monitoramento de Risco e Desastres (CENAD), à ANA, ao CEMADEN, e demais órgãos de interesse. Sempre que há necessidade, são enviados também boletins de alerta hidrológico, com informações adicionais de previsões dos níveis dos rios, de forma que os órgãos atuantes possam se preparar da melhor forma possível para o evento.

Em Santa Catarina, a Epagri/Ciram é a instituição estadual designada para emitir e comunicar avisos hidrometeorológicos. A Secretaria de Estado da Defesa Civil (SDC) tem a responsabilidade de receber, analisar e disseminar os avisos e alertas de instituições

federais, estaduais, regionais, municipais e locais no contexto do Sistema Estadual de Proteção e Defesa Civil.

Basicamente, sistemas de alerta configuram um pacote integrado de equipamentos de coleta e transmissão de dados, um sistema de modelagem de previsão e monitoramento, um sistema de comunicação de alertas e um componente correspondente às ações de resposta, que envolve os órgãos estaduais ou municipais responsáveis (KOURGIALAS; KARATZAS, 2011). É possível encontrar autores que conceitualizam um sistema de alerta para inundações como sendo a combinação entre um subsistema de previsão de inundação (componente técnico-científico) e um subsistema de disseminação do alerta de inundação (componente social) (HANDMER; PENNING-ROWSELL, 1990; PARKER; FORDHAM, 1996).

Os eventos de inundação ocorrem distribuídos no tempo e no espaço, de forma aparentemente aleatória, algo que exige desses sistemas grande complexidade em função da existência de incertezas na previsão. Avanços nas pesquisas relacionadas às diferentes configurações e particularidades de sistemas de alerta indicam interesse em aprimorar as estratégias de gestão de risco de desastre. Existe a sugestão de uma etapa de revisão do sistema de alerta para que este possa ser adaptado a novas necessidades por meio de análises contínuas (PEDROLLO *et al.*, 2011). O que significa que um sistema de alerta depois de implementado não será um produto estático que jamais será revisto, mas dinâmico e atualizado sempre que necessário (FINCK, 2020).

3.5 PREVISÃO DE INUNDAÇÃO

Diversos fatores hidrológicos e hidrodinâmicos relacionados com o domínio do problema são importantes para o gerenciamento de desastres causados por inundações e, conseqüentemente, para implementação de sistemas de alerta úteis. Utilizar modelos para realizar previsões relacionadas a eventos de inundação é um desafio, pois os modelos são sensíveis à distribuição temporal e espacial da precipitação e a fatores geomorfológicos da bacia hidrográfica (BELL; MOORE, 2000; IVANOV *et al.*, 2004). Os modelos devem ser capazes de prever o estado dos componentes fisiográficos e hidrodinâmicos do domínio do problema para projetar cenários futuros.

Os modelos de previsão são capazes de representar o mundo físico e os processos e fenômenos que nele ocorrem a partir da sintetização de fatores, como características de impermeabilização do solo, tipo de cobertura vegetal, intensidade e variabilidade espacial da precipitação, além da geomorfologia dos rios e planícies de inundações (MONTE *et*

al., 2016). Os modelos também podem representar os processos de armazenamento e transferências de água na natureza, por meio de preceitos matemáticos. A representação do domínio físico é tratada por alguns autores como modelagem de dados geográficos e a do domínio de fluxo de massa e energia como modelagem científica (NETO; RODRIGUES, 1999).

Os Sistemas de Apoio à Decisão Espacial (SADE) são sistemas capazes de representar esses dois domínios do mundo real e prover ferramentas de apoio ao processo decisório. Quando a previsão de inundações envolve a modelagem científica, representada pelos processos de armazenamento e transferências de água e a modelagem de dados geográficos, dada pela representação geográfica ou espacial das variáveis existentes nesses processos, então os sistemas de previsão e alerta a inundações são elementos de suporte à decisão agregados ao SADE (NETO; RODRIGUES, 1999).


A previsão é a capacidade de estimar com antecedência o estado futuro de um sistema, podendo ser classificada em previsão de curto prazo – algumas horas até alguns dias - ou longo prazo – várias semanas ou meses (MOSAVI; OZTURK; CHAU, 2018; TUCCI, C. E., 2005). Para inundações urbanas geralmente são utilizadas previsões de curto prazo (HAPUARACHCHI; WANG; PAGANO, 2011; PAGANO *et al.*, 2014; PEDROLLO, O. C., 2017). O tempo de antecedência máximo da previsão (T_f) dependerá das características hidrológicas da bacia como o tempo de concentração (T_c) e o tempo de propagação da onda de cheia ao longo do canal principal (T_r) (TUCCI, 2005). A combinação destes tempos determina o tipo de modelo a ser utilizado e, por conseguinte, os requisitos necessários para que o modelo funcione.

Por exemplo, quando T_c é grande comparado com T_f , as previsões podem ser baseadas em modelos de transformação chuva-vazão que utilizam dados de chuva observada. Esta análise é genérica e especulativa uma vez que não há parâmetros objetivos que estabeleçam, efetivamente, quando utilizar uma ou outra estratégia de modelagem. Quando T_r é grande comparado com T_f , as previsões podem ser baseadas em propagação, com modelos vazão-vazão. Essa situação é comum em bacias médias e grandes, nas quais a área a ser inundada está a uma distância significativa do início do canal principal, sendo que o principal fluxo causador da inundação vem de canais distantes.

Outro parâmetro que deve ser considerado é o tempo de pico (T_p) que é o tempo transcorrido entre momento do centro de massa da chuva e o momento quando ocorre a vazão de pico (Figura 2). Nesta situação, deve-se observar continuamente a evolução da

chuva em intervalos regulares e projetar com auxílio do modelo o momento da vazão de pico. O tempo de antecedência deve ser menor que o tempo de pico em valor suficiente para as ações de resposta ocorrerem.

Figura 2- Características importantes do hidrograma e definição dos tempos.



Fonte: Adaptado de Collischonn; Tassi (2008).

Como o T_f é um elemento chave para a previsão de inundações, a utilização de modelos empíricos para previsão é de particular interesse em função de seu baixo tempo computacional comparado com modelos físicos convencionais (HENONIN *et al.*, 2013; MOSAVI; OZTURK; CHAU, 2018). Os modelos empíricos possuem aplicação para previsão de inundações, pois aplicam técnicas estatísticas e de inteligência computacional para relacionar dados hidrológicos (ex. precipitação) com dados de fluxo de água em canais. Esses modelos apresentam melhores desempenhos em situações em que as interações e dependências dos processos físicos são desconhecidas ou parcialmente conhecidas (HAPUARACHCHI; WANG; PAGANO, 2011). A disponibilidade de dados de sensoriamento remoto, como imagens de satélites, promoveu o aprimoramento de modelos físicos para previsão e aplicação em sistemas de alerta (ACOSTA-COLL; BALLESTER-MERELO; MARTÍNEZ-PEIRÓ, 2018) e até mesmo o desenvolvimento de técnicas de detecção de inundações em escala global (ALFIERI, L. *et al.*, 2013). Essas técnicas proporcionaram visões gerais das áreas afetadas, além do aperfeiçoamento dos sistemas de previsão e alerta, do gerenciamento de risco e de ações de resgate.

Em Bruen e Yang (2006) foi testada a hipótese de que um modelo empírico de redes neurais artificiais é capaz de ajustar o componente determinístico das deficiências do modelo hidráulico/físico. A técnica foi aplicada em uma pequena bacia urbana, utilizando dados de precipitação e vazão observados. Essa alternativa mostrou-se capaz de melhorar as previsões de fluxo dos canais para uma ampla gama de alcances de previsão, comprovando que é possível a combinação de modelos físicos com modelos empíricos para melhorar o desempenho de simulação em tempo real e a eficiência da previsão no âmbito de sistemas de previsão e alerta a inundações.

3.6 MODELOS HIDRODINÂMICOS

Os modelos são ferramentas utilizadas para simular o comportamento da água na bacia hidrográfica procurando representa-lo tão exato quanto possível (NETO, 2019c). A modelagem para simulação de eventos de inundação teve um incremento significativo nas últimas décadas, a partir de avanços computacionais e do desenvolvimento de softwares de simulação mais precisos. A introdução dos modelos hidrodinâmicos na modelagem de eventos de inundação é uma consequência deste ciclo de desenvolvimento tecnológico, que inclui a integração da modelagem científica com a modelagem geográfica (NETO; RODRIGUES, 1999).

Uma das aplicações da modelagem hidrodinâmica é o mapeamento de áreas suscetíveis a inundações, normalmente realizado em duas etapas: a primeira corresponde à modelagem hidrológica, com o objetivo de determinar os hidrogramas de máximas em junções da rede hidrográfica que tenham relação direta com as áreas inundáveis; a segunda é a inserção desses hidrogramas como dados de entrada em modelos de simulação hidrodinâmica (GUASSELLI *et al.*, 2016; TENG *et al.*, 2017). Estes modelos têm por função propagar, a partir das junções mencionadas, as vazões em regimes permanente ou não permanente ao longo dos canais, determinando os níveis ou alturas associadas aos volumes propagados nos canais (HICKS; PEACOCK, 2005).

A popularidade dos modelos hidrodinâmicos na análise de eventos de inundação pode ser atribuída, em parte, à ligação direta dos eventos hidrodinâmicos aos eventos hidrológicos, à possibilidade de criação de mapas com superfícies de inundação (LIZ, 2018), a inserção de estruturas hidráulicas (pontes, galerias, contenções etc.) e ainda a quantificação do tempo de duração do evento (TENG *et al.*, 2017). Os resultados da simulação podem ser acessados na forma de tabelas, mapas e gráficos, os quais podem

estar associados a modelos digitais de terrenos, imagens de satélites de alta resolução ou mapas temáticos. Dessa forma, os modelos hidrodinâmicos podem contribuir para a implementação de medidas estruturais, como dimensionamento de barramentos e diques de contenção, e medidas não-estruturais, a partir da análise hidrodinâmica das inundações e a consequente configuração de sistemas de previsão e alerta (RIBEIRO; LIMA, 2011).

A modelagem hidrodinâmica unidimensional (1D) e bidimensional (2D), normalmente é utilizada no mapeamento de inundações. Os mapas de inundação ilustram os fenômenos hidráulicos envolvidos, pelos quais definem-se a profundidade da água, os níveis máximos de inundação, a evolução e velocidade do fluxo e também a variação da vazão ao longo do tempo da simulação (HENONIN *et al.*, 2013; PAIVA; COLLISCHONN; BUARQUE, 2011). A profundidade do nível d'água em um determinado ponto da planície inundada pode ser utilizada como indicador de alerta quando for determinada dentro do tempo de antecedência máximo (T_f). Para isso, os modelos bidimensionais, associados ao uso de modelos topográficos de alta resolução, têm se mostrado promissores, dado que tais modelos produzem resultados interessantes em locais de relevo complexo (COSTABILE; MACCHIONE, 2015).

São diversas as plataformas disponíveis para simulação hidrodinâmica, podem ser mencionadas como exemplos: *Storm Water Management Model* (SWMM); MIKE; SOBEK; FLO-2D; LISFLOOD; TELEMAC, Delft3D, HEC-RAS. A maioria oferece interação com Sistemas de Informações Geográficas (SIG) e permitem a manipulação de dados externamente ao software, com importação e conversão de arquivos em extensões diversas, o que fez a modelagem de inundações melhorar de forma considerável nos últimos anos (LIZ, 2018).

O HEC-RAS, *Hydrological Engineering Center River Analysis System* (USACE, 2016a), é largamente utilizado para fins de simulação de inundações (BOBOC *et al.*, 2016; LIZ, 2018; MALIK; AHMAD, 2014), mostrando-se capaz de executar cálculos hidráulicos unidimensionais e bidimensionais para uma rede completa de canais naturais e construídos e planícies de inundação, sob regime de escoamento permanente ou não-permanente, além de permitir a análise de transporte de sedimentos. Para toda esta multiplicidade de simulações, há a possibilidade de criação de gráficos e tabelas, avaliação em interface gráfica e oportunidade de criar animações de eventos e cenários (MACHADO, 2017; USACE, 2016a).

A interface do HEC-RAS é bastante intuitiva e de fácil utilização para o usuário. Na sua janela principal devem ser inseridos três tipos de arquivos, que são manipulados

dentro do próprio software. Cada projeto deve conter um arquivo de geometria, um de vazão, e um arquivo com as especificações da simulação. Há possibilidade de acoplamento entre modelos 1D e 2D, o que permite simulações utilizando-se de estruturas geométricas comuns em modelos unidimensionais, como as *cross sections*, estruturas no canal, estruturas laterais ao canal e áreas de armazenamento (USACE, 2016a).

Nas simulações 2D, a formulação matemática, através de uma abordagem de matrizes e malhas flexíveis ou não, permite o uso de equações simplificadas de diferenças ou volumes finitos. Estas estruturas em formato de malhas proporcionam a modelagem de áreas secas e molhadas em locais planos ou com descontinuidade topográfica – pontos de saltos ou declives em locais rasos –, sem prejuízo aos resultados do modelo (TENG *et al.*, 2017). Modelos hidrodinâmicos como o HEC-RAS representam uma simplificação do complexo sistema hidrológico-hidráulico que envolve um curso d'água, o que permite sua aplicação para estimar áreas inundáveis e gerar mapas de zonas suscetíveis a inundações (SAVAGE *et al.*, 2016).

O acoplamento de tecnologias SIG com softwares de modelagem hidrodinâmica caracterizam os Sistemas de Apoio à Decisão Espacial – SADE (NETO; RODRIGUES, 1999). A partir da integração desses modelos com ferramentas SIG, é possível a exportação de resultados georreferenciados na forma de mapas de inundação dentro da abordagem de um SADE (CANHOLI, 2014). Khalfallah; Saidi (2018) e Knebl *et al.* (2005) realizaram essa associação, a partir da incorporação de uma extensão do ArcGis à modelagem hidrodinâmica realizada no HEC-RAS para a produção de mapas de inundação. Os autores verificaram a eficiência desta metodologia para previsões de inundações, o que demonstra a versatilidade da ferramenta para estudos neste tema, e que esta pode ser incorporada em um sistema de alerta para mitigação de riscos.

3.7 REDES NEURAIS ARTIFICIAIS

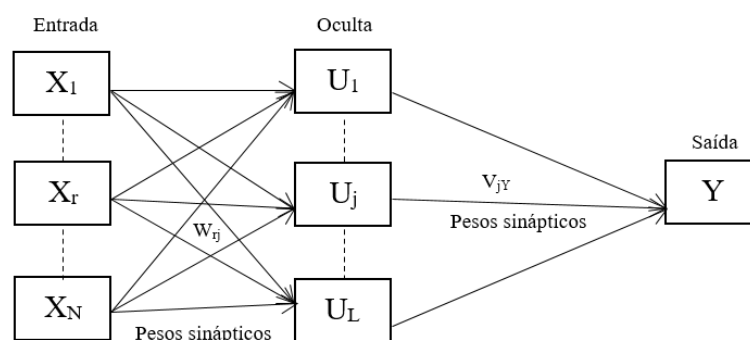
As redes neurais artificiais (RNAs) são modelos empíricos, caracterizadas por serem sistemas paralelos distribuídos que relacionam um conjunto de vetores de entrada a um conjunto de vetores de saída (BRAGA; LUDEMIR; CARVALHO, 2007). As relações numéricas entre estes dois conjuntos não possuem significado físico e sua função é produzir valores de saídas tão exatos quanto possível.

Originalmente, as RNAs foram desenvolvidas para supostamente mimetizar o funcionamento esquemático dos sistemas neurais biológicos (neurônios e sinapses biológicos) (MACCULLOCH; PITTS, 1943), sendo capazes de aprendizado quando

submetidas a treinamento, e de resposta a estímulos de acordo com esse treinamento. O aprendizado ocorre por meio da ativação de neurônios e sinapses. Por isso, as RNAs são estruturadas por meio de nós (neurônios) de entrada, camada intermediária (neurônios e sinapses) e nós (neurônios) de saída. Esses elementos são interconectados por conexões chamadas de pesos sinápticos e representados matematicamente por grafos direcionados.

O modelo mais típico de rede neural artificial é o tipo MLP (*Multilayer Perceptron*). As RNAs do tipo MLP são caracterizadas por conterem, pelo menos, uma camada intermediária (Figura 1). Estas redes apresentam um poder computacional muito maior do que as redes sem camadas escondidas (RUMELHART *et al*, 1986), sendo consideradas aproximadores universais (HECHT-NIELSEN, 1987).

Figura 3-Arquitetura da rede MLP (Multilayer Perceptron)



Fonte: Elaborado pela autora (2020).

A estrutura interna da rede neural é formada por funções de transferência não lineares interconectadas e embora cada neurônio individual implemente sua função de forma lenta e imperfeita, coletivamente a rede é capaz de realizar tarefas de forma surpreendentemente eficiente (REILLY; COOPER, 1990). Essa característica de processamento de informações faz das RNAs um instrumento computacional poderoso, capaz de aprender a partir de exemplos e, então, generalizar para situações desconhecidas. Ou seja, as RNAs são capazes de aprendizado quando submetidas a treinamento, possuindo a capacidade de memorização e resposta a estímulos (PEDROLLO; PEDROLLO, 2013).

O aprendizado das redes neurais biológicas ocorre através da alteração das conexões entre neurônios. A partir desse princípio, Hebb (1949) desenvolveu o primeiro método de treinamento para redes neurais artificiais, denominado de regra de aprendizado de Hebb, difundindo o conceito de plasticidade sináptica. A primeira aplicação prática

desses conceitos deu origem ao modelo básico do *Perceptron*, introduzido por Rosenblatt (1958). Em seguida, Widrow e Hoff (1960) desenvolveram um tipo de rede neural chamada Adaline – máquina de Adaptação Linear – utilizando funções de ativação contínuas e lineares. Basicamente, o objetivo de uma rede é identificar padrões de entrada para certos padrões de saída, no entanto, um Perceptron não é capaz de mapear certos padrões não lineares – simetria, paridade e conectividade, por exemplo.

Esse tema foi abordado por Minsky e Papert (1969) ao discutirem os limites dos Perceptron. Isso provocou uma paralisação nas pesquisas de redes neurais artificiais devido à falta de um procedimento simples e genérico para treinar redes de três ou mais camadas. A evolução nas pesquisas se deu novamente a partir da década de 80, quando Rumelhart *et al.* (1986) apresentou um algoritmo de retropropagação de erros que permitia o ajuste dos pesos sinápticos em redes com mais de uma camada, chamado método retropropagativo. Esse método é uma generalização da regra delta (WIDROW; HOFF, 1960), por meio da retropropagação dos erros de cada camada para a anterior. Ou seja, o erro da penúltima camada é a variação do erro quadrático de saída em função dos estados da penúltima camada (Equação 1).

$$e_{int}^2 = \frac{\partial e_{sai}^2}{\partial f} * \frac{\partial f}{\partial (w_{sai} * s_{int})} * \frac{\partial (w_{sai} * s_{int})}{\partial s_{int}} = e_{sai}^2 * f'(w_{sai} * s_{int}) * w_{sai} \quad (1)$$

Em que: e_{int} = erro na camada interna; e_{sai} = erro na camada posterior; w_{sai} = pesos sinápticos na camada posterior; s_{int} = derivadas da função de ativação da camada interna;

Esse método é simples e de fácil implementação, mas apresenta alguns problemas como a convergência lenta e, por vezes, ineficiência (ZHANG; PATUWO; HU, 1998). Pode-se acelerar o treinamento adicionando um termo que depende da última alteração feita nos pesos, evitando a oscilação extrema e aumentando a velocidade de aprendizado (Rumelhart *et al.*, 1986). Esse termo ficou conhecido como termo do momento de inércia (Equação 2).

$$\Delta w(t) = -\tau * \delta * P * \alpha * \Delta w(t - 1) \quad (2)$$

Em que: τ = taxa de aprendizado; δ = derivada da função de ativação; P = sinal de entrada; α = Coeficiente do momento de inércia a ser definido; $\Delta w(t - 1)$ = Passo aplicado no ciclo anterior.

Vogl *et al.* (1988) implementaram melhorias no algoritmo retropropagativo, ao utilizar uma taxa heurísticamente variada para o treinamento, combinada com o termo de momento. O método da taxa heurísticamente variável consiste em, quando o erro em um ciclo de treinamento sofrer redução, aumentar a taxa no próximo ciclo. Em contrapartida, quando a os erros aumentam, a taxa de aprendizado é reduzida, sendo os fatores de redução e aumento, recomendados, respectivamente 0,5 e 1,1.

Um problema que pode ocorrer durante o treinamento de redes neurais é o superajustamento (*overfitting*). O superajustamento ocorre quando a rede memoriza excessivamente os exemplos de treinamento, mas não consegue generalizar frente a entradas que não foram apresentadas no treinamento. Em outras palavras, a rede é capaz de replicar o comportamento individual das amostras de treinamento, incluindo erros e aleatoriedade, perdendo a capacidade de generalização (PEDROLLO; PEDROLLO, 2013). Existem alternativas para superar o problema de superajustamento, sendo que uma delas é realizar a interrupção antecipada do treinamento aplicando a técnica de validação cruzada (HECHT-NIELSEN, 1990). Para isso, divide-se os dados em três conjuntos: treinamento, validação e verificação. A divisão dos dados deve ser realizada com cautela. O conjunto de treinamento precisa dos valores extremos das entradas e saídas, pois RNAs não são indicadas para extrapolações fora do domínio numérico de treinamento (PEDROLLO, 2017). O conjunto de verificação precisa de alguns eventos extremos para verificar que o treinamento garantiu uma boa generalização (ECKHARDT, 2008).

O treinamento é realizado com o primeiro conjunto e, a cada ciclo, testa-se a rede com o conjunto de validação para determinar um ponto de parada ótimo. O treinamento é interrompido no ciclo em que a métrica de desempenho para o conjunto de validação passa a ser pior, pois, a partir desse, a rede passará a ser superajustada, perdendo progressivamente a capacidade de generalização (HECHT-NIELSEN, 1990). O algoritmo de treinamento depende do conjunto de pesos iniciais, uma vez que a atribuições de pesos sinápticos aleatórios pode causar o estacionamento em uma região de mínimo local. Esse problema pode ser evitado realizando repetições no treinamento, com a escolha do modelo que apresentou melhor desempenho com a amostra de validação, o que aumenta a robustez do modelo (DORNELLES, 2007; OLIVEIRA *et al.*, 2014).

Além disso, o controle do superajustamento pode ser feito pela limitação dos graus de liberdade (número de neurônios internos) do modelo. A pesquisa de uma complexidade interna mínima da RNA (número de neurônios intermediários) deve

resultar em uma rede neural com a menor complexidade possível, que ainda preserva a mesma capacidade de aproximação e generalização de uma rede propositalmente superdimensionada, a qual não apresente superajustamento, devido à interrupção oportuna do treinamento (LUCCHESI; DE OLIVEIRA; PEDROLLO, 2020; SARI; CASTRO; PEDROLLO, 2017). A pesquisa de complexidade é realizada a partir dos resultados da amostra de validação.

A amostra de verificação, por sua vez, é utilizada para a avaliação final da capacidade de generalização, e não deve ter participado de nenhuma etapa anterior, nem do treinamento, nem da escolha da configuração da rede neural (HECHT-NIELSEN, 1990).

A aplicação de RNAs para modelos de previsão vem sendo estudada desde 1964, quando Hu (1964) utilizou uma versão adaptada da rede Adaline (WIDROW; HOFF, 1960) para previsão do tempo, ainda que de forma limitada. Cottrell *et al.* (1995); Lapedes e Farber (1987) aplicaram RNAs para previsão de séries temporais e obtiveram resultados muito satisfatórios, o que contribuiu para a utilização de RNAs na modelagem de problemas não lineares, como no caso de previsões temporais. Verificou-se que as RNAs são ferramentas robustas para modelar muitos processos hidrológicos não lineares e possuem aplicações em diversas áreas da hidrologia como: chuva-vazão, vazão-vazão, gerenciamento de água subterrânea e estimação da precipitação (ASCE, 2000). Esses modelos são muito utilizados devido à simplicidade conceitual com que é representado o sistema hidrológico de uma bacia hidrográfica.

Um exemplo de que a utilização de RNAs para generalização de sistemas complexos com vistas à aplicação em bacias hidrográficas reais é possível foi elaborado por Minns e Hall (1996). Os autores utilizaram dados sintéticos de eventos de precipitação com a intenção de avaliar a capacidade da rede neural de compreender os padrões de entrada fornecidos por uma sequência de chuvas, com saídas na forma de vazão. Os resultados indicaram que as RNAs são capazes de identificar relações utilizáveis entre a vazão e precipitações antecedentes. A aplicação de RNAs para previsão de desastres de inundação na China foi testada por Wei *et al.* (2002), utilizando uma série de dados de 1949 a 1994. Os resultados obtidos confirmam que RNAs possuem uma capacidade válida de previsão de desastres, e simples, uma vez que seu processo independe do conhecimento dos tipos de relações entre as variáveis.

As RNAs mostraram-se capazes de realizar previsões de vazões de um rio em condições normais e em condições extremas, comumente causadoras de eventos de

inundação (TINH, 2019). O bom desempenho da RNA para previsão de vazões extremas foi obtido a partir do treinamento do modelo com dados observados de seis estações climatológicas. Uma análise de regressão linear múltipla foi realizada com os mesmos dados para validação da metodologia. As previsões da RNA MLP apresentaram resultados superiores às aquelas da análise de regressão em todas as métricas de avaliação (R^2 , MSE, RMSE).

As RNAs proporcionam rapidez do processo de treinamento do modelo e respostas preditivas com altos índices de qualidade, permitindo aplicá-las em situações que exigem respostas rápidas, como no caso da previsão de inundações (DEBASTIANI, 2016). Uma vasta quantidade de estudos foi realizada com relação à capacidade preditiva de RNAs no processo chuva-vazão (AWCHI, 2014; MOSAVI; OZTURK; CHAU, 2018; OLIVEIRA *et al.*, 2013). Neto *et al.* (2019) mostraram que modelos de base numérica (RNA e Árvore de Decisão) apresentaram resultados mais satisfatórios na previsão de vazões diárias que os modelos de base física (TOPMODEL e SWAT), quando a vazão do dia anterior (Q_{t-1}) foi incorporada na camada de entrada. No entanto, no âmbito da previsão de inundações, os parâmetros de entrada para calibração da rede podem variar. A utilização apenas de dados pluviométricos e fluviométricos apresenta limitações devido à alta variabilidade espaço-temporal dos eventos de precipitação associados a inundações. Essa limitação ocorre, principalmente, em função de que algumas regiões apresentam baixa densidade de sensores e redes de monitoramento hidrometeorológicos funcionais (MISHRA; COULIBALY, 2009).

As RNAs também vêm sendo utilizadas com o intuito de previsões de níveis fluviais para a emissão de alerta a inundações urbanas (BERKHAHN; FUCHS; NEUWEILER, 2019; BERMÚDEZ; CEA; PUERTAS, 2019; JHONG; WANG; LIN, 2017; MIGNOT; LI; DEWALS, 2019; PAN *et al.*, 2011; PEDROLLO, O. C., 2017; SILVA, 2019). Em Pedrollo (2017) foram desenvolvidos modelos de previsão de nível a partir de diferentes grupos de postos fluviométricos para a localidade de Estrela/RS. Os níveis fluviais previstos revelaram-se instrumentos úteis para orientar ações preventivas, sendo os modelos capazes de realizar previsões para alcances de 5 horas e 11 horas com MEA igual a 0,09 m e 0,14 m, respectivamente.

Um modelo de RNA desenvolvido com a aplicação de técnica de amostragem sistemática para composição das séries de dados de treinamento e de médias móveis - com uso de ponderação temporal exponencial e gama-, sobre os dados de entrada foi utilizado para compor uma ferramenta capaz de gerar e integrar as previsões

fluviométricas com a espacialização de áreas inundáveis, além de estimar os prejuízos na bacia do Rio Caí/RS (SILVA, 2019). Como resultado foram obtidos dois modelos de previsão com alcances de 20h e 24h para os municípios de São Sebastião do Caí e de Montenegro, que resultaram em NS superiores a 0,9. O mapeamento das áreas inundáveis foi obtido através da compatibilização das referências de nível vertical de um MDT de alta resolução e as seções linimétricas existentes no perímetro urbano, resultando na obtenção de manchas de inundação com intervalos de nível de 0,5m, cobrindo uma faixa que vai da cota de início de inundação à cota associada a um TR de 100 anos.

A previsão de inundações em regiões urbanas que carecem de redes de monitoramento hidrológico consolidadas - seja de estações pluviométricas, fluviométricas ou sensores de nível-, é dificultada pela indisponibilidade de dados. Em estudos mais recentes (CHU *et al.*, 2020; DIKSHIT; PRADHAN; ALAMRI, 2020), os autores evidenciam a possibilidade de utilizar dados simulados a partir de modelos de base física (ex.: hidrodinâmicos 2D) para aumentar a quantidade e a qualidade dos dados disponíveis para desenvolvimento dos modelos de RNAs para previsão e mapeamento de inundação. Nesse sentido, a utilização de dados simulados por modelos de base física é uma alternativa interessante, pois permite a produção de uma referência terrestre para treinamento e validação de modelos empíricos, na ausência de registros oficiais observados de inundação.

Bermúdez *et al.* (2018) utilizou os resultados da simulação de um modelo 1D/2D para treinamento de um modelo de RNA para previsão de inundações pluviais. Os autores concluíram que mapas produzidos por modelos físicos podem ser utilizados para uma caracterização razoável da profundidade de inundação de uma superfície, sendo suficientes para desenvolvimento do modelo de RNA.

Devido à pouca disponibilidade de dados observados para realizar previsões de inundação em tempo real para uma região de Taiwan, Jhong; Wang; Lin (2017) propuseram uma abordagem capaz de produzir mapas de inundação com SVM (*Support Vector Machine*) utilizando dados de profundidade de inundação gerados pelo modelo hidrodinâmico FLO-2D. A partir da área de inundação gerada pelo modelo hidrodinâmico, os autores extraíram a profundidade da água em pontos específicos da grade que, juntamente com dados de precipitação acumulada, serviram como dados de entrada para desenvolvimento do modelo de SVM. Em um segundo estágio da pesquisa, foi possível utilizar as informações de grade de simulação 2D para que o modelo empírico também fosse capaz de responder com a espacialização da inundação, gerando mapas das

áreas inundadas. Os resultados produzidos pelo modelo foram muito positivos, com capacidade de realizar previsões espaciais de inundações com 1 h - 6 h de antecedência.

Berkhahn; Fuchs; Neuweiler (2019) também analisaram a abordagem de redes neurais artificiais associado a um modelo hidrodinâmico 2D. Os autores utilizaram o modelo HYSTEM-EXTRAN 2D (HE 2D) para criar um banco de dados de eventos de inundação. Esses dados foram utilizados para o desenvolvimento de uma RNA MLP capaz de reproduzir os níveis máximos da água e a distribuição espacial da inundação, por meio de informações de células inundadas ou não inundadas do modelo HE 2D. Após os resultados obtidos apresentarem tempo computacional e precisão suficientes para integrar um sistema de alerta, o modelo de RNA pode ser visto como um passo importante em direção à previsão 2D em tempo real para inundações.

Seguindo a mesma linha de utilização de modelos empíricos para simulação da distribuição espacial da inundação, Chu *et al.* (2020) evidencia que existe a necessidade de desenvolver modelos mais rápidos e simples que os modelos físicos para simulação de inundação. Os autores utilizaram uma RNA de regressão generalizada (GRNN) para mapeamento de áreas inundadas com dados horários de profundidade da água produzidos pelo modelo hidrodinâmico 2D TUFLOW. O modelo foi aplicado em uma região central da Austrália e os resultados indicam que, com processos de modelagem apropriados e dados suficientes, modelos do tipo de RNAs podem ser uma alternativa rápida e eficiente para simulação de inundação em sistemas ambientais complexos, como regiões urbanas.

Kabir *et al.* (2020) apresentaram uma nova abordagem para previsão de mapas de inundação para aplicação em tempo real utilizando um modelo de rede neural convolucional (CNN) e compararam os resultados com um modelo de SVR (*Support Vector Regression*). Os mapas de inundação foram produzidos pelos modelos empíricos a partir da identificação de células inundadas/não inundadas provenientes do modelo 2D (LISFLOOD-FP), sendo utilizados os resultados do modelo hidrodinâmico para treinamento do modelo CNN. Os resultados mostram que o modelo CNN supera o SVR por uma grande margem. O modelo CNN é altamente preciso na captura de células inundadas de acordo com as métricas de avaliação obtidas (NS e RMSE). Os autores concluíram que o método oferece grande potencial para modelagem de inundação em tempo real e previsão antecipada, considerando sua simplicidade de aplicação, desempenho superior e eficiência computacional.

Diante do exposto, conclui-se que o desenvolvimento da modelagem de redes neurais artificiais é promissor em estudos ou simulações de inundações, sendo possível a

associação de modelos físicos às RNAs a fim de melhorar o processo de simulação e otimizar a produção de resultados confiáveis, com possível utilização em sistemas de previsão e alerta.

3.8 MÉTRICAS PARA AVALIAÇÃO

Têm sido apresentadas diversas métricas que cumprem a função de indicar o desempenho dos modelos de previsão (KITANIDIS; BRAS, 1978). Em sua grande maioria, são obtidas a partir do cotejamento entre os resultados produzidos pelo modelo e os valores respectivos observados a campo. No geral, não há consenso entre os valores limítrofes a serem considerados para classificação do desempenho dos modelos ou sobre a metodologia ideal a ser seguida para avaliação, o que proporciona um certo grau de subjetividade na análise (MORIASI *et al.*, 2015; RITTER; MUÑOZ-CARPENA, 2013).

No entanto, entre as diversas recomendações existentes na literatura, há três mais relevantes que devem ser incluídas para avaliação do desempenho: (1) utilizar pelo menos um indicador de erro absoluto do modelo (apresentado nas unidades das variáveis); (2) um índice adimensional (ou indicador de erro relativo) para quantificar a qualidade do ajuste; e (3) uma representação gráfica da relação entre as estimativas do modelo e as observações (RITTER; MUÑOZ-CARPENA, 2013). A comparação visual dos dados simulados e observados proporciona uma visão geral do desempenho dos modelos (ASCE, 1993; MORIASI *et al.*, 2007).

A média do erro absoluto (MAE - *mean absolute error*) serve para verificar o quanto o valor absoluto produzido pelo modelo, em média, se distancia do valor absoluto da série observada (Equação 1). Esse é um indicador valioso porque apresenta o erro na unidade dos constituintes de interesse, o que auxilia na compreensão e análise dos resultados. Um valor de MAE igual a zero indica um ajuste perfeito do modelo; valores inferiores à metade do desvio padrão dos dados medidos podem ser considerados baixos e apropriados para uma boa avaliação do modelo (MORIASI *et al.*, 2007; SINGH *et al.*, 2004).

$$MAE = \frac{1}{n} * \sum_{i=1}^n |Q_{obs,i} - Q_{sim,i}| \quad (1)$$

Em que: $Q_{obs,i}$ = valor observado no tempo i ; $Q_{sim,i}$ = valor simulado no tempo i .

O indicador de desempenho *Percentage bias* (Pbias) avalia a tendência média dos valores previstos de serem maiores ou menores do que os observados (MORIASI *et al.*,

2015) (Equação 2). O valor ótimo para Pbias é zero, com valores positivos indicando superestimação pelo modelo e valores negativos indicando subestimação. Valores em torno de $\pm 25\%$ são considerados satisfatórios (NETO *et al.*, 2019; PÉREZ-SÁNCHEZ *et al.*, 2019).

$$Pbias = \frac{\sum_{i=1}^n (Q_{obs,i} - Q_{sim,i}) * 100}{\sum_{i=1}^n Q_{obs,i}} \quad (2)$$

Além disso, pode ser empregado como indicador o quantil $E90$, que corresponde aos valores que não foram ultrapassados pelos erros em 90% das previsões. Analisar a distribuição dos erros (ou quantis dos erros), neste caso o $E90$, pode ser uma maneira de inferir se o modelo está tendendo a superestimar ou subestimar na previsão, mas, principalmente, proporciona estimativas de erros extremos esperados.

O coeficiente de eficiência de Nash-Sutcliffe (NS) é uma métrica quantitativa adimensional, tradicionalmente utilizada para avaliação do desempenho de modelos hidrológicos. Ele determina a magnitude relativa da variância residual (ruído) em comparação com a variância dos dados medidos (informação), expressando a proporção da variância dos dados observados que são representados pelo modelo (NASH; SUTCLIFFE, 1970) (Equação 3).

$$NS = 1 - \frac{\sum (Q_{obs} - Q_{sim})^2}{\sum (Q_{obs} - Q_{med_{obs}})^2} \quad (3)$$

4 MATERIAS E MÉTODOS

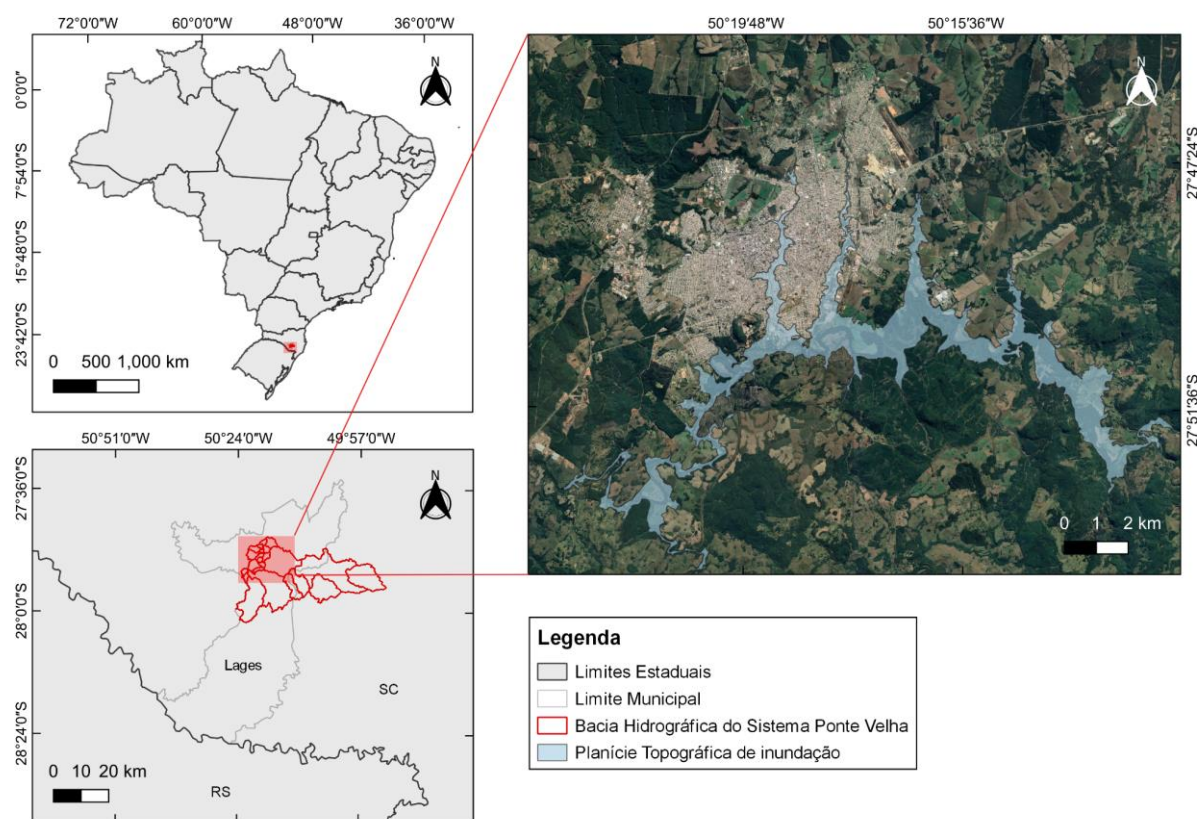
4.1 ÁREA DE ESTUDO

A área de estudo corresponde à região urbana de Lages. A cidade está localizada na região serrana de Santa Catarina, sendo o maior município catarinense em extensão territorial, com área total de 2.651,4 km² (PML, 2020), e população estimada em 157.544 habitantes (IBGE, 2019). Apresenta uma rede hidrográfica bem distribuída, sendo que diversos rios cortam o município, como o rio Caveiras, Carahá, Ponte Grande, Pelotas, Canoas, Lava-tudo, Vacas Gordas, Macacos e Pessegueiro (SANTOS, 2010).

O núcleo urbano de Lages está inserido na bacia hidrográfica do Sistema Ponte Velha, especificamente nas sub-bacias do rio Carahá e Ponte Grande (Figura 4). A bacia hidrográfica do Sistema Ponte Velha possui aproximadamente 798,45 km², abrange também os municípios de Paineira e Urupema, podendo ser subdividida em 11 sub-bacias (NETO, 2019b). A configuração do Sistema Ponte Velha em 11 sub-bacias foi utilizada na simulação hidrológica para obtenção dos hidrogramas dos eventos. A área de interesse para o monitoramento e previsão dos eventos de inundação é a região urbana de Lages, com contribuição das sub-bacias urbanas dos rios Carahá e Ponte Grande. Em razão disso, a área de simulação hidrodinâmica é menor para representar apenas as áreas que críticas de inundação.

A planície topográfica de inundação é um dos elementos da paisagem hidrológica e delimita o trecho crítico a inundações. As principais áreas inundáveis do perímetro urbano de Lages, próximas aos rios urbanos Carahá e Ponte Grande, fazem parte da planície topográfica de inundação. Nela estão inseridos 34 bairros do perímetro urbano de Lages, sendo que 4.489 lotes estão totalmente dentro ou são interceptados por essa estrutura da paisagem hidrológica (NETO, 2019c).

Figura 4-Mapa de localização da área de estudo.



Fonte: Elaborado pela autora (2020).

O clima na região é do tipo temperado (Cfb), sem estação seca definida e com verão fresco (ALVARES et al., 2014). A temperatura média anual para o município de Lages é de 15,7°C, com máximas registradas para os meses de janeiro e fevereiro e mínimos em junho (SCHIER et al., 2019). Com base na estação meteorológica Lages (código 2750031), monitorada pela EPAGRI-CIRAM, o regime pluviométrico apresenta-se acima dos 100 mm para todos os meses do ano, as precipitações médias mensais máximas são encontradas nos meses de setembro, outubro e janeiro, e mínimas no período de abril, maio e junho. A precipitação média anual é de 1.540,3 mm (PADILHA, 2017).

A cidade de Lages está sob a unidade geomorfológica Planalto de Lages. Esta unidade caracteriza-se por um relevo de dissecação homogênea em forma de colina, esta homogeneidade só é quebrada pela presença de alguns morros e em alguns trechos, sua limitação é feita por escarpas (EMBRAPA, 2004). Os solos predominantes na região correspondem ao cambissolo e nitossolo (EMBRAPA, 2004), o primeiro encontrado nas proximidades dos talwegues, variando em profundidade e o segundo, típico de encostas, são solos rasos (NETO; CORDEIRO, 2015).

4.2 EVENTOS SELECIONADOS

Para o desenvolvimento desta pesquisa foram selecionados eventos hidrológicos extremos que provocaram inundações em Lages. Os eventos dos anos de 2005, 2011 e 2017 foram escolhidos, pois causaram inundações significativas na planície urbana. Além disso, devido à carência de uma rede de monitoramento hidrológico consolidada na região, esses são eventos que foram registrados oficialmente pelas estações de monitoramento hidrológico, sendo utilizados como base também em outros estudos. As inundações extremas que ocorrem na cidade têm como principal responsável os volumes do rio Caveiras e estão associadas a chuvas máximas com durações de 1 a 5 dias (LIZ, 2018; NETO, 2019b) (Tabela 1).

Tabela 1- Sumário das probabilidades (P) e tempos de retornos (TR) das chuvas máximas anuais de 1 dia e acumuladas de 2 a 5 dias para a cidade de Lages (SC), de acordo com o modelo de Distribuição de Probabilidades de Gumbel para os anos de ocorrência de inundação utilizados nesta pesquisa.

Ano	Chuva de 1 d (mm)	P	TR (anos)
2005	92,1	0,2689	3,7
2011	113,3	0,1006	9,9
2017	152,2	0,0144	69,5
Chuva de 2 d (mm)		P	TR (anos)
2005	183,6	0,0428	23,4
2011	142	0,1634	6,1
2017	177,6	0,0523	19,1
Chuva de 3 d (mm)		P	TR (anos)
2005	185,7	0,091	11
2011	150,8	0,2312	4,3
2017	182,1	0,1005	9,9
Chuva de 4 d (mm)		P	TR (anos)
2005	219	0,0623	16,1
2011	159,8	0,2605	3,8
2017	200	0,1002	10
Chuva de 5 d (mm)		P	TR (anos)
2005	219	0,0934	10,7
2011	159,8	0,3394	2,9
2017	227,8	0,0761	13,1

Fonte: (NETO, 2019b)

*Fonte dos dados observados: Evento de 2005 e 2011 - dados diários da Estação Lages de código 2750005, localizada na Estação Experimental da EPAGRI em Lages (latitude -27°48'30", longitude -50°19'42", altitude 937,00m). Evento de 2017 - dados diários da Estação Coral pertencente ao CEMADEN de código 2750046, localizada no bairro Coral em Lages (latitude -27°48'25" e longitude -50°18'18", altitude 915,00m)

De modo geral, percebe-se que as chuvas de 2017 foram significativamente maiores do que as registradas nos outros dois eventos, especialmente para os acumulados de 2 dias. O evento de 2005 foi o segundo maior evento dos três selecionados, com maiores volumes precipitados do segundo dia em diante. O evento de 2011 é o menor dos três. As chuvas máximas de 2011 não ultrapassaram a menor chuva de 2017 e foram superiores apenas à menor chuva de 2005.

As datas em que ocorreram as inundações foram 18 e 19/05/2005, 08 e 09/08/2011 e 04 e 05/06/2017 (Tabela 2). Na Tabela 2 estão apresentados os períodos de dados utilizados nas simulações hidrológicas e hidrodinâmicas e quais conjuntos foram utilizados no treinamento, validação e verificação dos modelos de previsão.


Tabela 2- Detalhamento dos eventos e períodos utilizados.

	Datas de pico de hidrograma	Período utilizado na simulação		Utilização na RNA
2005	18 e 19/maio	06/05/2005 a 13/06/2005	30 dias	Validação
2011	08 e 09/agosto	01/08/2011 a 09/09/2011	40 dias	Verificação
2017	04 e 05/junho	05/05/2017 a 12/06/2017	39 dias	Treinamento

Fonte: Elaborado pela autora (2021).


As datas de ocorrência dos picos de vazão dos eventos serviram de base para a seleção dos períodos de dados utilizados na simulação. Os períodos foram definidos para que permitissem a observação do comportamento de ascensão e de recessão dos hidrogramas. Contando o número de dias antes e após o evento, para 2005, 2011 e 2017 foram totalizados 30, 40 e 39 dias, respectivamente. O comportamento das vazões observadas nestes três eventos é apresentado nas Figuras 5, 6 e 7.

Figura 5- Hidrograma observado na estação fluviométrica Ponte Velha durante o evento de inundação de 2005.




Fonte: Elaborado pela autora (2021).

Figura 6- Hidrograma observado na estação fluviométrica Ponte Velha durante o evento de inundação de 2011.



Fonte: Elaborado pela autora (2021).

Figura 7- Hidrograma observado na estação fluviométrica Caveiras Montante 1 durante o evento de inundação de 2017.

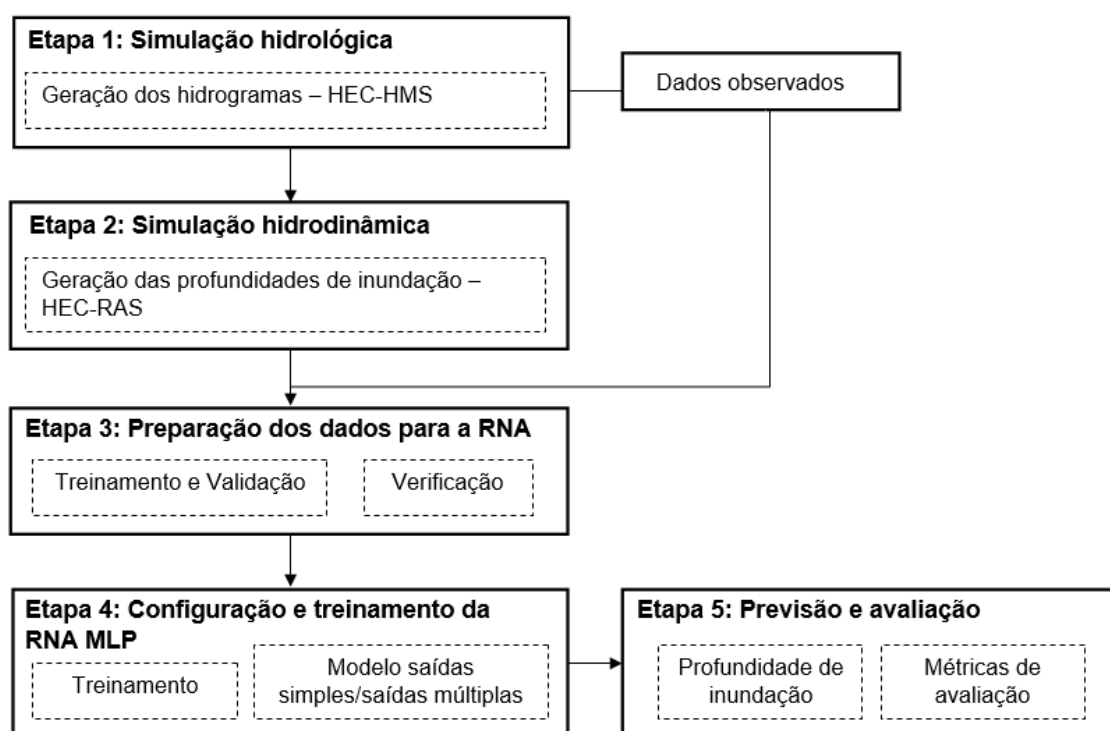


Fonte: Elaborado pela autora (2021).

4.3 DELINEAMENTO DA PESQUISA

O estudo foi desenvolvido em cinco etapas, detalhadas na Figura 8: (1) obtenção dos hidrogramas dos eventos extremos ocorridos em Lages nos anos de 2005, 2011 e 2017 por meio da simulação hidrológica; (2) realização de simulação hidrodinâmica para obtenção das profundidades da água – nessa etapa também realizou-se a análise espacial das inundações para definição dos locais de monitoramento; (3-4) desenvolvimento do modelo de previsão da profundidade de água em diferentes limiares de tempo utilizando RNAs do tipo MLP; (5) avaliação do desempenho dos modelos de previsão.

Figura 8 – Fluxograma do delineamento da pesquisa.



Fonte: Elaborado pela autora (2021).

Para a determinação dos hidrogramas, realizou-se a simulação hidrológica dos eventos de 2005, 2011 e 2017 no HEC-HMS 4.6. O modelo hidrológico conceitual do Sistema Ponte Velha desenvolvido no âmbito do projeto Hidro-Lages foi disponibilizado para realização da simulação hidrológica desta pesquisa. O modelo conceitual está calibrado com o evento de 2005 e foi utilizado para simulação dos eventos de 2011 e 2017. Os dados inseridos para simulação hidrológica correspondem à precipitação, evapotranspiração e vazão observados. Os hidrogramas resultantes da simulação dos eventos foram utilizados como dados de entrada no modelo hidrodinâmico.

As profundidades de inundação foram produzidas por meio da simulação hidrodinâmica no HEC-RAS 5.0.6. O modelo foi calibrado com o evento de 2005 e

utilizado para simulação dos eventos de 2011 e 2017. A simulação hidrodinâmica e a geração dos mapas de inundação tiveram como foco apenas a parte da planície topográfica de inundação urbana de Lages, que abrange os rios Carahá, Ponte Grande e parte do rio Caveiras. O modelo digital de terreno (MDT) utilizado para a modelagem possui resolução espacial vertical de 30 cm.

O modelo de previsão foi desenvolvido com a aplicação da técnica de redes neurais artificiais no Matlab, tendo como entrada básica dados de precipitação de duas estações pluviométricas representativas da região, dados de vazão de uma estação fluviométrica localizada a jusante da área de interesse, as vazões geradas na simulação hidrológica (utilizadas também como entradas do modelo hidrodinâmico) e os dados de profundidade da água obtidos da simulação hidrodinâmica. Foram estruturados modelos de RNA para antecedências de 3, 6, 8, 12, 14, 18 e 20 horas. Buscou-se avaliar a aplicação de modelos de RNA com saída simples – previsão da profundidade da água em um local de monitoramento – e modelos de RNA com saídas múltiplas – previsão da profundidade da água em dois ou três locais simultâneos.

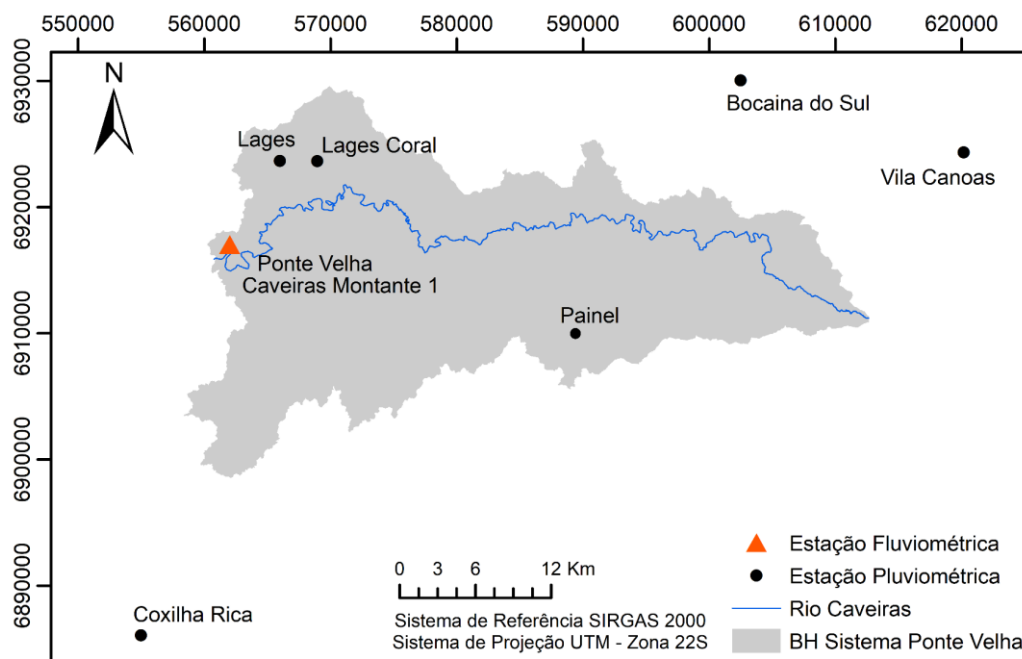
O contexto desta pesquisa foi um sistema urbano com ausência de dados de níveis fluviais observados. A aplicação da técnica de RNAs utilizou a profundidade da água estimada com o uso de simulação hidrodinâmica como indicador do estado do sistema em pontos específicos da planície inundável de Lages. Dessa forma, os resultados do modelo hidrodinâmico são considerados como a representação da realidade, e espera-se que a RNA seja capaz de reproduzir os resultados produzidos pelo HEC-RAS. A previsão de inundação, para ser útil, deve contar com capacidade de aplicação rápida, mesmo que esta envolva o uso de muitos modelos. A metodologia, formulada para o uso em bacias hidrográficas que carecem de dados de monitoramento nos locais de previsão, pressupõe que as RNAs do tipo Multilayer Perceptron possam, uma vez treinadas a partir de dados simulados pelo HEC-RAS, atender essas situações.

4.4 DADOS OBSERVADOS UTILIZADOS

Os dados pluviométricos e fluviométricos foram obtidos no portal eletrônico da Agência Nacional de Águas e Saneamento (ANA) – Hidroweb. Para a simulação dos eventos hidrológicos extremos de 2005 e 2011 no HEC-HMS, utilizou-se as estações pluviométricas: Bocaina do Sul, Vila Canoas, Coxilha Rica, Painel e Lages (Figura 9). Para o evento de 2017, as mesmas estações pluviométricas foram utilizadas, com exceção da estação Lages, que não disponibiliza mais seus dados desde o ano de 2014. Dessa

forma, utilizou-se dados da estação Lages Coral, que está sob responsabilidade do Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN) e corresponde à mesma área de captação da estação Lages, ambas localizadas na área urbana do município.

Figura 9 - Distribuição espacial das estações utilizadas.




Fonte: Elaborado pela autora (2021).

Os dados de vazão utilizados para simulação hidrológica dos eventos de 2005 e 2011 são originários da estação fluviométrica Ponte Velha. Para o evento de 2017 foram utilizados dados fluviométricos da estação Caveiras Montante 1. A estimativa da evapotranspiração foi realizada a partir do método de Penman-Monteith (FAO), a partir de dados diários originários da estação meteorológica de Lages (EPAGRI-CIRAM), localizada sob as coordenadas 27°48'55'' de latitude sul e 50°19'46'' de longitude oeste, a 937m de altitude. Todos os dados utilizados no modelo HEC-HMS são diários e mesmo aqueles provenientes de estações automáticas que são subdiários, foram acumulados ou tiveram sua média obtida. Um diagrama foi confeccionado para sintetizar informações sobre os dados utilizados para simulação hidrológica (Figura 10). Dados mais específicos sobre as estações são apresentados na Tabela 2.

Utilizou-se o método de Thiessen para espacialização das chuvas ponderadas para as áreas de contribuição de cada uma das sub-bacias do sistema (Apêndice 2). Em seguida os dados precipitação, vazão e evapotranspiração foram utilizados no HEC-HMS para obtenção dos hidrogramas dos eventos selecionados.

Figura 10- Diagrama sintetizando as informações sobre as estações utilizadas na simulação hidrológica e locais de monitoramento.



Fonte: Elaborado pela autora (2021).

Tabela 3 - Informações das estações utilizadas.

Estação	Código	Tipo	Coordenadas (Graus)	
			Lat.	Long.
Bocaina do Sul	2749035	p	-24° 44' 39"	-49° 56' 39"
Lages	2750005	p	-27° 48' 30"	-50° 19' 42"
Coxilha Rica	2850004	p	-28° 09' 28"	-50° 26' 27"
Painei	2750007	p	-27° 55' 17"	-50° 05' 55"
Vila Canoas	2749031	p	-27° 48' 09"	-49° 46' 41"
Lages Coral	2750046	p	-27° 48' 25,20"	-50° 18' 18"
PCH Ponte Velha	71620500	f	-27° 52' 49,08"	-50° 22' 57"
PCH Caveiras Montante 1	71620450	f	-27° 52' 19,92"	-50° 22' 03"

Fonte: Elaborado pela autora (2021).

*Tipo: p = pluviométrica; f = fluviométrica.

4.5 SIMULAÇÃO HIDROLÓGICA

Para obtenção dos dados de vazão dos eventos hidrológicos em locais que não possuem estações de monitoramento e que permitam verificar os volumes que adentram a área urbana, realizou-se simulação hidrológica no HEC-HMS 4.6. A modelagem no HEC-HMS é dividida basicamente em três módulos: módulo de gerenciamento de bacia (*Basin model*), módulo de gerenciamento meteorológico (*Meteorological model + Time series data*) e módulo de especificações de controle (*Control specifications*).

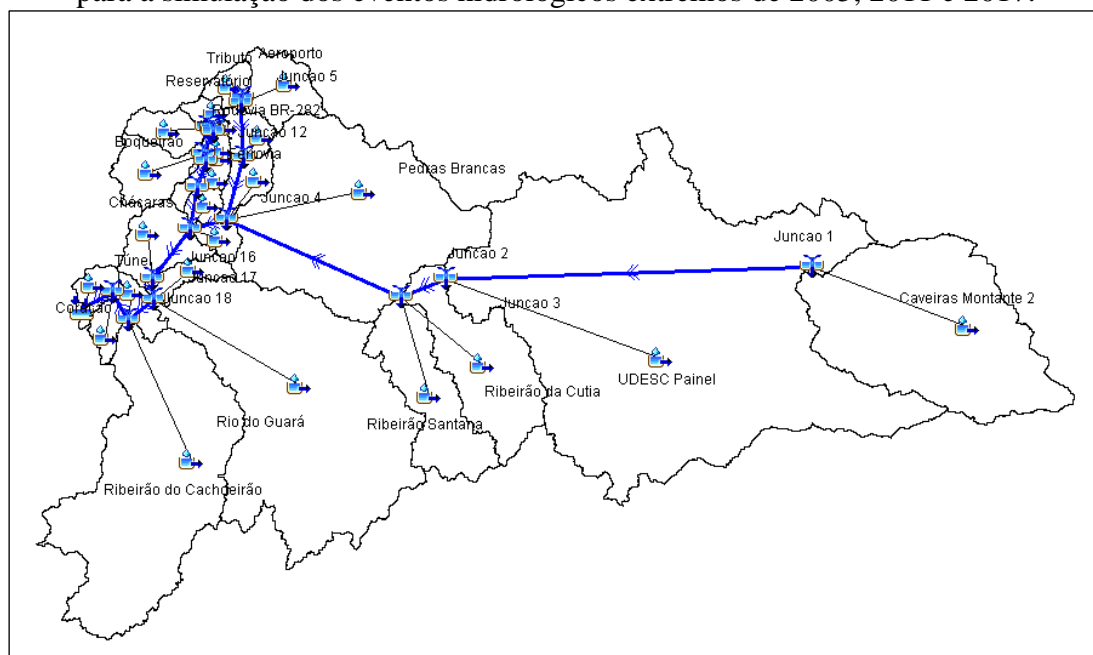
O módulo de gerenciamento de bacia é construído durante o pré-processamento dos dados geográficos e representa o modelo conceitual das simulações. Nele são

definidas as sub-bacias, as junções e as ligações efetuadas por trechos de canais. O exutório é entendido como o “ponto final” do escoamento e local onde a vazão observada pode ser comparada à que foi produzida nas simulações. O modelo conceitual produzido no âmbito do projeto Hidro-Lages (NETO, 2019a), que inclui o módulo de gerenciamento de bacia (*Basin model*) e os respectivos parâmetros de cálculo calibrados para o evento de 2005 foi disponibilizado para as análises desta pesquisa e utilizado para geração dos hidrogramas dos eventos de 2005, 2011 e 2017. A seguir são descritos detalhes a respeito do modelo conceitual e dos parâmetros de cálculo utilizados:

O modelo conceitual da modelagem hidrológica foi elaborado a partir da divisão da bacia hidrográfica do Sistema Ponte Velha em unidades hidrológicas pelo método da homogeneidade. Essa é uma estratégia que permite analisar o todo através da compreensão de suas partes. Para a análise de eventos de inundação, essa metodologia permite deduzir quais são os módulos que possuem maior ou menor influência, e quais características podem ser as responsáveis por alguns fenômenos.

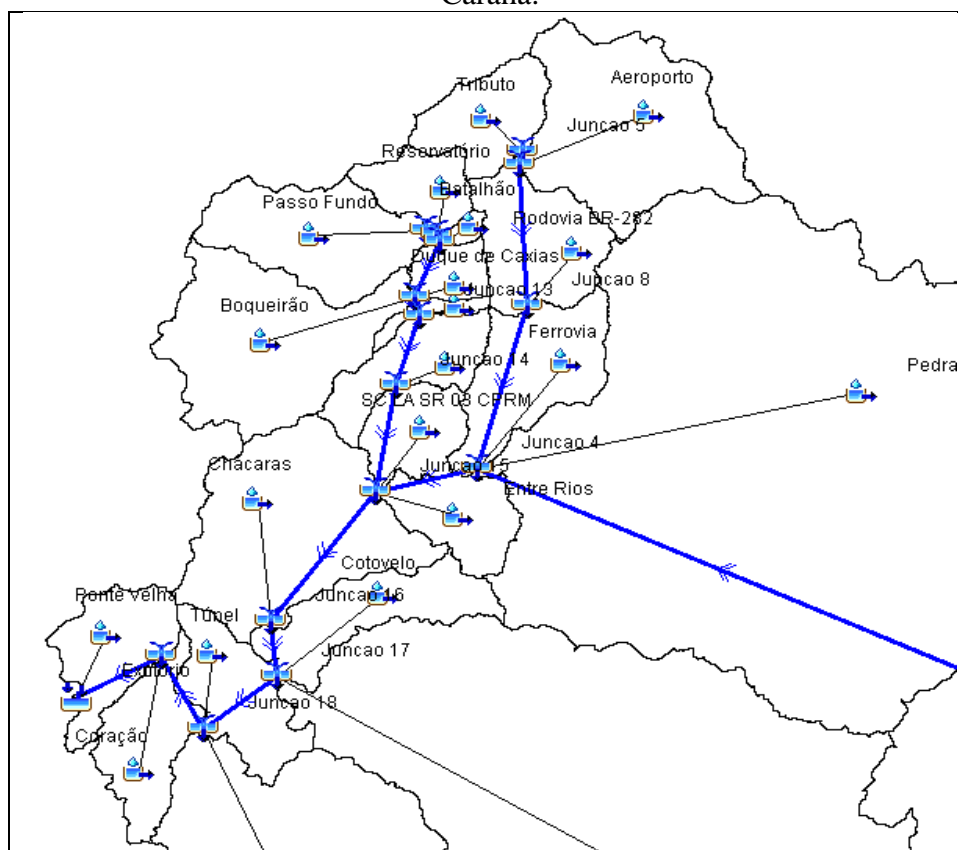
As bacias rurais e urbanas foram separadas em termos de uso e ocupação da terra predominantes, declividades e locais de confluências de rios de grande porte. Além disso, as junções foram estrategicamente alocadas em pontos de referência. Na figura 11 estão apresentados os elementos que identificam as sub-bacias do estudo; os canais que representam a conexão entre estas bacias hidrográficas; e as junções, que fazem o recebimento dos fluxos de montante provenientes de ambas as contribuições e seu aporte a jusante, com detalhe para os elementos nas sub-bacias urbanas do rio Ponte Grande e Carahá (Figura 12).

Figura 11- Elementos que compõem o modelo conceitual de bacia hidrográfica utilizado para a simulação dos eventos hidrológicos extremos de 2005, 2011 e 2017.



Fonte: Projeto Hidro-Lages (NETO, 2019a).

Figura 12- Detalhe do modelo conceitual nas bacias urbanas dos rios Ponte Grande e Carahá.



Fonte: Projeto Hidro-Lages (NETO, 2019a)

Utilizou-se para o cálculo de “perdas” (ou cálculo da chuva efetiva do evento), o método do Curve Number-SCS-CN. Este método de cálculo requer como parâmetros de

entrada os valores de CN, abstração inicial e impermeabilidade da bacia. O método de cálculo para a transformação chuva-vazão utilizado foi o Hidrograma Unitário (HU) do SCS. Este método foi utilizado devido à escolha do método do SCS para o cálculo da chuva efetiva, e pelo fato de que este tipo de hidrograma sintético é muito utilizado em situações onde as bacias hidrográficas não possuem monitoramento (PADILHA, 2017). Os valores de CN adotados para calibração do modelo hidrológico são provenientes de adaptações de valores disponíveis na literatura (COLLISCHONN; DORNELLES, 2013; SARTORI; NETO; GENOVEZ, 2005; TUCCI, 2009).

Para cálculo do escoamento base – importante na calibração de eventos de curta duração - foi utilizado o método de recessão exponencial, que possui três parâmetros estimados pelo modelo: a vazão inicial, a constante de recessão (k) e o ponto limiar de recessão.

O último conjunto de parâmetros do módulo de gerenciamento de bacia descreve as características médias dos canais, que condicionam a propagação da onda de inundação ao longo do tempo. Dentre as equações disponíveis, utilizou-se o método de Muskingum-Cunge (PADILHA, 2017). Este método de cálculo utiliza uma solução aproximada das equações da Onda Difusiva, que considera de forma simplificada os parâmetros das equações da continuidade e do momento. Por tratar-se de um modelo hidrológico, as equações baseiam-se em diferenças finitas, que levam em conta os parâmetros que descrevem as seções transversais dos canais e não consideram o comportamento das equações de Saint-Venant (USACE, 2016b).

O HEC-HMS exige a determinação do comprimento médio do canal, a declividade média, o coeficiente de rugosidade de Manning, a largura do canal, a geometria da seção transversal e a declividade dos taludes laterais. Esses parâmetros foram estimados por meio de fotografias aéreas, verificação *in loco* e referências bibliográficas (PADILHA, 2017; USACE, 2016b).

De maneira geral, a utilização de parâmetros médios, oriundos de eventos diversos, pode ser considerada correta, devido ao fato de que o próprio HEC-HMS é um modelo concentrado que realiza os cálculos a partir de parâmetros médios para quase todos os dados de entrada dos modelos. Apenas quando o analista opta por utilizar dados de entrada em grade, é que o modelo consegue distribuir espacialmente alguns atributos em cada sub-bacia. Fora desta perspectiva, sempre se utilizam médias e valores aproximados (LIZ, 2018). Os valores dos parâmetros de calibração do modelo hidrológico utilizados nesta pesquisa estão disponíveis no Apêndice C.

O módulo de gerenciamento meteorológico (*Meteorologic model + Time series data*) e de especificações de controle (*Control specifications*) estão associados em termos de funcionamento e foram ajustados conforme os dados hidrológicos de cada evento. No módulo meteorológico foram indicadas as estações pluviométricas, fluviométrica e meteorológica associadas a cada uma das unidades hidrológicas e inseridas as séries de precipitação, vazão e evapotranspiração potencial observadas para cada evento. Diante das ponderações efetuadas pelo método de Thiessen foram criadas estações meteorológicas “virtuais” com as precipitações ponderadas especificamente para cada UH existente.

4.6 SIMULAÇÃO HIDRODINÂMICA

A simulação hidrodinâmica bidimensional foi realizada no HEC-RAS 5.0.6. Esta etapa teve como objetivos centrais: elaborar mapas de inundação para os eventos hidrológicos extremos ocorridos em 2005, 2011 e 2017 na cidade de Lages; definir os locais de monitoramento com base nas características do terreno e no espalhamento da água durante os eventos de inundação; e obter os dados de profundidade da água nos diferentes locais de monitoramento durante os eventos simulados. A elaboração dos mapas de inundação para identificação das áreas inundáveis e obtenção dos dados de profundidade da água é imprescindível, nesse caso, para o desenvolvimento do modelo de previsão com RNAs.

A área no entorno dos rios Carahá, Ponte Grande e Caveiras foi escolhida para simulação hidrodinâmica devido à variedade de características físicas ali presentes, incluindo o canal dos rios, curvas de rios e uma extensa planície de inundação - ocupada em sua grande parte pela população. A construção da geometria para delimitação da área de simulação 2D foi realizada de forma a contornar a planície topográfica de inundações da região (Figura 13). Para calibração do modelo, foram testadas geometrias com diferentes tamanhos de células da malha, que variaram entre 5 m, 10 m e 30 m. O valor do coeficiente de Manning foi mantido em $0,08 \text{ s.m}^{-1/3}$ para todas as malhas, sendo definido com base em considerações da literatura e de estudos hidrodinâmicos realizados na área de interesse desta pesquisa (HICKS; PEACOCK, 2005; LIZ, 2018; NETO, 2019c).

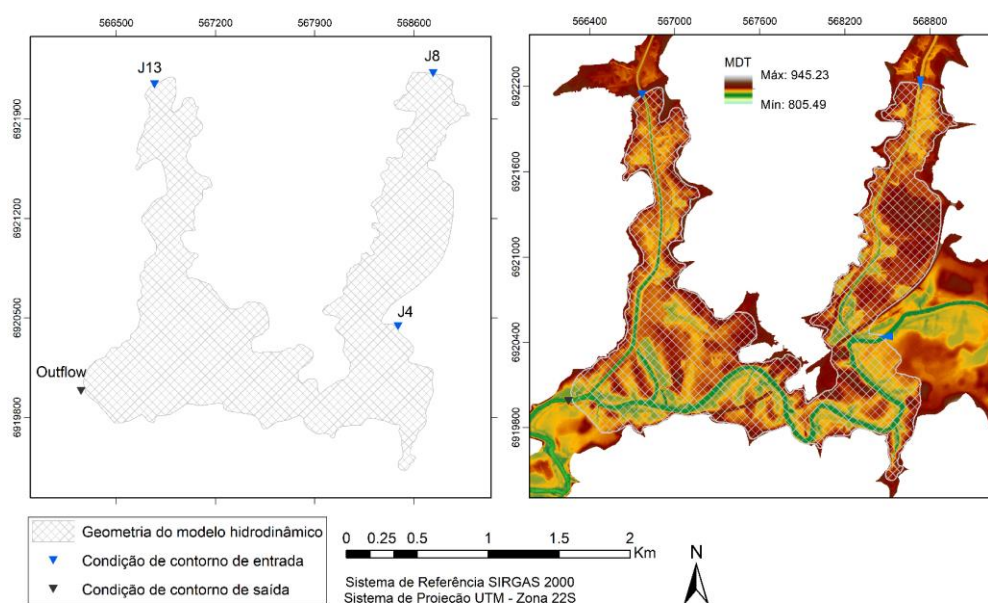
As características físicas da área de estudo estão representadas em um modelo digital de terreno (MDT) de alta resolução. Para as simulações, utilizou-se o MDT da planície topográfica de inundação de resolução vertical de 30 cm, produzido a partir de

aerofotogrametria a laser com sensor LiDAR (*Light Detection and Ranging*) e posterior técnica de ortorretificação digital (NETO, 2019d). A utilização de um MDT de alta resolução é um instrumento importante para confiabilidade dos resultados, espera-se que a resolução de 30 cm forneça detalhamento suficiente da superfície do terreno para que os mapas de inundação simulados representem com precisão as profundidades de água atingidas durante os eventos.

O HEC-RAS demanda a entrada de condições de contorno, denominadas de *Boundary Conditions* (BC), em um valor mínimo de duas. A primeira delas fornece a vazão de entrada, que pode ser um hidrograma, um cotograma ou uma curva-chave. A segunda condição de contorno retira a água do modelo, providenciando o esvaziamento da planície inundada. Foram utilizadas três condições de contorno de entrada de água no modelo, representativas das vazões que contribuem para a área de simulação. A primeira corresponde à vazão que escoar pelo rio Caveiras (J4); a segunda é a entrada referente ao rio Ponte Grande (J8); e a terceira, referente à vazão do rio Carahá (J13) (Figura 13). Os hidrogramas inseridos como condições de contorno no HEC-RAS foram obtidos por simulação hidrológica realizada no HEC-HMS.

Geralmente, adota-se a profundidade normal como condição de contorno de saída do modelo (*Outflow*), considerando a relação existente entre a declividade do canal e a rugosidade relacionada ao trecho final da malha. Nesta pesquisa, adotou-se um valor padrão de 0,001 m.m⁻¹ para a profundidade normal durante as simulações. Este valor é recomendado pelo manual do HEC-RAS, e significa que a cada 1 m de deslocamento horizontal há diminuição de 0,001 m na cota do terreno (BRUNNER; CEIWR-HEC, 2016). Essa proporção indica um terreno quase plano no trecho de jusante do canal, sem variações bruscas de profundidade da altura da lâmina d'água.

Figura 13-Geometria da simulação hidrodinâmica com destaque para as condições de contorno do modelo.

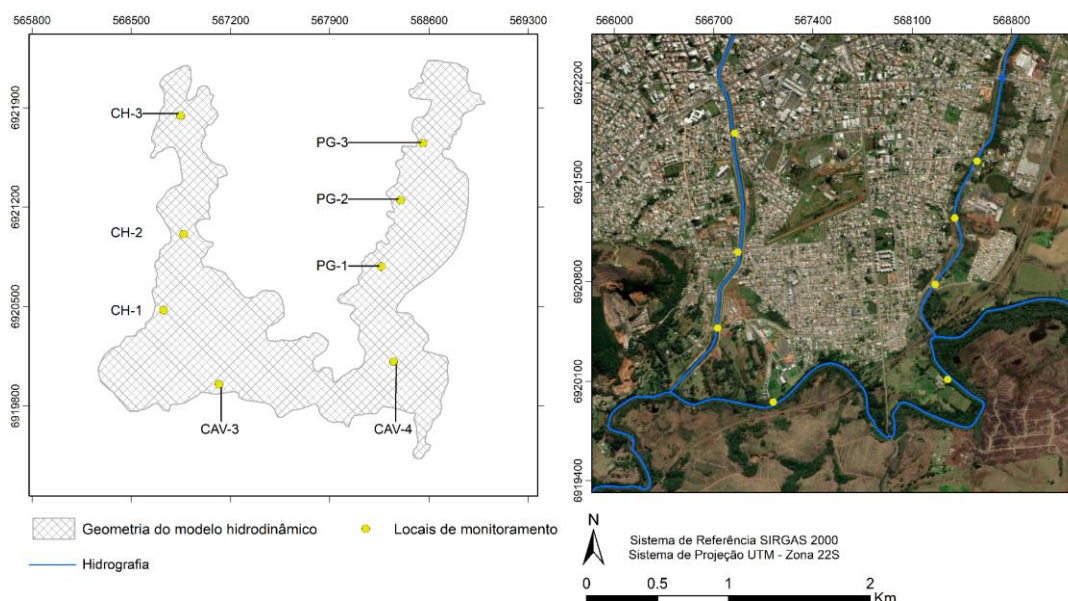


Fonte: Elaborado pela autora (2021).

Para executar a simulação hidrodinâmica é necessário estabelecer o intervalo de tempo da simulação e também os intervalos de tempo para visualização das animações que são apresentadas no RAS Mapper. Os intervalos de tempo da simulação foram alterados para que satisfizesse a condição Courant-Friedrichs-Lewy (CFL) (USACE, 2016a). O intervalo de tempo das animações foi fixado em uma hora, essas fornecem a visualização do estado do sistema em determinado momento e servem para avaliação visual dos resultados.

Os mapas de inundação produzidos permitem analisar o espalhamento da água, a profundidade e a velocidade da onda de cheia na área de interesse. A escolha dos locais de monitoramento foi realizada após a análise visual dos mapas de inundação simulados para os eventos de 2005, 2011 e 2017, e visita *in loco* nas regiões atingidas pela inundação simulada para verificar a situação de campo, como a sua proximidade do canal principal e o histórico de ocorrência de inundação com a população local. Foram determinados oito locais de monitoramento das profundidades de inundação, três locais ao longo do rio Carahá (CH-1, CH-2 e CH-3); três locais no rio Ponte Grande (PG-1, PG-2 e PG-3); e dois locais no rio Caveiras (CAV-3 e CAV-4) (Figura 14).

Figura 14- Espacialização dos locais de monitoramento.



Fonte: Elaborado pela autora (2021).

Os locais de monitoramento foram estrategicamente alocados de forma a permitir o monitoramento do nível dos rios ao longo da planície topográfica de inundações. A escolha e definição dos locais de monitoramento ocorreu após saída a campo, realizada com acompanhamento da equipe da Defesa Civil, para análise da área de estudo desta pesquisa. As áreas próximas aos rios urbanos, frequentemente atingidas por inundações, foram analisadas e considerou-se como critérios para a escolha dos locais de monitoramento: a proximidade das residências para com a margem do rio, o relevo do local e a facilidade de acesso. Dessa forma, os locais definidos nesta pesquisa poderão servir como referência futura para a instalação de réguas linimétricas na planície urbana pela Defesa Civil.

4.7 FORMULAÇÃO E ASPECTOS DA APLICAÇÃO DOS MODELOS DE PREVISÃO

Os modelos de RNA foram desenvolvidos no Matlab para previsão em oito locais de monitoramento da área de interesse: CAV-4, CAV-3, CH-1, CH-2, CH-3, PG-1, PG-2 e PG-3, conforme apresentado na Figura 14. Os modelos possuem entradas com dados de precipitação diária das estações Painel e Lages, e de vazão horária da estação Ponte Velha – em referência aos eventos de 2005 e 2011. Para o evento de 2017, as informações de precipitação são originárias das estações Painel e Lages Coral, e de vazão da estação Caveiras Montante 1. Além disso, também foram utilizadas as vazões horárias correspondentes às condições de contorno (J4, J8 e J13) do modelo hidrodinâmico e os

dados horários de profundidade da água (LM) como informações de entrada da rede. A saída do modelo é a profundidade da água que será atingida no local de monitoramento, para a qual se deseja uma previsão para alcances de 3, 6, 8, 12, 14, 18, 20 horas.

Inicialmente, foram inspecionadas quais as defasagens temporais dos dados que resultaram melhores desempenhos dos modelos para previsões da profundidade da água, considerando os alcances desejados. Para cada variável de entrada, as defasagens avaliadas são apresentadas na Tabela 4.

Tabela 4 - Defasagens temporais avaliadas para cada variável de entrada do modelo de previsão.

Variável de entrada	Defasagem avaliada
P1, P2	t-3; t-2; t-1; t
QJ4, QJ8, QJ13, QPV	t-6; t-4; t-3; t-2; t-1; t
LM	t-6; t-4; t-3; t-2; t-1; t

Fonte: Elaborado pela autora (2021).

Para análise das RNAs de saídas simples, os modelos foram estruturados e treinados para responderem a profundidade da água em um local de monitoramento, ou seja, cada local tem seu modelo respectivo (Tabela 5). Para a análise dos modelos de RNA com saídas múltiplas, os modelos rna_CAV4, rna_CH1 e rna_PG1 foram modificados para que realizassem a previsão da profundidade da água em locais de monitoramento relacionados de forma simultânea e renomeados rna_CAV, rna_CH e rna_PG.

Tabela 5-Apresentação dos modelos de RNAs de saídas simples ou saídas múltiplas utilizados para previsão da profundidade de água nos locais de monitoramento.

RNA de Saídas Simples		RNA de Saídas Múltiplas	
Local de monitoramento	RNA	Local de monitoramento	RNA
CAV-4	rna_CAV4	CAV-4	rna_CAV
CAV-3	rna_CAV3	CAV-3	
CH-1	rna_CH1	CH-1	
CH-2	rna_CH2	CH-2	rna_CH
CH-3	rna_CH3	CH-3	
PG-1	rna_PG1	PG-1	rna_PG
PG-2	rna_PG2	PG-2	
PG-3	rna_PG3	PG-3	

Fonte: Elaborado pela autora (2021).

A primeira etapa de desenvolvimento dos modelos de RNA consiste no pré-processamento dos dados com as defasagens temporais. Em seguida, os dados são sincronizados – todos sofrem translação temporal, considerando defasagens e alcances, para compor conjuntos ordenados de entrada-saída, chamados de registros – representam o estado atual da bacia (entrada) e a profundidade da água futura (saída).

Na segunda etapa é realizada a identificação dos parâmetros de escalonamento das variáveis de entrada e saída para que fiquem com valores dentro do intervalo de sensibilidade das funções de ativação utilizadas – nesta pesquisa foi utilizada a função de ativação sigmoide unipolar. Salienta-se que esse é um passo importante, no caso das entradas, para evitar que o algoritmo de retropropagação dê vantagem às grandezas de maior valor, e, no caso das saídas, para a sua adequação à imagem da função de ativação utilizada no neurônio de saída.

Na terceira etapa, os registros são separados nos conjuntos de treinamento, validação e verificação. A repartição dos registros foi determinada por evento. O evento do ano de 2017 foi selecionado para treinamento, pois apresenta valores mais extremos de vazão e profundidade da água atingida, os quais devem estar presentes no conjunto de treinamento. Os dados do evento de 2005 foram utilizados como conjunto de validação e os dados do evento de 2011 serviram como conjunto de verificação.

Na quarta etapa, realiza-se a pesquisa de complexidade interna para identificar a RNA com menor número de neurônios internos que apresente desempenho de validação semelhante ao de uma RNA superdimensionada, não sobreajustada. Já que métricas de avaliação tem comportamento de variável aleatória, apresentando uma variabilidade, essa etapa é realizada também visualmente por análise gráfica. Isso pode facilitar no discernimento, evitando equívocos de procedimentos automáticos.

Foram realizados treinamentos com cinco repetições, as quais permitem obter mais robustez do resultado, pois evitam a escolha de pesos sinápticos advindos de um mau começo derivados do sorteio dos pesos sinápticos iniciais. Os modelos resultantes das repetições podem apresentar diferentes pesos sinápticos e ainda assim possuir capacidade de generalização. Quanto maior o número de repetições, maior a confiabilidade do modelo e maior é o investimento em tempo de processamento, pois a operação mais dispendiosa computacionalmente é justamente a propagação do sinal de entrada na rede e a retropropagação do erro durante o treinamento (multiplicação de matrizes).

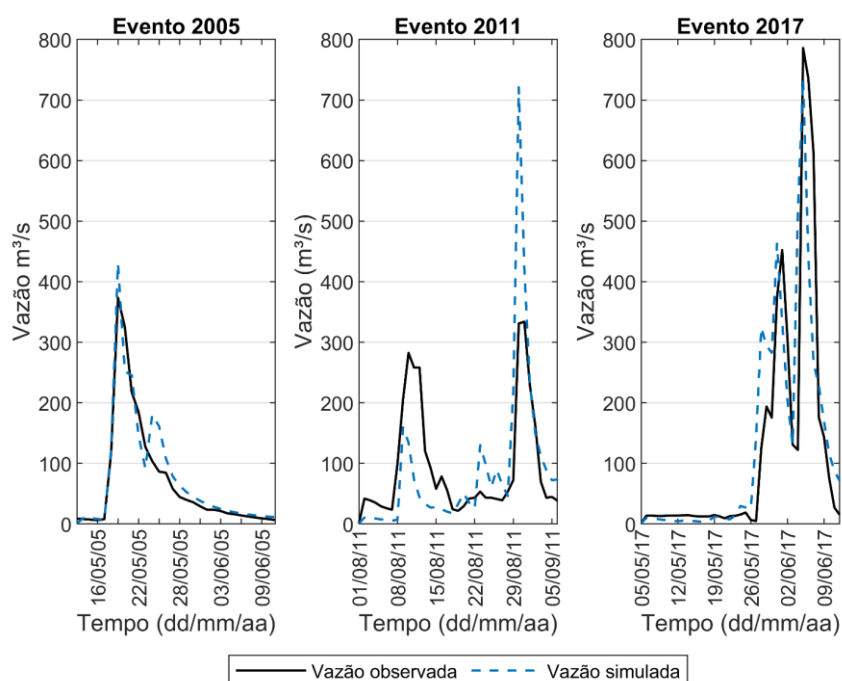
A última etapa consiste na avaliação do desempenho dos modelos. A avaliação é realizada a partir das estatísticas obtidas na etapa de verificação, ou seja, com relação ao conjunto de dados que não participou do desenvolvimento ou treinamento dos modelos. No caso desta pesquisa, o período de dados utilizado para a etapa de verificação é referente ao evento extremo ocorrido em 2011. Utilizou-se as métricas de avaliação descritas no item 3.8: NS, MAE, E90 e PBIAS. De forma complementar, realizou-se uma análise visual do comportamento dos gráficos de profundidade da água simulados pelo modelo hidrodinâmico (HEC-RAS 2D) e dos resultantes da previsão com as RNAs para uma visão mais detalhada do desempenho.

5 RESULTADOS E DISCUSSÃO

5.1 SIMULAÇÃO HIDROLÓGICA

Os hidrogramas dos eventos de 2005, 2011 e 2017 (Figura 15), utilizados como dados de entrada no modelo hidrodinâmico, foram obtidos por meio de simulação hidrológica no HEC-HMS 4.0.6. A utilização do modelo hidrológico calibrado com o evento de 2005, para a obtenção de uma simulação satisfatória dos eventos de 2011 e 2017, foi realizada considerando que a distribuição espacial da precipitação ocorreu de maneira semelhante nestes eventos (NETO, 2019b; PADILHA, 2017).

Figura 15- Hidrogramas dos eventos de 2005, 2011 e 2017 obtidos por simulação hidrológica no HEC-HMS.



A simulação do evento de 2005 foi a que apresentou melhor desempenho (NS igual a 0,901) porque o modelo hidrológico foi calibrado com as vazões observadas deste evento. As simulações dos eventos de 2011 e 2017 apresentaram desempenho inferior (NS igual a 0,582 e 0,686, respectivamente), pois foram utilizados os mesmos parâmetros de cálculo calibrados de 2005, porém com dados de chuva e evapotranspiração dos respectivos anos.

A simulação do evento de 2011 apresentou subestimação do primeiro pico e superestimação do segundo pico de cheia (Figura 15). Apesar da distribuição espacial da chuva ter sido semelhante para os três eventos, no sentido de que a ocorrência de precipitação abrangeu todas as unidades hidrológicas a montante e que influenciam na

resposta hidrológica observada na área urbana, o volume de chuva registrado para o evento de 2011 foi menor do que o registrado para os eventos de 2005 e 2017 (Apêndice 2).


Além disso, esse resultado pode ser uma consequência da baixa qualidade dos dados de vazão utilizados no modelo, pois a curva-chave da estação de monitoramento fluviométrico Ponte Velha não é confiável para este período, conforme se pode atestar da análise dos dados originais. Outros estudos realizados na região que utilizaram o período do evento hidrológico extremo de 2011 registraram resultados semelhantes e manifestaram a questão da confiabilidade dos dados produzidos pela estação Ponte Velha, sugerindo que os valores de vazões máximas podem ter sido influenciados por efeitos de remanso na estação de monitoramento, devido à presença da barragem do Salto do rio Caveiras a jusante (LIZ, 2018; PADILHA, 2017). Embora os dados de vazão observados possam apresentar tendências derivadas de curvas-chaves não totalmente confiáveis, eles permanecem sendo importantes e valiosos, pois são as únicas fontes disponíveis capazes de indicar as respostas da bacia hidrográfica durante a ocorrência das chuvas extremas neste período.

Outro fator que pode influenciar no desempenho das simulações são os parâmetros CNs obtidos no processo de calibração com o evento de 2005, cujos valores foram calculados pelo modelo por otimização. O CN é um parâmetro que representa o grau de permeabilidade de uma superfície e que, portanto, varia conforme o uso da terra, o grupo hidrológico do solo e a umidade antecedente do solo. O CN é um parâmetro empírico e utilizar um valor médio em uma unidade hidrológica com múltiplas superfícies e condições físicas de solo e umidade, pode contribuir para reduzir o desempenho das simulações. Consequentemente, um conjunto de parâmetros considerado ótimo para a simulação de um evento nem sempre irá possuir significados físicos suficientes para a representação ideal de outro, especialmente se a variabilidade espacial da chuva e sua intensidade não foram adequadamente traduzidas.

Fica evidente, porém, pelos valores obtidos de NS e pela Figura 15, que as simulações no HEC-HMS são razoavelmente boas. O comportamento do hidrograma nas fases de ascensão e recessão foi bem representado pelo modelo para os eventos de 2005 e 2017, principalmente com relação ao tempo necessário para se atingir os valores de pico. Houve aproximação dos valores máximos de vazão previstos e observados para ambos os eventos, embora o modelo preveja em excesso os fluxos em alguns momentos.

As vazões utilizadas como condições de contorno na simulação hidrodinâmica foram extraídas de três junções existentes no modelo hidrológico. As junções, no HEC-HMS, representam pontos de controle e permitem a obtenção de hidrogramas em locais não monitorados. Para a representação dos volumes causadores de inundação no domínio do problema, foram selecionadas junções representativas dos fluxos do rio Caveiras (J4), rio Ponte Grande (J8) e rio Carahá (J13).

Figura 16- Hidrogramas simulados correspondentes às junções de interesse (J4, J8 e J13) para a área de simulação hidrodinâmica (domínio do problema) com relação aos eventos de 2005, 2011 e 2017.



O comportamento dos hidrogramas simulados nas junções, com relação aos tempos de pico identificados nos eventos, é semelhante ao observado nas estações de monitoramento a jusante. A junção J4 representa grandes volumes de água devido à sua maior área de captação (492 km²), sendo significativamente maior que às áreas de captação de J8 (27,14 km²) e J13 (30,19 km²). A J4 contabiliza todo o volume escoado pelo rio Caveiras a montante de Lages, o qual exerce grande influência no comportamento hidrodinâmico dos rios Ponte Grande e Carahá e na ocorrência de inundações na região (LIZ, 2018).

As junções J8 e J13 representam os volumes escoados pelos rios Ponte Grande e Carahá, respectivamente. Estas duas junções apresentaram vazões relativamente pequenas, aproximadamente proporcionais às suas áreas de captações, uma vez que a

chuva é considerada média em toda a área de domínio de suas bacias. Os pequenos volumes de água são recomendados a se considerar para uma representação apropriada da dinâmica das inundações durante todo o evento (BERMÚDEZ; CEA; PUERTAS, 2019). Isso porque as pequenas vazões podem não ser capazes de desencadear inundações sozinhas, mas quando combinadas resultam em impactos extremos (LEONARD *et al.*, 2014). Dessa forma, elas foram utilizadas com a intenção de verificar os fluxos que adentram o domínio do problema, pelos rios afluentes, considerando a contribuição fornecida pelos módulos das sub-bacias urbanas.

5. 2 SIMULAÇÃO HIDRODINÂMICA

5.2.1 Ajuste da configuração da malha de simulação hidrodinâmica

Para a definição de uma geometria apropriada para as simulações bidimensionais no HEC-RAS, buscou-se conciliar um tamanho de célula suficientemente adequado para a representação do terreno adjacente e que oferecesse uma representação satisfatória do espalhamento e do fluxo da água sobre o domínio do problema. Três configurações de malhas foram testadas, com variação no tamanho das células de 30 m, 10 m e 5 m (Tabela 5).

Tabela 6- Malhas testadas para simulação dos eventos de inundação e respectivos parâmetros. Δt = passo de tempo da simulação; ΔX = tamanho da célula da malha.

Malha	ΔX (m)	Detalhamento (m)	Nº células na malha	Δt (s)	Tempo de simulação
1	30	Máximo 10 e mínimo 5	5 194	30	2 h 31 min
2	10	Máximo 10 e mínimo 5	27 988	5	7 h 28 min
3	5	Máximo 10 e mínimo 5	107 327	5	19 h 41 min


Fonte: Elaborado pela autora (2020).

Utilizou-se *breaklines* (linhas de quebra) posicionadas nos eixos longitudinais dos canais para o alinhamento das células e refinamento local (Figura 17). As células de tamanho menor e direcionadas ortogonalmente ao sentido do fluxo da água para os leitos dos rios, fornecem detalhamento à malha e são utilizadas com o intuito de melhorar o escoamento do fluxo.

O tempo computacional de simulação é uma das variáveis mais influenciadas pela mudança de tamanho das células (Tabela 5). A malha mais refinada exigiu 19 horas 41 minutos para a simulação, enquanto o grid com maior tamanho de célula, apenas 2 horas e 31 minutos. O tamanho da célula, a geometria da malha e o refinamento são escolhas do analista do modelo. A utilização de malhas com células maiores possui tendência a

processamento mais rápido; no entanto, malhas com resolução mais alta – e tamanho de célula menor – são sempre as melhores em termos de representação dos detalhes do terreno (LINTOTT, 2017).

Figura 17- Detalhamento nos canais com malhas de 30 m (A), 10 m (B) e 5 m (C).




Fonte: Elaborado pela autora (2021).

A definição do passo de tempo de simulação também é de crucial importância para a obtenção de um modelo numericamente estável e que forneça resultados condizentes com a realidade. Utilizou-se a condição CFL, que relaciona o tamanho das células da malha e o passo de tempo, para definir as condições mais adequadas para a simulação. Após realização dos testes de sensibilidade, a malha 3 apresentou melhor desempenho. Os valores de *Courant Number* – para a condição CFL - permaneceram inferiores a 3 (Figura 18). Observou-se, por análise visual, que o espalhamento da mancha de inundação ocorreu mais próximo do real na simulação da malha 3. Dessa forma, pode-se considerar que informações mais detalhadas sobre o comportamento hidrodinâmico da

água na planície de inundação foram produzidas, o que auxiliou na escolha do local dos pontos de monitoramento.

Vale ressaltar que as simulações 2D no HEC-RAS são realizadas a partir de um esquema de resolução implícito¹, o que permite que a informação do canal inteiro influencie na solução de qualquer outro ponto dentro da malha, ao contrário do que ocorre em modelos que possuem resolução explícita. Assim, pode-se aceitar valores um pouco mais elevados para o *Courant Number* sem prejudicar totalmente a estabilidade do modelo (USACE, 2016a).

Figura 18 -Exemplificação da distribuição do *Courant Number* com a malha de 5 m durante a simulação do evento de 2005.



Fonte: Elaborado pela autora (2021).

¹ Em um procedimento de solução implícita, o cálculo das elevações da superfície da água e das velocidades do fluxo em cada novo passo de tempo são expressos por uma combinação entre os valores conhecidos do passo anterior e os valores desconhecidos das células adjacentes no passo de tempo atual. Como resultado cada célula da malha está ligada às células vizinhas, que ligam todo o domínio do modelo de forma “implícita” (BABISTER; BARTON, 2012).

5.2.2 Análise das manchas de inundação e profundidades da água dos eventos simulados

A simulação hidrodinâmica dos eventos de inundação permitiu a identificação dos tempos de propagação da onda de cheia e a análise das profundidades de água atingidas durante os eventos. A evolução da água durante os eventos simulados com relação aos locais de monitoramento está apresentada nas Figuras 19, 20 e 21. Os períodos temporais representam as etapas de ascensão da onda de cheia, de inundação máxima e de recessão. É possível observar que, para todos os eventos, inicialmente ocorreu o extravasamento da água para as planícies inundáveis dos rios Caveiras e Ponte Grande. Em seguida, a água começou a atingir também a planície do rio Carahá e, então alcançou as profundidades máximas de inundação.

Figura 19-Representação da evolução da inundação com relação aos locais de monitoramento no evento de 2005.

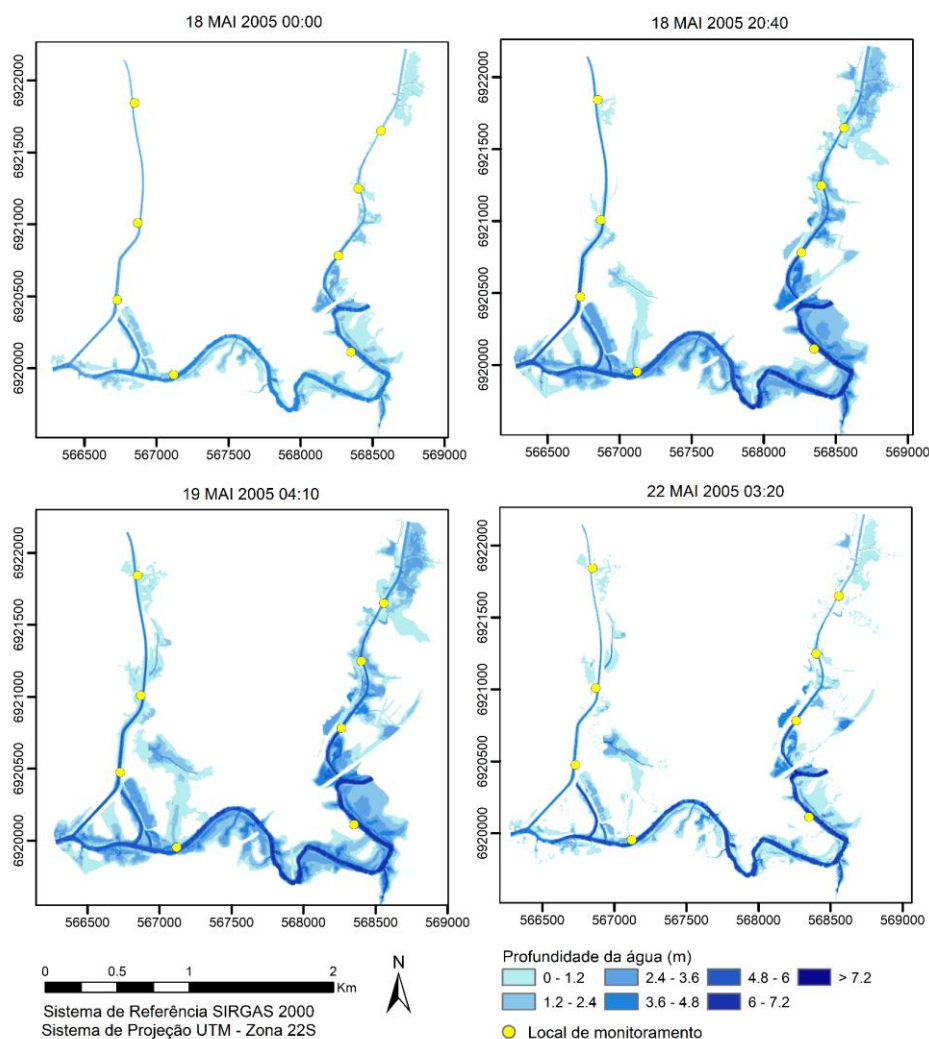


Figura 20- Representação da evolução da inundação com relação aos locais de monitoramento no evento de 2011.

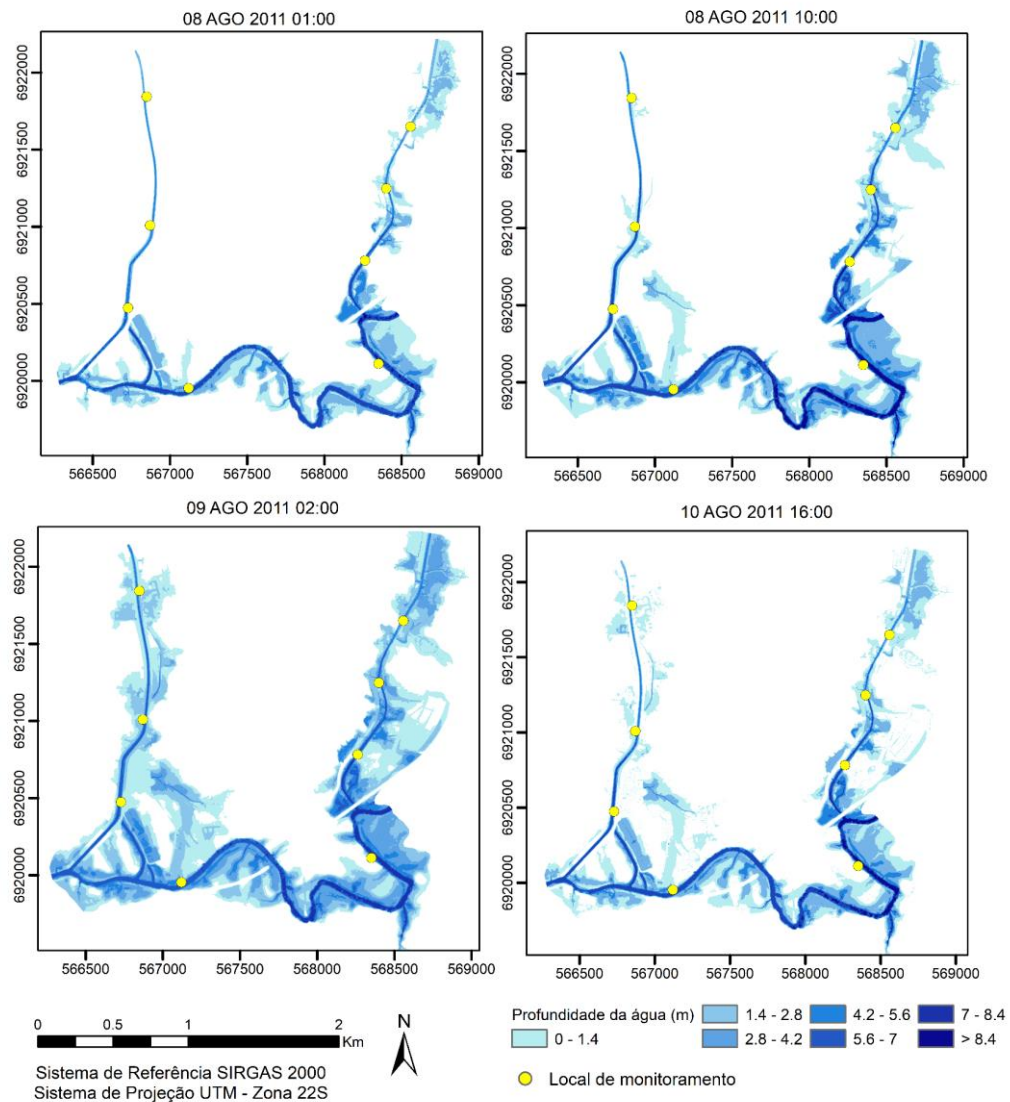
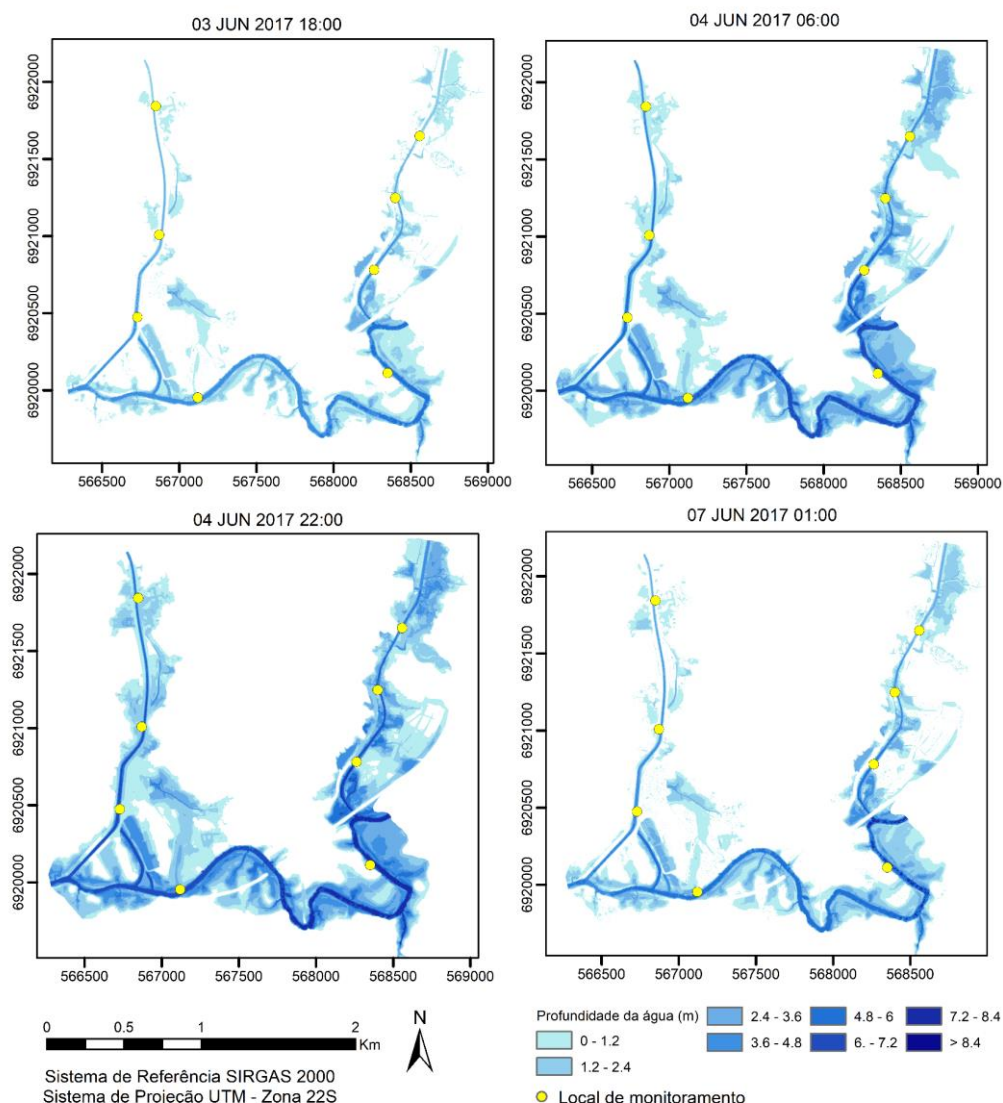


Figura 21 - Representação da evolução da inundação com relação aos locais de monitoramento no evento de 2017.



Os resultados das simulações indicaram que após a elevação do nível do rio Caveiras ocorre o início da contribuição desses volumes para o rio Ponte Grande, que apresenta o extravasamento da água para além de sua calha natural em torno de 14-16 horas após o início do evento. Entre 8 e 12 horas, aproximadamente, separam o início da inundação no rio Ponte Grande para o início no rio Carahá. Essa informação permite deduzir que os locais de monitoramento no rio Caveiras (CAV-4 e CAV-3) e no rio Ponte Grande (PG-1, PG-2, PG-3) podem ser utilizados para o monitoramento das profundidades que serão atingidas, em seguida, na planície do rio Carahá. Pode ser possível, a partir da análise da evolução da água ao longo da planície urbana, estabelecer uma relação entre os locais de monitoramento de forma a otimizar a previsão das profundidades de inundação considerando sua distribuição espacial e temporal e,

consequentemente, direcionar estrategicamente as ações de preparação e resposta aos eventos.

O tempo decorrido entre o início da ascensão do nível d'água e a máxima profundidade de inundação é de aproximadamente 24 horas para os três eventos. Esse comportamento pode ser explicado pelo fato de que as inundações na região não são repentinas, mas ocasionadas por precipitação acumulada (NETO, 2019b). As precipitações ocorridas em dias seguidos são, em sua maioria, de menor intensidade, e podem induzir a velocidades mais lentas da água, na medida em que os escoamentos superficiais atingem a rede hidrográfica durante as chuvas. Dessa forma, ocorre um aporte contínuo de deflúvio nos canais que provocam aumento gradativo dos armazenamentos na planície de inundação.

É possível observar que a recessão da onda de cheia e o esvaziamento das áreas inundadas ocorreu de forma lenta nos três eventos, passando-se dias até que o fluxo dos canais retornasse às condições normais. Isso pode indicar que após a evacuação dos moradores das residências atingidas, a permanência deles em abrigos persistiu por um período relativamente longo. O conhecimento do período de recessão da onda de cheia pode ser útil para realização das atividades de preparação e resposta do GDN, no sentido de estimar a quantidade de recursos necessários para o tempo que famílias precisarão ser abrigadas nos centros de atendimento.

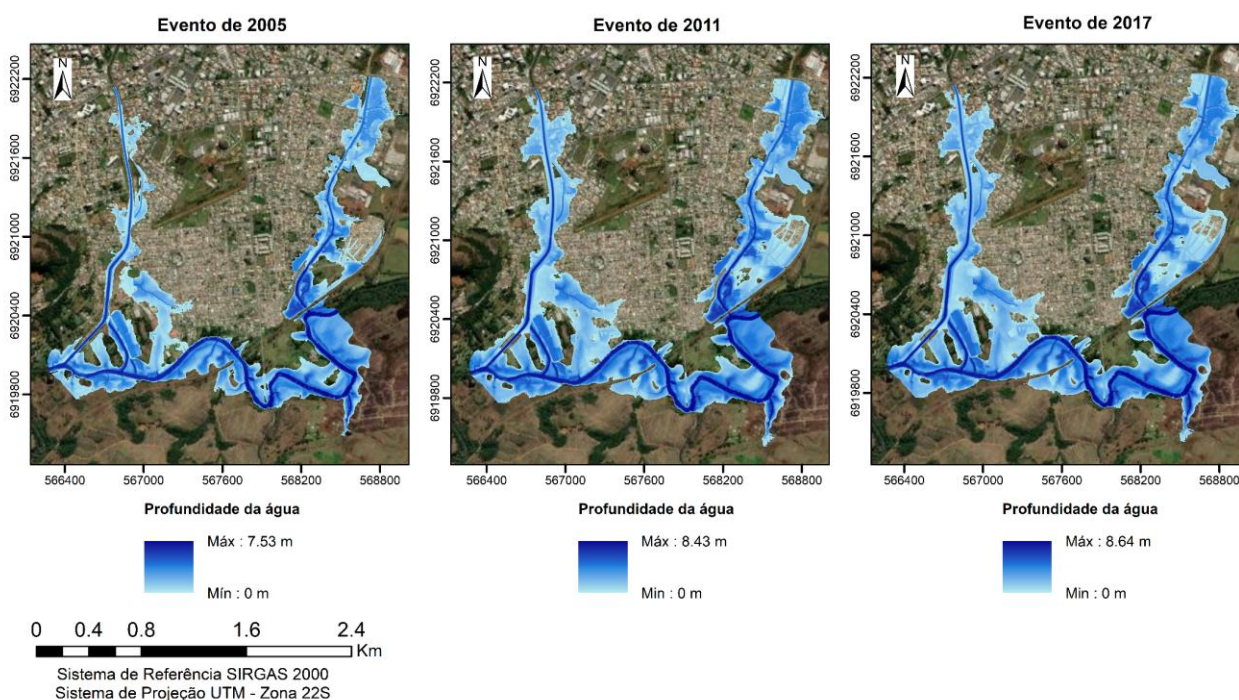
A velocidade com que a água escoou é diferente dependendo do canal. O rio Caveiras apresentou longa duração de inundação comparado ao comportamento dos afluentes, pois através do canal principal são escoados todos os volumes do início ao final da simulação. O rio Ponte Grande apresentou o escoamento de recessão retardado em comparação ao fluxo de escoamento do rio Carahá. Isso ocorre, principalmente, devido à uma galeria de concreto localizada no exutório do rio Ponte Grande que limita sua vazão máxima de escoamento (LIZ, 2018). A galeria foi construída sob uma ferrovia e ocasiona um estrangulamento da água que, muitas vezes, contribui para o armazenamento temporário de água nessa região até que todo o volume seja escoado.

A profundidade da água é representada no HEC-RAS 2D em termos de altura de inundação, considerando como referência de nível batimétrico o canal. As simulações realizadas resultaram em profundidades de inundação calculadas a partir do MDT utilizado, que possui resolução vertical de 30 cm. A precisão vertical de 30 cm proporcionada pelo MDT é considerada de alta resolução espacial, sendo essencial para a simulação de manchas de inundações que representem a realidade.

A avaliação do evento de 2005 demonstrou que neste foram atingidas as menores profundidades dentre os três eventos simulados (Figura 22). O valor máximo obtido durante a simulação do evento de 2005 foi de 7,53 m, profundidade esta identificada principalmente no rio Caveiras. Nos trechos dos rios urbanos as profundidades atingidas foram inferiores a 6,5 m. A profundidade máxima atingida na simulação de 2011 foi de 8,43 m, também, identificada nos trechos do rio Caveiras, o qual possui calha profunda e é capaz de comportar maior vazão e volume de água. Nos trechos dos rios urbanos a profundidade máxima atingida foi de 7,15 m no rio Carahá e 7,54 m no rio Ponte Grande.

O evento de 2017 é considerado o de maior magnitude, com a vazão máxima atingida próxima de 800m³/s. Como consequência, a simulação do evento de 2017 foi a que produziu as maiores profundidades de água, chegando a 8,64 m. Nas áreas da planície de inundação, próximo à população, a profundidade da água chegou a 3,5 m. De acordo com os registros da Defesa Civil, o evento de 2017 foi de grandes proporções, sendo um dos maiores contabilizados no município desde a grande enchente de 1983.

Figura 22- Profundidades máximas atingidas durante os eventos simulados.



As profundidades de água foram extraídas do modelo hidrodinâmico pela ferramenta *Profile lines*. Dessa forma, foi possível obter os dados em frequência horária para cada local de monitoramento ao longo do tempo de simulação (Figuras 23-25). Os

dados de profundidade da água foram organizados em planilhas do MSExcel e, posteriormente, utilizados para treinamento dos modelos de RNA.

Figura 23 - Profundidades de água (m) geradas pelo modelo hidrodinâmico ao longo do tempo nos locais de monitoramento para o evento de 2005.

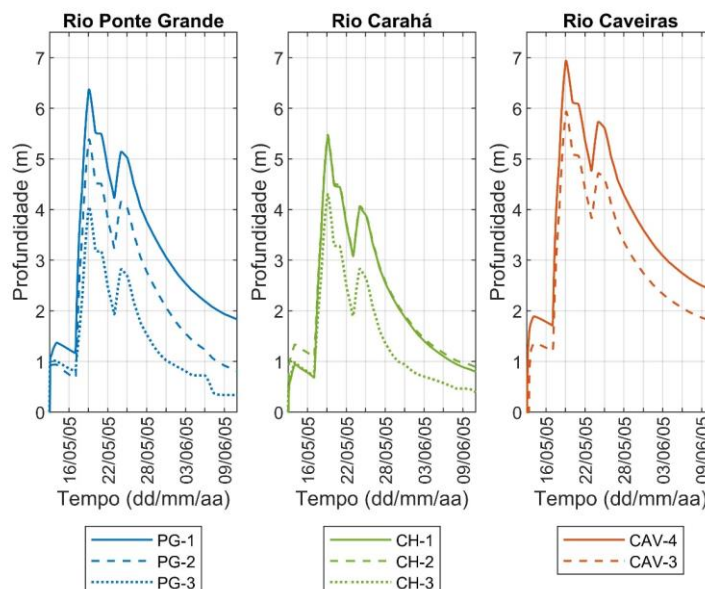


Figura 24- Profundidades de água (m) geradas pelo modelo hidrodinâmico ao longo do tempo nos locais de monitoramento para o evento de 2011.

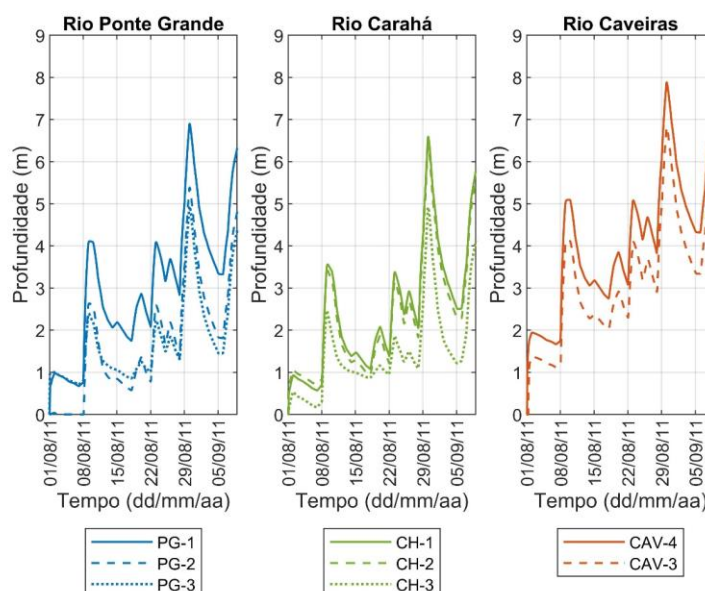
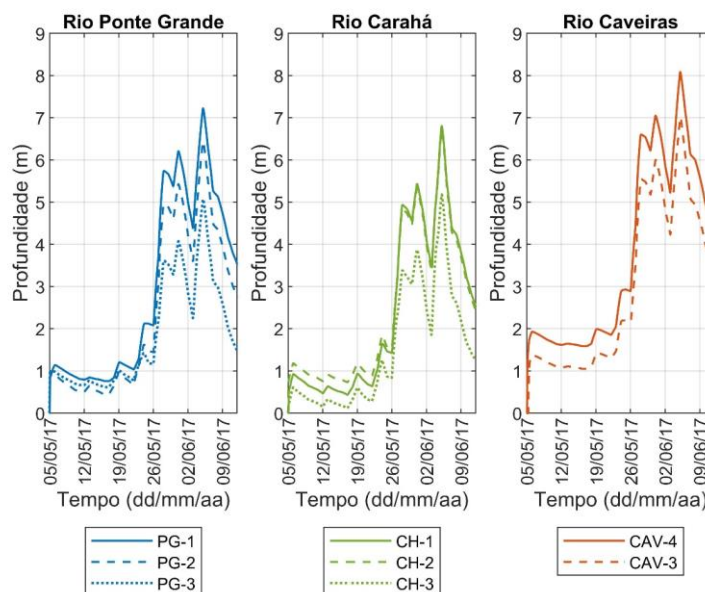


Figura 25- Profundidades de água (m) geradas pelo modelo hidrodinâmico ao longo do tempo nos locais de monitoramento para o evento de 2017.



5.3 DEFINIÇÃO DOS MODELOS DE RNA PARA OS LOCAIS DE MONITORAMENTO

5.3.1 Análise de combinações de diferentes defasagens temporais das variáveis de entrada

Os modelos de RNA podem ser construídos com diferentes combinações temporais das variáveis de entrada dependendo do objetivo de previsão e das características dos dados disponíveis. Para definição dos modelos buscou-se determinar a defasagem temporal das variáveis de entrada que proporcionasse as melhores eficiências durante a etapa de verificação para cada local de monitoramento. Realizaram-se previsões para alcances de 3, 6, 8, 12, 14, 18 e 20 horas, e para cada local de monitoramento foram testadas oito combinações de diferentes defasagens temporais das variáveis de precipitação, vazão e profundidade da água que variaram entre $t-6$, $t-3$, $t-2$, $t-1$ e t (valor atual). Ao conduzir essa análise observou-se que os componentes temporais capazes de proporcionar melhor desempenho no modelo são os que possuem dados menos defasados - com atraso temporal de até 3 horas. Para cada local de monitoramento foi escolhida a combinação responsável pelas melhores métricas de desempenho (NS, MAE, E90, Pbias) considerando todos os alcances de previsão. As combinações das defasagens temporais escolhidas para cada local de monitoramento estão apresentadas na Tabela 6.

Tabela 7- Combinação de defasagens temporais das variáveis de entrada do modelo de previsão.

Local de monitoramento	Combinação de entradas escolhidas
CAV-4	P1 (t), P2 (t), QJ4 (t-2), QJ4 (t-1), QJ4 (t), QJ13 (t-2), QJ13 (t-1), QJ13 (t), QJ8 (t-2), QJ8 (t-1), QJ8 (t), QPV (t-2), QPV (t-1), QPV (t), LM (t-1), LM (t)
CAV-3	P1 (t), P2 (t), QJ4 (t-1), QJ4 (t), QJ13 (t-1), QJ13 (t), QJ8 (t-1), QJ8 (t), QPV (t-1), QPV (t), LM (t-1), LM (t)
CH-1	P1 (t-2), P1 (t), P2 (t-2), P2 (t), QJ4 (t-1), QJ4 (t), QJ13 (t-1), QJ13 (t), QJ8 (t-1), QJ8 (t), QPV (t-1), QPV (t), LM (t-1), LM (t)
CH-2	P1 (t), P2 (t), QJ4 (t-1), QJ4 (t), QJ13 (t-1), QJ13 (t), QJ8 (t-1), QJ8 (t), QPV (t-1), QPV (t), LM (t-1), LM (t)
CH-3	P1 (t-2), P1 (t), P2 (t-2), P2 (t), QJ4 (t-1), QJ4 (t), QJ13 (t-1), QJ13 (t), QJ8 (t-1), QJ8 (t), QPV (t-1), QPV (t), LM (t-1), LM (t)
PG-1	P1 (t-2), P1 (t), P2 (t-2), P2 (t), QJ4 (t-1), QJ4 (t), QJ13 (t-1), QJ13 (t), QJ8 (t-1), QJ8 (t), QPV (t-1), QPV (t), LM (t-1), LM (t)
PG-2	P1 (t-2), P1 (t), P2 (t-2), P2 (t), QJ4 (t-1), QJ4 (t), QJ13 (t-1), QJ13 (t), QJ8 (t-1), QJ8 (t), QPV (t-1), QPV (t), LM (t-1), LM (t)
PG-3	P1 (t), P2 (t), QJ4 (t-1), QJ4 (t), QJ13 (t-1), QJ13 (t), QJ8 (t-1), QJ8 (t), QPV (t-1), QPV (t), LM (t-1), LM (t)

P1= precipitação (mm) estação Painei; P2 = precipitação (mm) estação Lages (para os eventos de 2005 e 2011) ou estação Lages Coral (para o evento de 2017); QJ4, QJ8, QJ13 = vazões originárias da simulação hidrológica (m³/s); QPV = vazão (m³/s) estação Ponte Velha (para os eventos de 2005 e 2011) ou estação Caveiras Montante 1 (para o evento de 2017). LM = profundidade da água no local de monitoramento (m).

5.3.2 Análise da complexidade interna

A análise de complexidade interna buscou determinar o nível de complexidade estrutural da rede neural pela definição do número de neurônios internos (nni) necessários. Para determinação da complexidade ideal dos modelos de RNAs, utilizou-se o método enunciado por Lucchese; De Oliveira; Pedrollo (2020); Sari; Castro; Pedrollo, (2017) , que consiste em uma análise gráfica da relação entre o erro quadrático da etapa de validação e o número de neurônios internos, começando por uma rede superdimensionada (20 neurônios internos) até o menor número de neurônios possível (1 neurônio interno).

A partir da análise gráfica, é possível identificar um limiar de complexidade no qual o decaimento do desempenho do modelo atinge um platô semelhante ao da rede superdimensionada (20 neurônios internos), porque há um número de neurônios internos suficiente para descrever as relações entre as variáveis de entrada e saída da rede. O número de neurônios internos para se atingir o platô teórico foi identificado para cada local de monitoramento, considerando todos os alcances de previsão testados. Os limites

de complexidade variaram entre 10, 8, 6, 5 e 4 neurônios dependendo do local de monitoramento. O número de neurônios internos é apresentado na Tabela 7 e o resultado completo dessa etapa da pesquisa podem ser vistos no Apêndice A.

Tabela 8- Número de neurônios internos escolhidos para cada local de monitoramento.

Local de monitoramento	rna	nni
CAV-4	rna_CAV4	6
CAV-3	rna_CAV3	5
CH-1	rna_CH1	6
CH-2	rna_CH2	4
CH-3	rna_CH3	10
PG-1	rna_PG1	8
PG-2	rna_PG2	5
PG-3	rna_PG3	10

5.4 MODELOS DE PREVISÃO COM SAÍDAS SIMPLES

Nesta etapa foram analisados os oito modelos de RNA desenvolvidos para cada local de monitoramento (rna_CAV4, rna_CAV3, rna_CH1, rna_CH2, rna_CH3, rna_PG1, rna_PG2 e rna_PG3). Os modelos possuem uma única variável de saída, que corresponde à profundidade da água no respectivo local de monitoramento. As previsões foram realizadas considerando alcances de 3, 6, 8, 12, 14, 18 e 20 horas. O número de neurônios internos é variável dependendo do local de monitoramento (Tabela 7), mas é o mesmo para todos os alcances. O número máximo de ciclos admitidos no treinamento foi de 500000, considerando 5 repetições.

5.4.1 Locais de monitoramento no rio Caveiras – CAV-4 e CAV-3

As variáveis de entrada com as respectivas defasagens temporais utilizadas para o modelo rna_CAV4 e rna_CAV3 são ilustradas na Figura 26 e 27. As métricas de desempenho para o modelo de saídas simples dos locais de monitoramento CAV-4 e CAV-3 são apresentados na Tabela 8 e 9.

Figura 26-Ilustração da rna_CAV4, referente ao modelo de previsão da profundidade de água no local de monitoramento (LM) CAV-4, com as variáveis de entrada e defasagens temporais utilizadas.




Figura 27-Ilustração do modelo rna_CAV3, referente à previsão da profundidade de água no local de monitoramento (LM) CAV-3, com as variáveis de entrada e defasagens temporais utilizadas.




Tabela 9-Métricas de avaliação do desempenho na verificação para a rna_CAV4. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.

Modelo	Alc h	E90 cm	MAE cm	NS -	Pbias %
rna_CAV4	3	9,5	4,7	0,997	0,775
	6	10,4	8,3	0,991	0,636
	8	18,9	11,4	0,984	1,60
	12	33,4	19,7	0,952	1,52
	14	90,9	41,0	0,853	7,26
	18	61,0	39,8	0,857	-1,59
	20	72,1	37,3	0,848	2,53

Tabela 10-Métricas de avaliação do desempenho na verificação para a rna_CAV3. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.

Modelo	Alc h	E90 cm	MAE cm	NS -	Pbias %
rna_CAV3	3	4,5	4,0	0,997	-0,093
	6	42,5	17,6	0,960	4,82
	8	18,4	10,8	0,984	1,41
	12	24,9	15,9	0,966	-0,032
	14	55,6	28,3	0,908	5,15
	18	90,1	41,4	0,820	7,68
	20	54,2	33,0	0,856	1,54

5.4.2 Locais de monitoramento no rio Carahá – CH-1, CH-2, CH-3

As variáveis de entrada com as respectivas defasagens temporais utilizadas para o modelo rna_CH1, rna_CH2 e rna_CH3 são ilustradas na Figura 28, 29 e 30. As métricas de desempenho para o modelo de saídas simples dos locais de monitoramento CH-1, CH-2 e CH-3 são apresentados na Tabela 10, 11 e 12.

Figura 28- Ilustração do modelo rna_CH1, referente à previsão da profundidade de água no local de monitoramento (LM) CH1-1, com as variáveis de entrada e defasagens temporais utilizadas.




Figura 29- Ilustração do modelo rna_CH2, referente à previsão da profundidade de água no local de monitoramento (LM) CH-2, com as variáveis de entrada e defasagens temporais utilizadas.




Figura 30- Ilustração do modelo rna_CH3, referente à previsão da profundidade de água no local de monitoramento (LM) CH-3, com as variáveis de entrada e defasagens temporais utilizadas.




Tabela 11- Métricas de avaliação do desempenho na verificação para a rna_CH1. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho

Percentage bias.					
Modelo	Alc h	E90 cm	MAE cm	NS -	Pbias %
rna_CH1	3	6,9	7,1	0,993	-0,934
	6	5,0	11,0	0,981	-3,06
	8	10,9	8,7	0,989	-0,167
	12	38,1	21,3	0,949	0,723
	14	56,1	24,4	0,924	3,82
	18	93,6	44,7	0,815	10,2
	20	81,4	40,2	0,826	7,75

Tabela 12-Métricas de avaliação do desempenho na verificação para a rna_CH2. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.

Modelo	Alc h	E90 cm	MAE cm	NS -	Pbias %
rna_CH2	3	6,8	5,6	0,995	-0,099
	6	7,7	5,7	0,995	0,084
	8	10,8	11,4	0,984	-1,56
	12	23,3	28,8	0,887	-5,59
	14	37,0	37,7	0,859	-5,49
	18	46,5	44,9	0,742	-5,99
	20	58,8	47,7	0,743	-4,81

Tabela 13- Métricas de avaliação do desempenho na verificação para a rna_CH3. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.

Modelo	Alc h	E90 cm	MAE cm	NS -	Pbias %
rna_CH3	3 h	3,4	4,5	0,994	-0,752
	6 h	14,1	9,8	0,979	-0,604
	8 h	21,4	13,8	0,965	-1,06
	12 h	47,1	21,9	0,903	1,39
	14 h	38,9	26,7	0,868	-2,46
	18 h	71,3	40,4	0,678	-0,858
	20 h	86,6	40,6	0,670	8,43

5.4.3 Locais de monitoramento no rio Ponte Grande – PG-1, PG-2, PG-3

As variáveis de entrada com as respectivas defasagens temporais utilizadas para o modelo rna_PG1, rna_PG2 e rna_PG3 são ilustradas na Figura 31, 32 e 33. As métricas de desempenho para o modelo de saídas simples dos locais de monitoramento PG-1, PG-2 e PG-3 são apresentados na Tabela 13, 14 e 15.

Figura 31- Ilustração do modelo rna_PG1, referente à previsão da profundidade de água no local de monitoramento (LM) PG-1, com as variáveis de entrada e defasagens temporais utilizadas.




Figura 32- Ilustração do modelo rna_PG2, referente à previsão da profundidade de água no local de monitoramento (LM) PG-2, com as variáveis de entrada e defasagens temporais utilizadas.




Figura 33- Ilustração do modelo rna_PG3, referente à previsão da profundidade de água no local de monitoramento (LM) PG-3, com as variáveis de entrada e defasagens temporais utilizadas.




Tabela 14-Métricas de avaliação do desempenho na verificação para a rna_PG1. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho

Percentage bias.					
Modelo	Alc h	E90 cm	MAE cm	NS -	Pbias %
rna_PG1	3	5,0	5,2	0,997	-0,608
	6	8,9	8,1	0,992	-0,341
	8	17,0	11,8	0,982	0,232
	12	53,3	24,6	0,933	5,08
	14	45,8	29,7	0,906	0,163
	18	83,8	43,7	0,803	1,56
	20	69,4	48,7	0,792	-2,15

Tabela 15- Métricas de avaliação do desempenho na verificação para a rna_PG2. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho Percentage bias.

Modelo	Alc h	E90 cm	MAE cm	NS -	Pbias %
rna_PG2	3	4,2	4,1	0,997	-0,4
	6	7,7	7,0	0,994	-0,589
	8	9,8	16,4	0,970	-4,04
	12	31,0	27,4	0,916	-2,72
	14	36,9	29,5	0,906	-2,47
	18	59,6	33,6	0,862	3,05
	20	68,1	52,3	0,712	-3,97

Tabela 16- Métricas de avaliação do desempenho na verificação para a rna_PG3. Alc – alcance; E90 – quantil 0,90 dos erros absolutos; MAE – média do erro absoluto; NS – coeficiente de desempenho de Nash-Sutcliffe; Pbias - coeficiente de desempenho

Percentage bias.					
Modelo	Alc h	E90 cm	MAE cm	NS -	Pbias %
rna_PG3	3	3,9	4,0	0,995	-1,01
	6	10,7	6,3	0,987	0,262
	8	17,6	12,5	0,968	-2,19
	12	49,3	17,0	0,914	5,28
	14	44,3	20,6	0,891	2,09
	18	54,5	35,8	0,721	-6,35
	20	60,0	32,2	0,756	5,54

5.4.4 Análise dos resultados dos modelos de previsão de saídas simples

Foram observadas diferenças no desempenho dos modelos segundo o local de monitoramento, principalmente para previsões de alcances maiores. O modelo para CAV-4 apresentou NS elevado (0,850); no entanto, MAE igual a 41 cm e Pbias igual a 7,26%, caracterizando os maiores erros para previsões de 14 h de antecedência entre os modelos. Esse local, em particular, está localizado em uma região de recebimento de elevados volumes de água e de mudanças significativas no sentido do fluxo da água – devido à uma curva acentuada no rio Caveiras. Nesse caso, a frequência dos dados de profundidade utilizados para o desenvolvimento dos modelos (intervalos de 1 hora) pode não capturar com detalhes o comportamento da inundação, principalmente em momentos de mudança rápida no padrão do fluxo da água.

Os modelos dos locais CH-2, CH-3 e PG-3 apresentaram NS relativamente menor que os demais para alcances maiores (14 h – 20 h), o que indica uma capacidade inferior desses modelos em explicar a variância dos dados para esses alcances. Esses locais de monitoramento estão localizados a montante das áreas alagadas e não possuem como entrada certos dados, que podem ser mais importantes para a previsão de maior antecedência. Para previsões com 14 horas de antecedência, os valores de Pbias encontrados foram de -5,49; -2,46 e 2,09% para CH-2, CH-3, e PG-3, respectivamente. A MAE é inferior a 38 cm nesses locais. Para os quatro locais restantes (CH-1, PG-1, PG-2 e CAV-3), a MAE encontrada foi inferior a 29 cm para alcances de 14 h.

O desempenho obtido é apenas ligeiramente menor do que o encontrado para previsões de níveis fluviais com RNAs do tipo MLP para a localidade de Encantado, na bacia do rio Taquari-Antas (FINCK; PEDROLLO, 2021), com NS igual a 0,99; 0,95 e 0,92 e MAE de 5,4; 17,7 e 19,4 cm para previsões de 4, 10 e 20 h, respectivamente. Esses resultados foram encontrados pelos autores utilizando cerca de três anos e cinco meses de dados horários de uma rede telemétrica com seis postos pluviométricos para treinamento e verificação do modelo, ao passo que nesta pesquisa, os dados utilizados foram de apenas três eventos cujas profundidades foram obtidas por simulação hidrodinâmica.

Além disso, a bacia do rio Taquari-Antas possui 26 600 km², o que confere uma certa estabilidade nas taxas de aumento das vazões durante os eventos. Apesar da bacia do Sistema Ponte Velha possuir uma área inferior (798,45 km²), é possível que o bom desempenho alcançado nas previsões de profundidade, em geral, se deva à extensa planície topográfica de inundação a montante dos locais de monitoramento. Nessa região

o rio Caveiras se apresenta sinuoso e com baixa declividade, o que produz fluxos relativamente lentos e laminares em seu trajeto (LIZ, 2018).

A compreensão pela RNA das relações entre as variáveis está vinculada à qualidade e à resolução espacial do MDT utilizado nas simulações hidrodinâmicas (BERMÚDEZ *et al.*, 2018). Estudos sugerem que MDTs de resolução mais grosseira resultam em maiores áreas de inundação e profundidades pelo efeito da suavização do relevo, com diminuição das diferenças de nível entre os pontos da superfície (MUTHUSAMY *et al.*, 2021; SAKSENA; MERWADE, 2015). Uma representação refinada da superfície do terreno para efeito das simulações hidrodinâmicas, como a utilizada nesta pesquisa, pode permitir que a RNA considere as interações dinâmicas que ocorrem no sistema de inundação, o que aumenta a qualidade das previsões das RNAs (CHU *et al.*, 2020).

Conforme o aumento do alcance de previsão, o desempenho dos modelos foi comprometido, sinalizando redução na capacidade de compreensão e representação das relações entre as variáveis utilizadas para previsões de grande antecedência. Os dados utilizados para previsão com alcances maiores (14 h - 20 h) podem incluir informações irrelevantes, que não contribuem para o bom desempenho do modelo (JHONG; WANG; LIN, 2017). Assim como podem carecer de informações representativas do que realmente ocorre entre o momento da previsão e o horizonte correspondente ao alcance desta. No geral, os modelos apresentaram-se capazes de realizar previsões para alcances com até 20 horas de antecedência com MAE inferior a 52 cm e NS igual ou superior a 0,67.

Para previsões com antecedência de até 8 horas, todos os modelos de RNA com saídas simples apresentaram resultados muito bons. O coeficiente NS permaneceu igual ou superior a 0,96 e o bom desempenho dos modelos é confirmado pelos resultados obtidos para a MAE, esses foram inferiores a 18 cm para alcances de 3 h até 8 h. Os valores de Pbias mantiveram-se dentro da faixa de desempenho considerado muito bom para modelos de previsão hidrológica (NETO, *et al.*, 2019; TAMIRU; DINKA, 2021). Possibilitar a realização de previsões de eventos de inundação com antecedência de 3, 6 ou 8 horas pode significar tempo suficiente para que medidas de preparação e resposta sejam implementadas, como por exemplo, alertar a população e realizar atividades de evacuação da área. De acordo com o PLACON de Lages, o tempo de antecedência suficiente é de 5 h para que as ações de resposta possam ser viabilizadas (COMPDEC, 2018), o que permite inferir que os modelos de RNAs avaliados nesta pesquisa podem servir na configuração de um sistema de previsão e alerta a inundações para a cidade.

Os resultados indicaram ainda que a aplicação de RNAs é uma alternativa para previsões de inundação de forma espacializada, a partir de locais de monitoramento distribuídos na planície inundável urbana. Essa questão parece relevante e significativa, principalmente, no âmbito de sistemas de previsão e alerta a inundações, pois pode aumentar a eficiência prática desses sistemas. O conhecimento objetivo da profundidade da água nas áreas urbanas afetadas por inundações é de principal interesse dos gestores para que medidas efetivas de preparação e resposta possam ser tomadas. Dessa forma, a informação precisa e antecipada da profundidade da água em locais específicos da planície inundável urbana pode qualificar o processo decisório na esfera do GDN.

Além disso, as observações de seções fluviais podem ser combinadas com os dados de profundidade previstos em locais estratégicos dentro das áreas urbanas; deste modo, a variedade de informações sobre o comportamento hidrodinâmico dos rios urbanos e sobre o efeito que a contribuição desses exerce para a ocorrência de um desastre pode contribuir para a melhoria do processo decisório nas diferentes etapas do GDN.

5.4.5 Análise da sensibilidade das variáveis de entrada para a previsão

Nesta etapa foi realizada a exclusão de variáveis de entrada com o intuito de verificar o efeito dessas para o desempenho do modelo. Os modelos parciais (MP) representam a exclusão de uma ou mais variáveis de entrada por vez e permitem verificar a importância dessas para o desempenho do modelo completo (MC). A análise foi realizada por meio da comparação dos resultados do coeficiente NS da etapa de verificação entre os MC e MP, visto que essa métrica possibilita compreender a variância dos dados que pode ser explicada pelo modelo e, consequentemente, permite averiguar qual a contribuição de cada variável para as previsões. Na Tabela 16 estão descritas as variáveis excluídas para cada MP.

Tabela 17- Apresentação dos modelos desenvolvidos nesta pesquisa para análise da importância de cada variável de entrada nas previsões. MC – Modelo completo; MP – Modelos parciais.

Modelo	Entradas	Entradas excluídas
MC	P1; P2; QJ4; QJ13; QJ8; QPV; LM	-
MP1	P2; QJ4; QJ13; QJ8; QPV; LM	P1
MP2	P1; QJ4; QJ13; QJ8; QPV; LM	P2
MP3	P1; P2; QJ13; QJ8; QPV; LM	QJ4
MP4	P1; P2; QJ4; QJ8; QPV; LM	QJ13
MP5	P1; P2; QJ4; QJ13; QPV; LM	QJ8
MP6	P1; P2; QJ4; QJ13; QJ8; LM	QPV
MP7	P1; P2; QJ4; QJ13; QJ8; QPV	LM
MP8	QJ4; LM	P1; P2; QJ13; QJ8; QPV

Existem poucas variações no desempenho dos modelos com a retirada dos dados de precipitação da estação Painel (P1), representado pelo conjunto MP1 (Figura 34). Nota-se uma pequena redução no NS dos locais de monitoramento do rio Caveiras e rio Ponte Grande para previsões a partir de 18 horas. Esse comportamento está representado pelos locais CAV-4 e PG-1 na Figura 34. Os locais de monitoramento CH-2 e CH-3 apresentaram comportamento semelhante, com exceção do local CH-1, para o qual houve um pequeno aumento no NS no alcance de 18 horas e manteve-se o desempenho equivalente ao do MC para os demais alcances.

Para o conjunto MP2, que representa a exclusão da variável de precipitação da estação Lages/Lages Coral (P2), foram encontrados resultados similares aos do conjunto MP1. Os locais de monitoramento no rio Caveiras e Carahá sofrem redução no NS para alcances maiores – a partir de 18 horas (Figura 35). No entanto, a ausência desses dados de precipitação passa a influenciar negativamente a capacidade dos modelos no rio Ponte Grande em explicar a variância dos dados um pouco antes - a partir do alcance de 12 horas.

A redução no NS dos modelos foi pouco significativa com a ausência das variáveis de precipitação, as quais passam a influenciar negativamente o desempenho dos modelos para alcances maiores, apenas. A baixa sensibilidade que os modelos apresentaram à exclusão de P1 e P2 pode ter sua razão relacionada à diferença existente entre a escala de discretização temporal das precipitações (diárias) com relação a escala temporal da

variável de saída (horária), o que faz com que esses dados não exerçam grande influência para previsões com alcances menores.

Figura 34- Efeito da retirada dos dados de precipitação da estação Paineira (P1), representado pelo conjunto MP1 (modelos parciais 1) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre a métrica NS para todos os alcances.






Figura 35- Efeito da retirada dos dados de precipitação da estação Lages/Lages Coral (P2), representado pelo conjunto MP2 (modelos parciais 2) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre métrica NS para todos os alcances.



A variável QJ4 é certamente uma das variáveis mais importantes para os modelos, pois sua retirada afeta todos os locais de monitoramento. Na Figura 36 está ilustrado o impacto da retirada dessa variável para os locais CAV-3, CH-3 e PG-3, que refletem o comportamento observado também nos demais locais. Nota-se que a ausência dos dados de QJ4 reduziu o NS dos modelos a partir do alcance de 8 horas, e de forma mais pronunciada para alcances de 20 horas. Essa variável corresponde ao hidrograma da junção J4, localizada no rio Caveiras, que representa o somatório dos volumes provenientes das bacias a montante do domínio do problema. Por sua vez, o rio Caveiras é um agente de grande influência para a ocorrência de inundações na área urbana de Lages, contribuindo, inclusive, para que as áreas de planície dos rios Carahá e Ponte Grande sejam inundadas (LIZ, 2018; NETO, 2019c). Portanto, está refletido o impacto

dos volumes do rio Caveiras que adentram a área urbana sobre a ocorrência de inundação em Lages na importância da variável QJ4 para os modelos de previsão.

Figura 36- Efeito da retirada dos dados de vazão QJ4, representado pelo conjunto MP3 (modelos parciais 3) em relação ao modelo completo (MC) para os locais CAV-3, CH-3 e PG-3 sobre a métrica NS para todos os alcances.



A retirada da variável QJ13, representada pelo conjunto MP4, teve impacto negativo na capacidade do modelo em explicar a variabilidade dos dados para os locais de monitoramento do rio Caveiras e Ponte Grande, exemplificados pelos locais CAV-3 e PG-3 na Figura 37. A redução do NS nesses modelos ocorreu principalmente para alcances maiores (18 h-20 h). Quando analisamos alcances entre 3 h e 14 h o efeito da exclusão de QJ13 foi pouco perceptível. Os locais de monitoramento do rio Carahá sofreram pouca ou nenhuma variação, como exemplificado pelo local CH-3 (Figura 37).

O comportamento oposto foi observado com a exclusão da variável QJ8 (conjunto MP5) que aparentemente teve pouca influência no desempenho dos modelos do rio Caveiras e Ponte Grande (Figura 38). Apenas os locais de monitoramento no rio Carahá pareceram ter sido mais afetados. Com a exclusão da variável QJ8, o local de monitoramento CH-3 teve redução no NS de maneira mais pronunciada para o alcance de 18 horas (Figura 38), o que também ocorreu para os locais CH-1 e CH-2. O fato de que os modelos sem as variáveis de vazão QJ13 e QJ8 tenham o desempenho praticamente inalterado, nas previsões de até 12 horas, pode estar relacionado com o pequeno volume

que essas vazões representam isoladamente na elevação da onda de cheia e, consequentemente, nas profundidades de inundação.

Figura 37- Efeito da retirada dos dados de vazão QJ13, representado pelo conjunto MP4 (modelos parciais 4) em relação ao modelo completo (MC) para os locais CAV-3, CH-3 e PG-3 sobre métrica NS para todos os alcances.





Figura 38- Efeito da retirada dos dados de vazão QJ8, representado pelo conjunto MP5 (modelos parciais 5) em relação ao modelo completo (MC) para os locais CAV-3, CH-3 e PG-3 sobre a métrica NS para todos os alcances.



A ausência da variável QPV (conjunto MP6) parece ter aumentado o NS dos modelos em comparação com o MC para alcances a partir de 12 horas (Figura 39). Esse comportamento foi verificado para todos os locais de monitoramento, sendo apresentados na Figura 39 apenas CAV-4, CH-1 e PG-1 para fins de simplificação. A variável QPV corresponde aos dados de vazão observados a jusante, sendo utilizada nos modelos como um indicador das condições gerais de descarga da área de interesse, com o intuito de contribuir com uma maior robustez da modelagem.

Figura 39- Efeito da retirada dos dados de vazão QPV, representado pelo conjunto MP6 (modelos parciais 6) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre a métrica NS para todos os alcances.





Figura 40- Efeito da retirada dos dados de profundidade da água (LM), representado pelo conjunto MP7 (modelos parciais 7) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre a métrica NS para todos os alcances.




Os resultados obtidos para o conjunto MP7 indicaram que os dados de profundidade são muito importantes para o desempenho dos modelos desta pesquisa (Figura 40). Para os locais no rio Caveiras, representado pelo local CAV-4, ocorreu redução expressiva no desempenho do modelo com a retirada da variável de profundidade da água, notável a partir do alcance de 8 horas. A ausência dos dados de profundidade da água afetou de forma mais significativa o desempenho dos modelos no rio Ponte Grande comparado ao rio Carahá, o que está demonstrado na Figura 40 pelo comportamento de PG-1 e CH-1.

O comportamento da inundação, no geral, difere entre os rios Ponte Grande e Carahá. Isso ocorre, principalmente, em função de uma galeria de concreto localizada no exutório da bacia do rio Ponte Grande, que acaba por reduzir o fluxo de água que escoar por essa região e permite que o período de extravasamento do nível do rio Ponte Grande para as áreas inundáveis seja mais longo. Pode ser que os dados de precipitação e vazão apenas, não sejam suficientes para a previsão já que existem outras variáveis contribuem

para o aumento da profundidade da água na região inundável do rio Ponte Grande (como a galeria). Nesse caso, os dados de profundidade são mais eficazes em informar ao sistema sobre esse comportamento.

O conjunto MP8 representa a exclusão das variáveis P1, P2, QJ8, QJ13 e QPV, com o intuito de avaliar o efeito conjunto das variáveis QJ4 e LM para o desempenho dos modelos (Figura 41). Para alcances de até 12 horas, o NS do conjunto MP8 pareceu não apresentar variações e manteve-se semelhante ao do MC. No geral, o NS permaneceu acima de 0,8 para todos os locais de monitoramento. Na Figura 41 estão apresentados os resultados para CAV-4, CH-1 e PG-1, para fins de exemplificação.

Figura 41-Efeito da retirada dos dados de profundidade da água (LM), representado pelo conjunto MP8 (modelos parciais 8) em relação ao modelo completo (MC) para os locais CAV-4, CH-1 e PG-1 sobre a métrica NS para todos os alcances.



A parcimônia de um modelo de previsão é conseguida com o menor número de variáveis e parâmetros possíveis, sem que isto implique em perda de desempenho. Sob este ponto de vista, poderia-se considerar a retirada de algumas das variáveis analisadas do processo de previsão, pois para alcances de até 8 horas – tempo de antecedência suficiente para previsões no domínio do problema –, o NS dos modelos apresentou redução significativa apenas quando retiradas individualmente as variáveis QJ4 e LM. Avaliar a distribuição dos quantis dos erros ou a importância estatística de cada variável

pode ser uma forma de esclarecer o real efeito da exclusão de cada uma para o desempenho dos modelos.

De modo geral, as variáveis analisadas neste tópico pareceram não exercer influência, isoladamente, na qualidade das previsões de profundidades de inundação de até 8 horas. As que se mais destacaram foram a variável QJ4 (conjunto MP3), que representa o hidrograma de entrada na junção J4, e a variável LM (conjunto MP7), que representa o vetor das profundidades de água. Além de servir como condição de contorno de entrada na simulação hidrodinâmica, a variável QJ4 reflete as interações hidrológicas e hidrodinâmicas das descargas das bacias a montante da área urbana (NETO, 2019c). A variável LM corresponde ao vetor das profundidades e reflete o efeito das ondas de cheias ao longo do tempo. Ambas as variáveis já foram consideradas relevantes durante todo o procedimento de pesquisa e agora foi possível constatar sua importância individual (conjuntos MP3 e MP7) e conjunta (conjunto MP8) quando se pensa em realizar previsões para a área de estudo desta pesquisa.

5.5 MODELOS DE PREVISÃO COM SAÍDAS MÚLTIPLAS

5.5.1 Aspectos gerais da formulação dos modelos de saídas múltiplas

Os modelos de saídas múltiplas foram testados para avaliar o desempenho da RNA na previsão da profundidade de água em locais de monitoramento simultaneamente, em comparação com a abordagem convencional de modelos com saídas simples. Os modelos rna_CAV4, rna_CH1 e rna_PG1 foram modificados para realizar a previsão de locais de monitoramento relacionados, simultaneamente à previsão dos respectivos pontos, e renomeados rna_CAV, rna_CH e rna_PG. A combinação das defasagens temporais e o número de neurônios internos definidos para os modelos originais seguem iguais para os modelos de saídas múltiplas. O treinamento foi realizado considerando 500000 ciclos, com cinco repetições. As previsões foram realizadas para os mesmos alcances da etapa anterior. Nas figuras 42, 43 e 44 estão ilustrados os modelos de saídas múltiplas

Figura 42-Ilustração da rna_CAV, referente ao modelo de previsão da profundidade de água nos locais de monitoramento CAV-4 e CAV-3 com as variáveis de entrada e defasagens temporais utilizadas.




Figura 43- Ilustração da rna_CH, referente ao modelo de previsão da profundidade de água nos locais de monitoramento CH-1, CH-2 e CH-3 com as variáveis de entrada e defasagens temporais utilizadas.





Figura 44- Ilustração da rna_PG, referente ao modelo de previsão da profundidade de água nos locais de monitoramento PG-1, PG-2 e PG-3 com as variáveis de entrada e defasagens temporais utilizadas.




5.5.2 Locais de monitoramento no rio Caveiras – Modelo rna_CAV

O modelo rna_CAV foi treinado para realizar a previsão simultânea da profundidade da água dos locais de monitoramento CAV-4 e CAV-3. Os resultados das métricas de avaliação indicaram melhora no desempenho do modelo quando utilizada a abordagem de saídas múltiplas (Figura 45). Para ambos os locais de monitoramento do rio Caveiras, o ganho mais sensível observado está ao se comparar os erros que não foram superados em 90% das previsões (representado pelo E90), os quais foram reduzidos para todos os alcances quando utilizado o modelo de saídas múltiplas. Isso indica que o modelo de saídas múltiplas possui uma capacidade superior para conter os erros maiores.

Além disso, o modelo de saídas múltiplas conferiu maior estabilidade aos resultados. Para o local de monitoramento CAV-4, houve uma redução excepcional no desempenho para o alcance de 14 h com o modelo de saídas simples, o que não ocorreu com o modelo de saídas múltiplas. Nota-se que as estatísticas de avaliação evoluíram de forma mais regular com a variação do alcance para o modelo de saídas múltiplas, o que pode representar que grande parte das variações aleatórias dessas estatísticas foram reduzidas.

Figura 45- Comparação das métricas de desempenho na etapa de verificação dos modelos de saídas simples e saídas múltiplas para os locais de monitoramento no rio Caveiras (CAV-3 e CAV-4) com variação do alcance de previsão.



É esperado que conforme o alcance de previsão aumenta, a capacidade de resposta do modelo diminua, sendo este comportamento observado tanto para os modelos de saídas simples quanto de saídas múltiplas (Figura 45). Para alcances de previsão maiores (18 h-20 h), o modelo de saídas múltiplas teve o valor de NS reduzido quando comparado com o modelo simples; contudo, manteve-se acima de 0,74.

Os gráficos da previsão da profundidade da água na etapa de verificação apresentam desempenho muito bom do modelo de saídas múltiplas para alcances de 3 h-8 h de antecedência (Figura 46 e 47). Nota-se, visualmente, certa deterioração da capacidade de previsão do modelo para alcances superiores a 12 horas - há um atraso na previsão da primeira fase de ascensão da onda de cheia e a etapa de recessão também é prejudicada. Além disso, os modelos passaram a superestimar as profundidades de inundação para alcances superiores a 18 horas.

Figura 46- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CAV-4 considerando diferentes alcances para o evento de 2011 (evento de verificação).

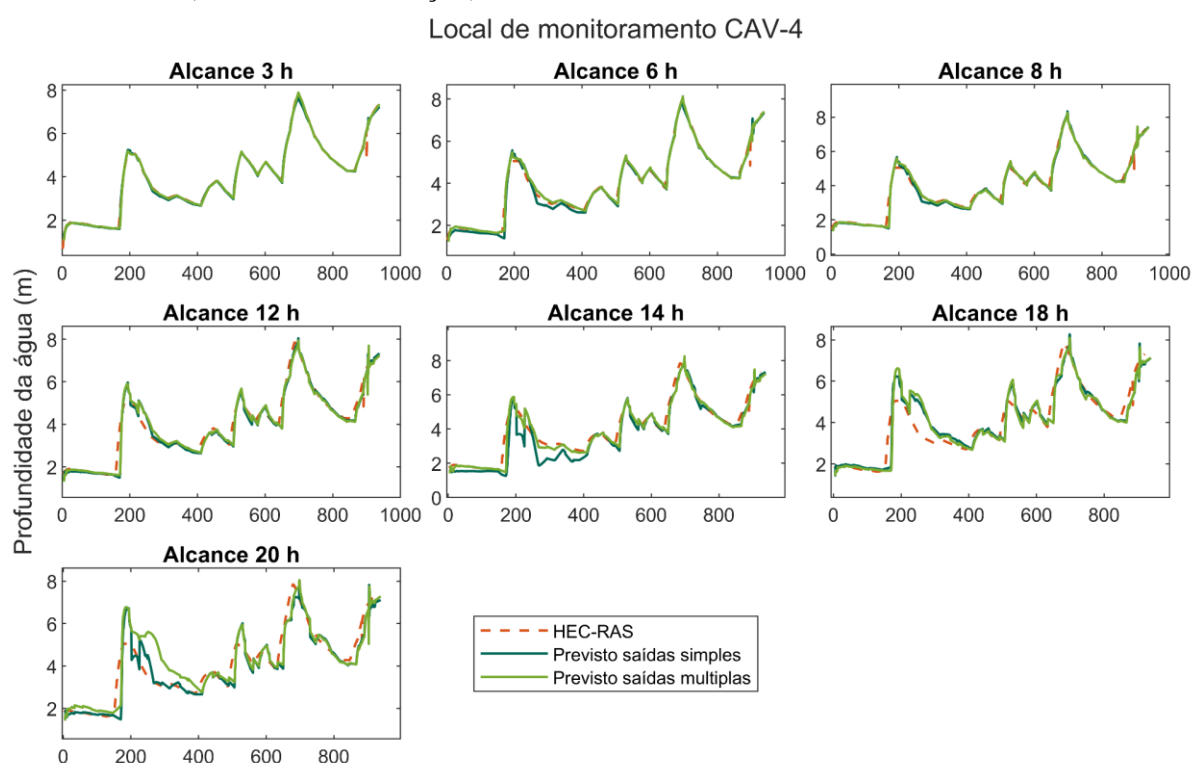
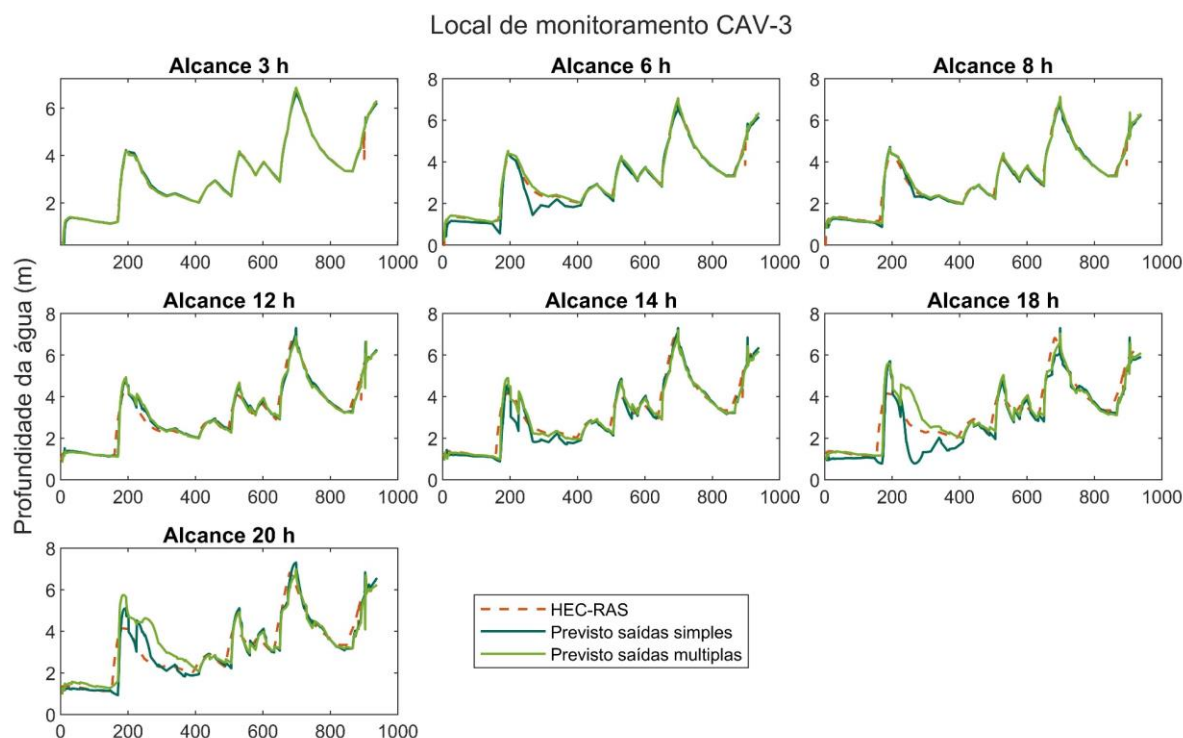


Figura 47- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CAV-3 considerando diferentes alcances para o evento de verificação (evento de 2011).



Os valores máximos de profundidade e o comportamento de recessão da onda de cheia foram mais bem reproduzidos pelo modelo de saídas múltiplas, principalmente para alcances de até 14 horas, corroborando os resultados encontrados para as métricas de avaliação. Para o local de monitoramento CAV-3, o modelo de saídas múltiplas teve um desempenho muito melhor para o alcance de 6 horas. É possível observar, na Figura 47, a reprodução mais precisa do comportamento da onda de cheia na etapa de recessão do primeiro pico para os alcances de 6, 8 e 14 horas.

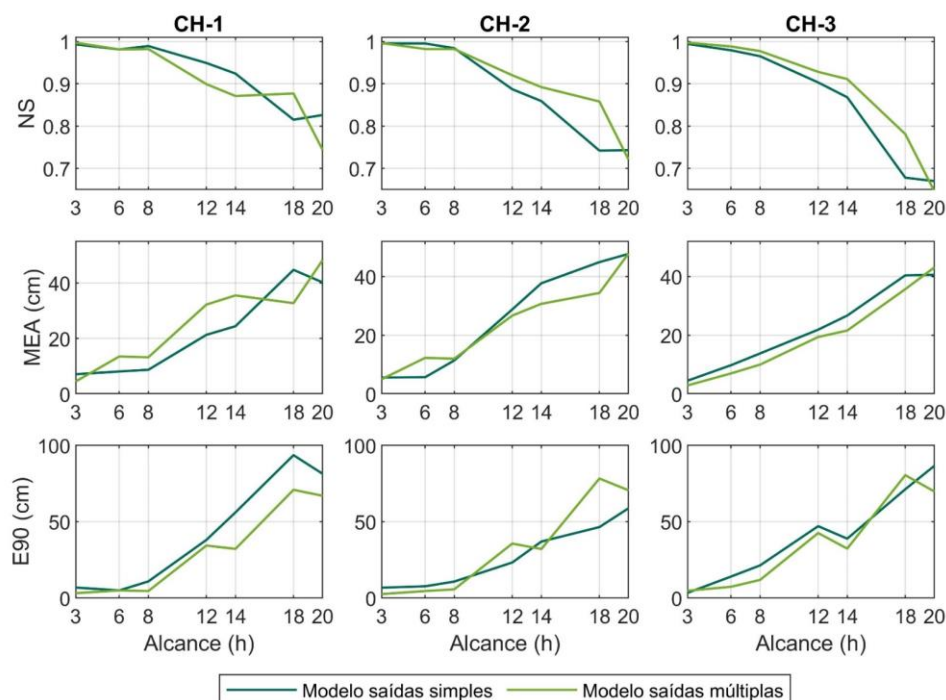
5.5.3 Locais de monitoramento no rio Carahá – Modelo rna_CH

O modelo rna_CH foi treinado para realizar a previsão simultânea da profundidade de água nos locais de monitoramento CH-1, CH-2 e CH-3. O modelo apresentou notável vantagem comparativa no desempenho para previsão da profundidade de água nos locais de monitoramento CH-2 e CH-3, em comparação às RNAs de saídas simples. As métricas tornaram-se equivalentes apenas para o alcance de 20 h, quando os modelos já não conseguem efetivamente realizar boas previsões.

O local CH-2 apresentou aumento do NS para alcances de 12 h a 18 h, sendo obtidos valores superiores a 0,78 (Figura 48). Para o local CH-3, o NS aumentou para

todos os alcances, exceto para o de 20 horas. Para alcances menores (3 h a 8 h) os resultados da MAE dos modelos de saídas múltiplas foram inferiores a 15 cm para os três locais de monitoramento no rio Carahá.

Figura 48- Comparação das métricas de desempenho na etapa de verificação dos modelos de saídas simples e saídas múltiplas para os locais do monitoramento no rio Carahá (CH-1; CH-2; CH-3) com variação do alcance de previsão.



A utilização do modelo de saídas múltiplas não proporcionou benefícios significativos para a previsão de profundidade da água no local CH-1 quando analisamos o coeficiente NS e a MAE. Apesar disso, para esse mesmo local, houve redução nos erros não ultrapassados 90% do tempo (E90) para todos os alcances quando utilizado o modelo de saídas múltiplas. Isso significa que, ao reduzir os erros maiores, o modelo está apresentando um comportamento mais estável, pois os erros serão menos sujeitos a valores extremos.

Para os locais de monitoramento no rio Carahá, a maior diferença observada entre a simulação dos modelos de saídas simples e saídas múltiplas está relacionada à reprodução do comportamento da onda de cheia (Figuras 49-51). A capacidade de reprodução dos dados de profundidade de água pelo modelo de saídas múltiplas é maior para os três locais de monitoramento. Os modelos de saídas simples subestimaram os valores máximos de profundidade da água na maioria dos alcances, o que é atenuado

quando utilizado o modelo de saídas múltiplas. Esse efeito pode ser visualizado de forma mais expressiva no local CH-3 (Figura 51).

Figura 49-Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CH-1 considerando diferentes alcances para o evento de verificação (evento de 2011).

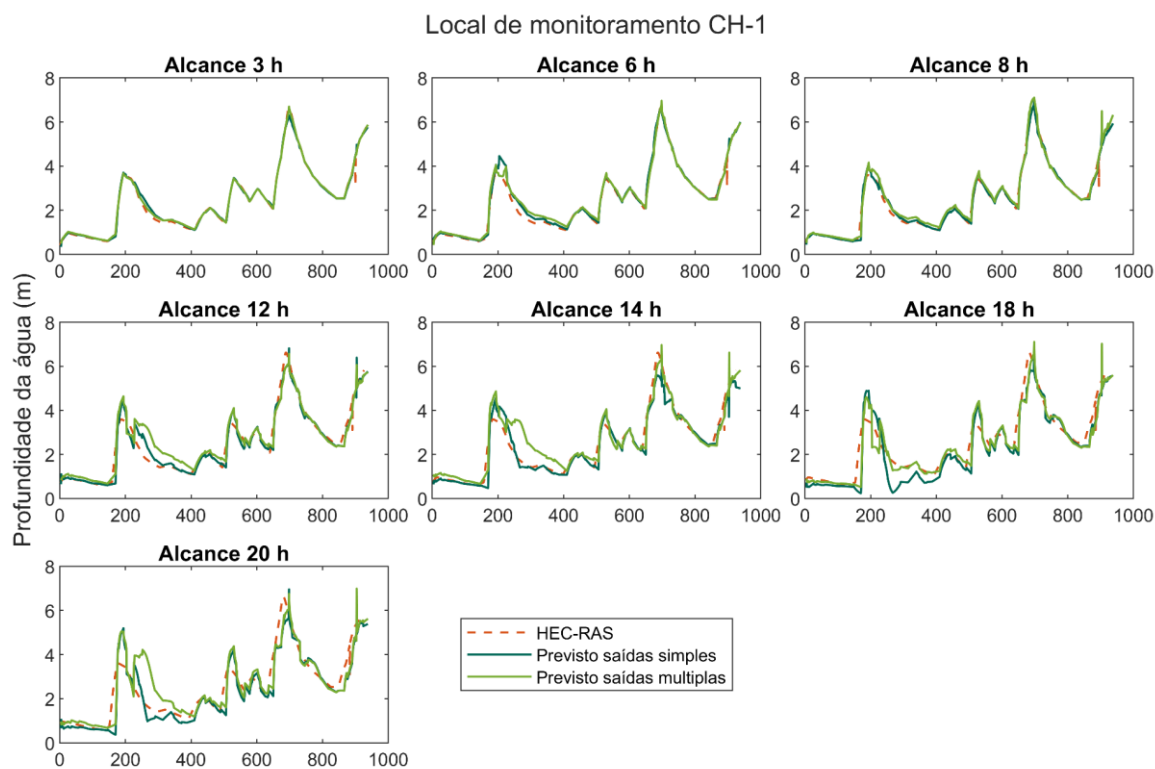


Figura 50- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CH-2 considerando diferentes alcances para o evento de verificação (evento de 2011).

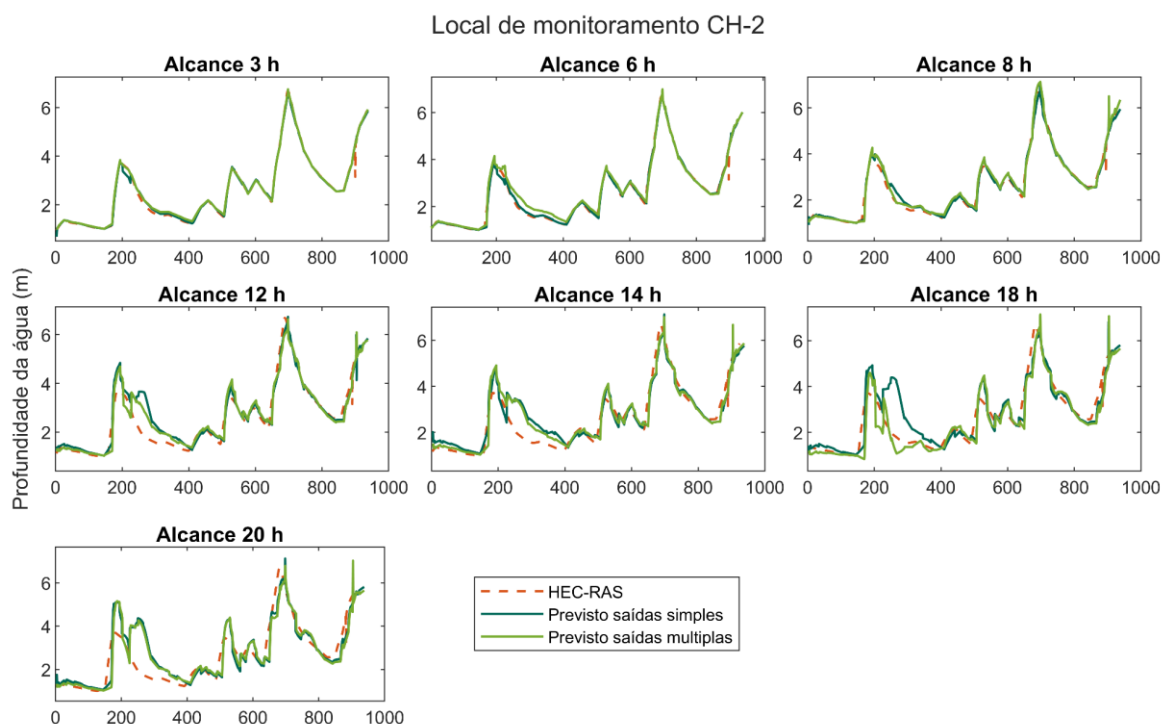
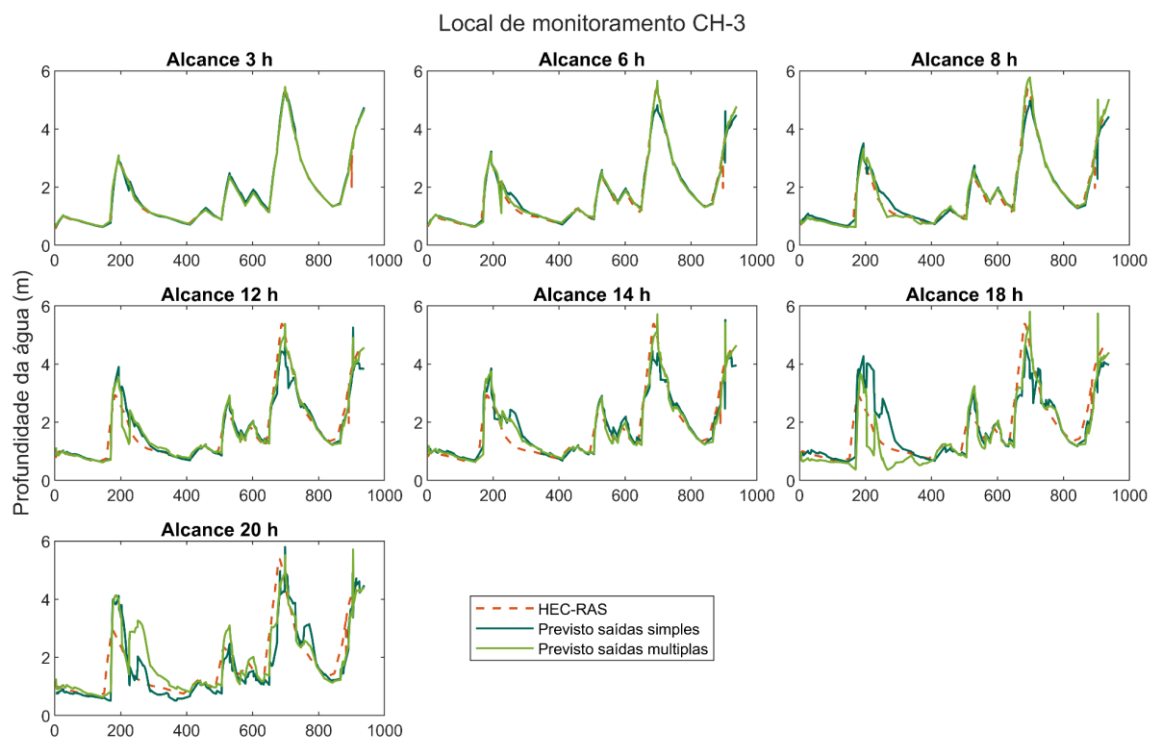


Figura 51- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento CH-3 considerando diferentes alcances para o evento de verificação (evento de 2011).

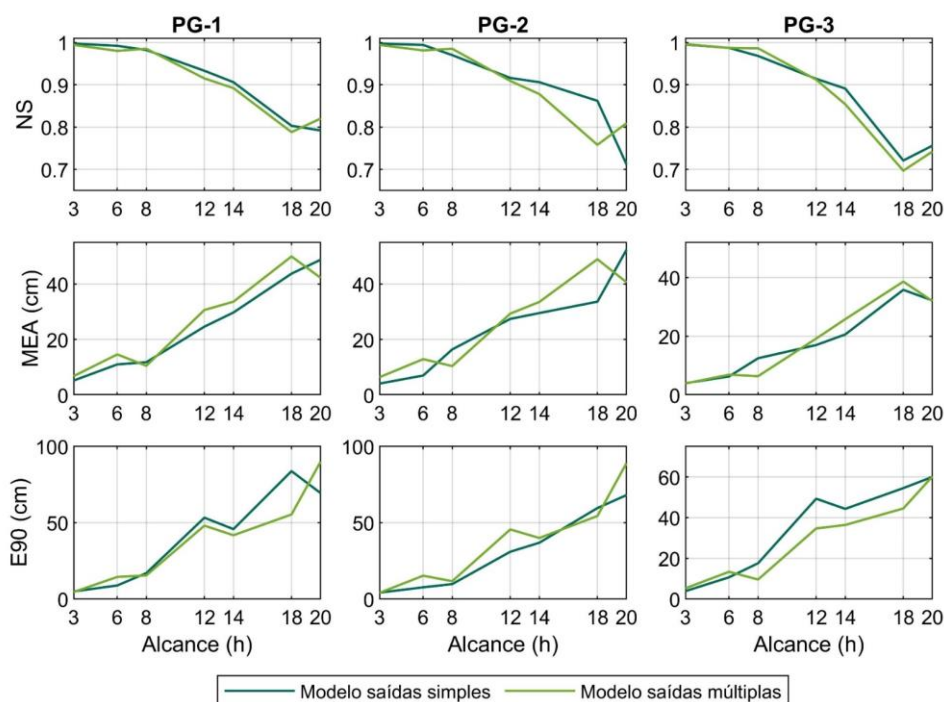


5.5.4 Locais de monitoramento no rio Ponte Grande – Modelo rna_PG

O modelo rna_PG foi treinado para realizar a previsão da profundidade da água dos locais de monitoramento PG-1, PG-2 e PG-3. As métricas de avaliação (NS e MAE) permaneceram similares entre os modelos de saídas simples e múltiplas para alcances de até 8 horas (Figura 52). Especificamente para o alcance de 20 horas, a experimentação de saídas múltiplas proporcionou aumento no desempenho para os três locais de monitoramento.

Para os locais PG-1 e PG-3, os resultados da métrica E90 favoreceram o modelo de saídas múltiplas. Observou-se redução nos erros não superados em 90% das previsões, isso pode indicar que o modelo de saídas múltiplas é capaz de conter os erros maiores, proporcionando maior estabilidade aos resultados.

Figura 52- Comparação das métricas de desempenho na etapa de verificação dos modelos de saídas simples e saídas múltiplas para os locais do monitoramento no rio Ponte Grande (PG-1; PG-2; PG-3) com variação do alcance de previsão.



Semelhante ao que ocorre para os locais de monitoramento do rio Caveiras e Carahá, para os locais do rio Ponte Grande os modelos de saídas simples têm tendência a subestimar os valores máximos de profundidade da água; enquanto os modelos de saídas múltiplas são capazes de superar essa limitação para alguns alcances (Figuras 53-55). Para PG-2 e PG-3, nos alcances de 3 h - 8 h, observou-se uma melhor capacidade do modelo de saídas múltiplas em reproduzir os valores máximos de profundidade da água (Figura 54 e 55).

No entanto, para alcances maiores (12h-20h) o modelo apresentou dificuldade para representar o primeiro pico da onda cheia, algo que ocorreu de forma menos pronunciada nos locais de monitoramento no rio Caveiras, por exemplo. Esse fato pode estar relacionado com as vazões utilizadas como condições de contorno no HEC-RAS e, consequentemente com dados de profundidade de água obtidos. Os volumes e profundidades atingidas no rio Caveiras são maiores do que as atingidas no rio Carahá e rio Ponte Grande. Além disso, a recessão da onda de cheia é mais lenta no rio Caveiras, proporcionando um período maior de dados de profundidade de água relevantes para as previsões de maiores alcances. Pelos resultados gráficos, percebe-se que os modelos de RNA captam essa dinâmica.

Figura 53- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento PG-1 considerando diferentes alcances para o evento de verificação (evento de 2011).

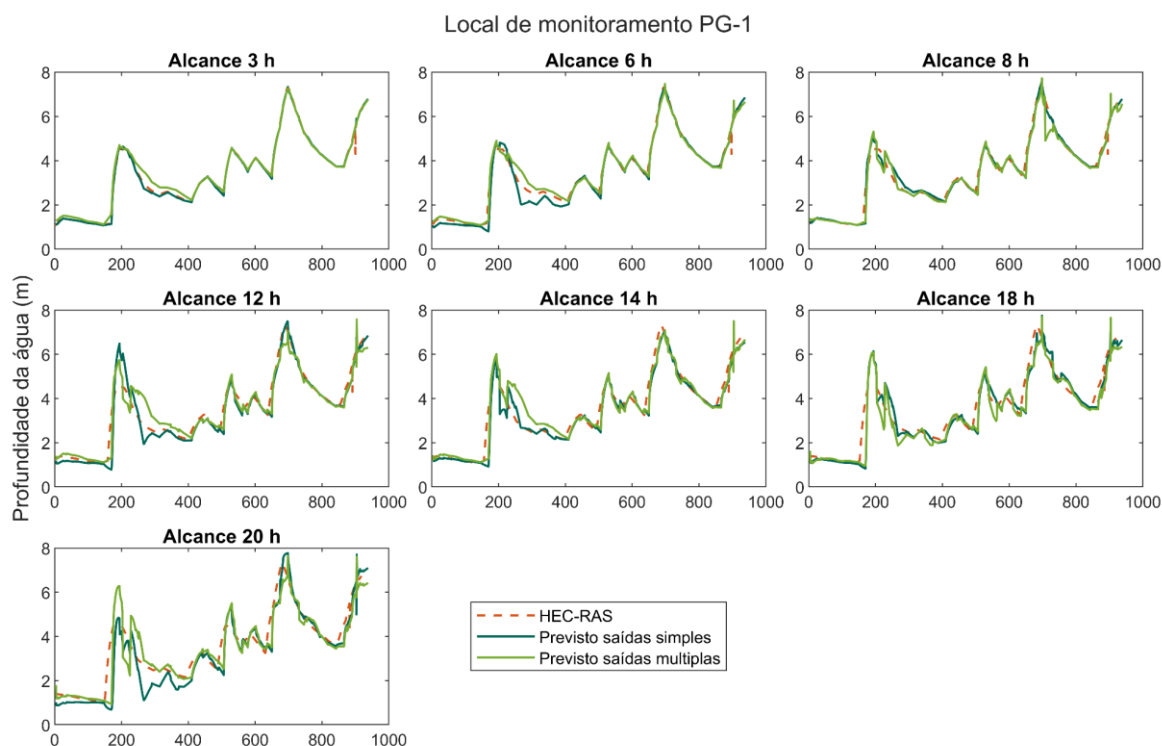


Figura 54- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento PG-2 considerando diferentes alcances para o evento de verificação (evento de 2011).

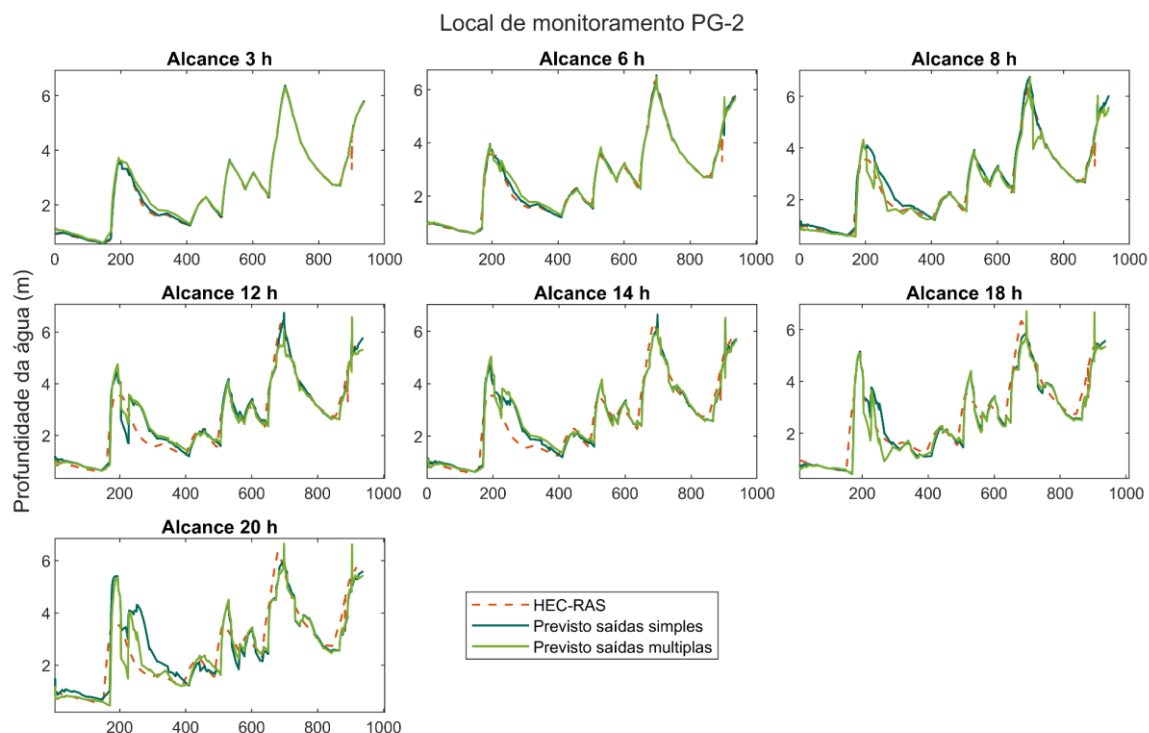
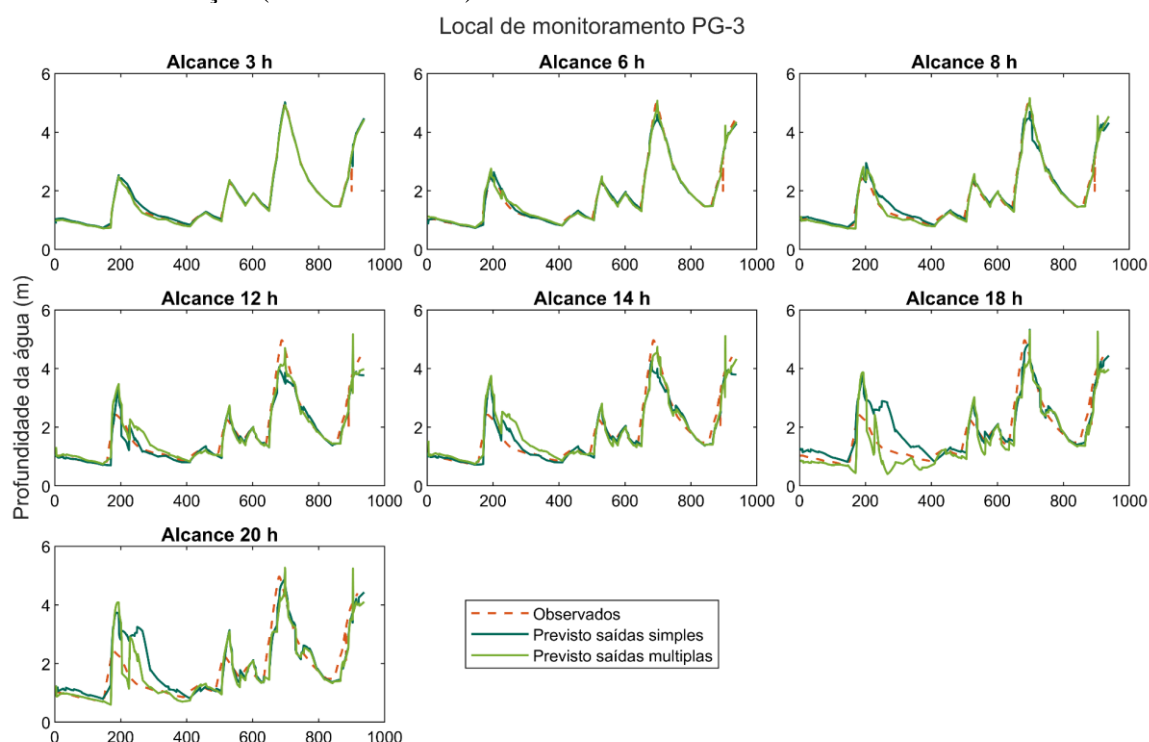


Figura 55- Comparação dos valores de profundidade da água simulados pelo modelo hidrodinâmico HEC-RAS, previstos pela RNA de saídas simples e RNA de saídas múltiplas no local de monitoramento PG-3 considerando diferentes alcances para o evento de verificação (evento de 2011).



5.5.5 Análise dos resultados dos modelos de previsão de saídas múltiplas

Utilizar um modelo de saídas múltiplas para previsão da profundidade da água simultaneamente em locais distribuídos na planície inundável viabilizou, em certa medida, a previsão de locais em cascata, semelhante ao que ocorre para canais. A exemplo dos locais no rio Caveiras (CAV-4 e CAV-3), ao prever a profundidade da água no local CAV-4 foi possível obter uma resposta simultânea para CAV-3 (localizado 2 km a jusante, aproximadamente), possibilitando uma visão integralizada da área. Visto que existe uma conexão entre um local e o outro, os modelos podem ser capazes de explorar a autocorrelação hidrodinâmica implícita entre vários locais de monitoramento, na dimensão espacial e temporal.

Além disso, as RNAs de saídas múltiplas apresentaram maior simplicidade de aplicação, de modo que a previsão da profundidade de água em dois ou mais locais de monitoramento foi realizada de forma simultânea com a utilização de apenas um modelo, o que pode ser uma possibilidade de reduzir o tempo e demanda computacional. Com o intuito de mapeamento de áreas inundáveis, Bermúdez et al. (2019) treinou 25.000 modelos SVR (*Support Vector Regression*) individuais e, em seguida, interpolou linearmente os resultados previstos para produzir os mapas de profundidade de água distribuídos em todo o domínio de simulação. Nesse caso, a utilização de modelos que fornecem respostas em locais simultaneamente seria uma forma de reduzir a demanda de trabalho.

Contudo, utilizar um único modelo para representação total do domínio de modelagem pode apresentar limitações. Para um domínio grande, pode não ser viável treinar um modelo separado para cada célula e uma abordagem de classificador global deve ser adotada, pois não seria possível fazer previsões para um domínio inteiro contendo milhões de células (KABIR; PATIDAR; PENDER, 2020). Portanto, ao escolher uma técnica de aprendizado de máquina deve-se ter em mente quais algoritmos existentes são adequados para cenários de saídas múltiplas – nesse quesito, as RNAs são modelos potencialmente úteis –, e também deve-se considerar o domínio espacial do problema.

Os gráficos de profundidade da água previstos pelas RNAs em comparação aos dados simulados pelo modelo hidrodinâmico indicaram a superioridade dos modelos de saídas múltiplas em relação aos modelos de saídas simples. Observou-se que os modelos de RNA de saídas simples apresentaram tendência a superestimar ou subestimar os valores máximos de profundidade da água. No entanto, quando utilizados os modelos de saídas múltiplas, a diferença entre os valores máximos de profundidade da água previstos

pela RNA e gerados pelo HEC-RAS foi menor ou quase nula, principalmente com relação a alcances de até 8 h. O que é um indicativo de que as RNAs de saídas múltiplas foram capazes de realizar melhores previsões do comportamento da profundidade de água durante o evento de inundação testado, sobretudo, devido à maior estabilidade proporcionada pelo modelo de saídas múltiplas que produziu erros menores do que os modelos de saídas simples.

Essa questão pode ter sua explicação relacionada à etapa de treinamento dos modelos, momento no qual é realizado o ajuste dos pesos sinápticos. No caso dos modelos de saídas múltiplas, os pesos sinápticos são ajustados para fornecer respostas simultaneamente eficientes para todas as saídas. Isso favorece o aprendizado do processo dinâmico em seu conjunto e pode evitar resultados discrepantes de saídas individuais, que não correspondem à totalidade do processo ou que contém erros decorrentes de um aprendizado com dados atípicos para aquela saída individual. Dessa forma, é obtido um treinamento eficiente para todas as saídas, semelhante a um treinamento “médio”.

É possível que os modelos de saídas múltiplas não produzam resultados individuais com a melhor precisão, mas são capazes de proporcionar maior estabilidade aos resultados no geral, ao reduzir os erros de maior magnitude. O ganho em estabilidade está diretamente relacionado ao ganho em confiabilidade, pois os erros, sempre presentes, foram menos extremos para os modelos de saídas múltiplas do que os produzidos por modelos de saídas simples.

A partir dos resultados obtidos, supõem-se que a utilização de saídas múltiplas na RNA produz um melhor aproveitamento, em sua estrutura de parâmetros internos, das relações físicas inerentes das variáveis de entrada, o que reflete em uma maior confiabilidade para os modelos de previsão. Além disso, corrobora a previsão de inundação de forma espacializada no domínio do problema, na qual as relações hidrodinâmicas existentes entre os locais de previsão, na escala temporal e espacial, podem ser compreendidas pela RNA. Essa é uma vantagem para previsões de inundações em áreas urbanizadas, onde interferências hidráulicas no comportamento hidrodinâmico do fluxo da água podem resultar em dificuldades e incertezas na modelagem empírica.

6 CONCLUSÕES

Esta pesquisa objetivou avaliar a aplicabilidade de RNAs para previsão da profundidade de água em planícies de inundação urbana, com o estudo de caso de Lages. A abordagem conceitual da pesquisa esteve baseada no escopo de um sistema de previsão e alerta, como uma das atividades no contexto do GDN. Um modelo hidrodinâmico foi utilizado para a obtenção dos dados de profundidade da água devido à ausência de dados de níveis fluviais observados. RNAs de saídas simples e RNAs de saídas múltiplas foram investigadas como meios de previsão das profundidades de água em locais distribuídos na planície inundável. Esses modelos foram estruturados para realizar previsões para alcances de 3 a 20 horas em oito locais de monitoramento distribuídos no domínio do problema.

A utilização de dados de profundidade de inundação gerados por simulação hidrodinâmica mostrou-se útil para o treinamento e verificação de RNAs com o objetivo de previsão. Uma vez que os dados utilizados são derivados de simulações 2D, as interações hidrodinâmicas do fluxo da água são consideradas pelas RNAs; assim, esses modelos podem ser capazes de assimilar a dinâmica de eventos de inundação com relativa precisão. Essa é uma oportunidade encorajadora para situações em que há falta de dados de monitoramento observados nas áreas sujeitas à inundação, sobretudo referente às áreas urbanas adjacentes aos rios.

A verificação dos modelos de RNAs de saídas simples teve resultados muito favoráveis. Para alcances de previsão de 6 h nos locais de monitoramento, as métricas de avaliação obtidas para NS; MAE, Pbias foram, em média, respectivamente, 0,989; 8,2 cm e -0.128%. Conforme as características dos eventos de inundação que ocorrem na área analisada, o tempo de antecedência de previsão alcançado com essa pesquisa é suficiente para atender ao Plano de Contingência de Proteção e Defesa Civil (PLACON), elaborado pela COMPDEC-LAGES.

A estratégia de previsão utilizada nesta pesquisa demonstrou potencial benefício para a previsão espacialmente distribuída das profundidades de inundação em áreas urbanas, como uma forma de qualificar o processo decisório no âmbito do GDN. Ao invés da previsão de níveis fluviais a montante da área atingida, é possível obter valores objetivos da profundidade da água em locais distribuídos na planície de inundação urbana. Assim, é possível aumentar a capacidade de resposta operacional para que as ações de ativação dos centros de atendimento, identificação das áreas que possivelmente serão

atingidas e de remoção dos moradores das áreas mais vulneráveis sejam realizadas com mais eficácia e rapidez.

A aplicabilidade das RNAs com saídas múltiplas foi evidenciada pelos resultados de desempenho obtidos na etapa de verificação dos modelos e na análise das profundidades de água simuladas pelo HEC-RAS e previstas pelas RNAs. Os modelos de RNA de saídas múltiplas foram capazes de prever os valores máximos de profundidade com melhores métricas de desempenho em comparação aos modelos de saídas simples. Os resultados obtidos para as métricas de desempenho, em especial para o E90, indicaram que os modelos de saídas múltiplas evitaram a ocorrência de variações drásticas no desempenho ao longo dos alcances avaliados.

A maior estabilidade proporcionada pelos modelos de saídas múltiplas aponta um caminho para utilização de modelos mais confiáveis para previsão de inundações em áreas urbanas. Os produtos gerados nesta pesquisa apresentam potencial para subsidiarem o desenvolvimento de sistemas de previsão e alerta a inundações mais eficientes, na medida em que exploram as vantagens dos modelos de base numérica e de base física. Essa pode ser uma abordagem válida para a previsão da profundidade de água de forma espacializada dentro do domínio do problema, o que possibilita aumentar a capacidade de resposta operacional no GDN.

7 RECOMENDAÇÕES

Esta pesquisa não esgotou a necessidade de mais estudos relacionados à utilização de Redes Neurais Artificiais para previsão de inundações na região analisada. Os principais pontos que podem ser considerados em pesquisas futuras são apresentados nesta seção.

Uma limitação dos modelos de RNAs é que o domínio de treinamento indica os limites da sua aplicação, característica comum aos modelos empíricos. Devido à falta de monitoramento hidrológico na região, é difícil dispor de séries históricas para estudos de inundação, dificultando o desenvolvimento de modelos para análises nesse contexto e por isso, foi escolhida a abordagem de treinamento por evento. No entanto, para que as condições sejam extrapoladas e seja possível abranger um maior domínio de características dos eventos de inundação, pode ser aconselhável treinar a rede para outros extremos, com o intuito de aumentar a capacidade de generalização da RNA. Além disso, é importante realizar a validação da metodologia como um todo a partir de dados observados de profundidades de inundação e, também, realizar a validação da extensão da mancha de inundação dos eventos.

A partir dos resultados obtidos com a experimentação de modelos de RNAs de saídas múltiplas, capazes de realizar previsões para dois ou três locais de monitoramento simultaneamente, mais pesquisas podem ser realizadas para análise de quantos locais simultâneos a RNA é capaz de prever mantendo um bom desempenho e, nesse sentido, se existe um limite a obtenção de um ajuste médio eficiente dos pesos sinápticos. O tamanho da área pode variar, já que essa estratégia foi aplicada, nesta pesquisa, para um domínio relativamente pequeno de abrangência de inundação.

Com relação à operacionalização do sistema, uma alternativa para aprimorar a capacidade operacional da Defesa Civil em resposta à eventos de inundação seria, a partir dos modelos de previsão estruturados nesta pesquisa, produzir uma quantidade de cenários, baseados em eventos passados, e configurar o sistema de alerta e o plano de contingências conforme os cenários projetados. Esses cenários podem ser construídos em parceria com a Defesa Civil e demais entidades envolvidas no GDN, o que proporciona familiaridade e maior agilidade na interpretação das informações, pois é importante o envolvimento desses atores no processo de desenvolvimento dos produtos que serão entregues a sociedade.

REFERÊNCIAS

- ACOSTA-COLL, M.; BALLESTER-MERELO, F.; MARTÍNEZ-PEIRÓ, M. Early warning system for detection of urban pluvial flooding hazard levels in an ungauged basin. **Natural Hazards**, [s. l.], v. 92, n. 2, p. 1237–1265, 2018. Available at: <https://doi.org/10.1007/s11069-018-3249-4>
- ALFIERI, L. *et al.* GloFAS-global ensemble streamflow forecasting and flood early warning. **Hydrology and Earth System Sciences**, [s. l.], v. 17, n. 3, p. 1161–1175, 2013. Available at: <https://doi.org/10.5194/hess-17-1161-2013>
- ALFIERI, Lorenzo *et al.* Operational early warning systems for water-related hazards in Europe. **Environmental Science and Policy**, [s. l.], v. 21, p. 35–49, 2012. Available at: <https://doi.org/10.1016/j.envsci.2012.01.008>
- ASCE. Criteria for Evaluation of Watershed Models. **Journal of Irrigation and Drainage Engineering**, [s. l.], v. 119, n. 3, p. 429–442, 1993. Available at: [https://doi.org/https://doi.org/10.1061/\(ASCE\)0733-9437\(1993\)119:3\(429\)](https://doi.org/https://doi.org/10.1061/(ASCE)0733-9437(1993)119:3(429))
- ASCE. Task Committee on Application of Artificial Neural Networks in Hydrology, Artificial Neural Networks in Hydrology. II:Hydrologic Application. **Journal of Hydrologic Engineering**, [s. l.], v. 5, n. 2, p. 124–137, 2000.
- AWCHI, T. A. River discharges forecasting in northern Iraq using different ANN techniques. **Water Resources Management**, [s. l.], v. 28, n. 3, p. 801–814, 2014. Available at: <https://doi.org/10.1007/s11269-014-0516-3>
- BABISTER, M.; BARTON, C. **Two dimensional Modelling in Urban and Rural Floodplains Revision Project**. [S. l.: s. n.], 2012.
- BELL, V. .; MOORE, R. J. The sensitivity of catchment runoff models to rainfall data at different spatial scales. **Hydrology and Earth System Sciences**, [s. l.], v. 4, n. 4, p. 653–667, 2000. Available at: <https://doi.org/https://doi.org/10.5194/hess-4-653-2000>, 2000.
- BELLOS, V.; TSAKIRIS, G. A hybrid method for flood simulation in small catchments combining hydrodynamic and hydrological techniques. **Journal of Hydrology**, [s. l.], v. 540, p. 331–339, 2016. Available at: <https://doi.org/10.1016/j.jhydrol.2016.06.040>
- BERKHAHN, S.; FUCHS, L.; NEUWEILER, I. An ensemble neural network model for real-time prediction of urban floods. **Journal of Hydrology**, [s. l.], v. 575, n. February, p. 743–754, 2019. Available at: <https://doi.org/10.1016/j.jhydrol.2019.05.066>
- BERMÚDEZ, M. *et al.* Development and Comparison of Two Fast Surrogate Models for Urban Pluvial Flood Simulations. **Water Resources Management**, [s. l.], v. 32, p. 2801–2815, 2018. Available at: <https://doi.org/https://doi.org/10.1007/s11269-018-1959-8>
- BERMÚDEZ, M.; CEA, L.; PUERTAS, J. A rapid flood inundation model for hazard mapping based on least squares support vector machine regression. **Journal of Flood Risk Management**, [s. l.], v. 12, n. July 2017, p. 1–14, 2019. Available at: <https://doi.org/10.1111/jfr3.12522>
- BOBOC, N. *et al.* Utilization of HEC-RAS for flood wave modelling on example of Prut River. **Geographia Napocensis**, [s. l.], v. 2, n. October 2012, p. 71–76, 2016.

- BRAGA, A. de P.; LUDEMIR, T. B.; CARVALHO, A. C. F. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: [s. n.], 2007.
- BRUEN, M.; YANG, J. Combined Hydraulic and Black-Box Models for Flood Forecasting in Urban Drainage Systems. **Journal of Hydrologic Engineering**, [s. l.], v. 11, n. 6, p. 589–596, 2006. Available at: [https://doi.org/10.1061/\(asce\)1084-0699\(2006\)11:6\(589\)](https://doi.org/10.1061/(asce)1084-0699(2006)11:6(589))
- BRUNNER, G. W.; CEIWR-HEC. **HEC-RAS River Analysis System: User Manual 1D and 2D Version 5.0**. [S. l.: s. n.], 2016. Available at: www.hec.usace.army.mil
- CANHOLI, A. P. **Drenagem Urbana e Controle de Enchentes**. 2. ed. São Paulo: Oficina Textos, 2014.
- CARTER, W. N. **Disaster Management A Disaster Manager's Handbook**. [S. l.: s. n.], 2008. ISSN 978-971-561-006-3. *E-book*.
- CASTRO, A. L. C. **Manual de planejamento estratégico em Defesa Civil**. [S. l.: s. n.], 1999.
- CEPED-UFSC. **Atlas Brasileiro de Desastres Naturais 1991 a 2012**. Florianópolis: CEPED UFSC, 2013. Available at: <http://150.162.127.14:8080/atlas/AtlasPernambuco.pdf>
- CHU, H. *et al.* An ANN-based emulation modelling framework for flood inundation modelling : Application , challenges and future directions. **Environmental Modelling and Software**, [s. l.], v. 124, 2020. Available at: <https://doi.org/10.1016/j.envsoft.2019.104587>
- COETZEE, C.; VAN NIEKERK, D. Tracking the evolution of the disaster management cycle: A general system theory approach. **Jàmá: Journal of Disaster Risk Studies**, [s. l.], v. 4, n. 1, p. 1–9, 2012. Available at: <https://doi.org/10.4102/jamba.v4i1.54>
- COLLISCHONN, W.; TASSI, R. **Introduzindo a Hidrologia**. Porto Alegre: IPH (Instituto de Pesquisas Hidráulicas/UFRGS), 2008.
- COLLISCHONN, Walter; DORNELLES, F. **Hidrologia para engenharia e ciências ambientais**. Porto Alegre: [s. n.], 2013.
- COMPDEC, C. M. de P. e D. C. **Plano de Contingência de Proteção e Defesa Civil**. Lages: [s. n.], 2018.
- COPPOLA, D. P. The management of Disasters. *In*: COPPOLA, D. P. (org.). **Introduction to International Disaster Management**. 3. ed. [S. l.]: Butterworth-Heinemann, 2015. p. 760. Available at: <https://doi.org/10.1016/b978-0-12-817368-8.00001-4>
- COSTABILE, P.; MACCHIONE, F. Enhancing river model set-up for 2-D dynamic flood modelling. **Environmental Modelling and Software**, [s. l.], v. 67, p. 89–107, 2015. Available at: <https://doi.org/10.1016/j.envsoft.2015.01.009>
- COTTRELL, M. *et al.* Neural Modeling for Time Series: A Statistical Stepwise Method for Weight Elimination. **IEEE Transactions on Neural Networks**, [s. l.], v. 6, n. 6, p. 1355–1364, 1995. Available at: <https://doi.org/10.1109/72.471372>
- D. N. MORIASI *et al.* Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. **Transactions of the ASABE**, [s. l.], v. 50, n. 3, p.

885–900, 2007. Available at: <https://doi.org/10.13031/2013.23153>

DEBASTIANI, A. **Desempenho De Redes Neurais Artificiais E Árvores De Regressão Na Modelagem Do Processo Chuva-vazão Da Bacia Do Alto Canoas**. 88 f. 2016. - Universidade do Estado de Santa Catarina (UDESC), [s. l.], 2016.

DIKSHIT, A.; PRADHAN, B.; ALAMRI, A. M. Pathways and challenges of the application of artificial intelligence to geohazards modelling. **Gondwana Research**, [s. l.], p. 12, 2020. Available at: <https://doi.org/10.1016/j.gr.2020.08.007>

DORNELLES, F. Previsão Contínua De Níveis Fluviais Com Redes Neurais Utilizando Previsão De Precipitação. [s. l.], p. 291, 2007.

ECKHARDT, R. R. **GERAÇÃO DE MODELO CARTOGRÁFICO APLICADO AO MAPEAMENTO DAS ÁREAS SUJEITAS ÀS INUNDAÇÕES URBANAS NA CIDADE DE LAJEADO / RS**. 116 f. 2008. - Universidade Federal do Rio Grande do Sul, [s. l.], 2008. Available at: lume.ufrgs.br/handle/10183/13755

EMBRAPA, E. B. de P. A. **Solos do Estado de Santa Catarina: Boletim de Pesquisa e Desenvolvimento**. Rio de Janeiro: Embrapa Solos, 2004. Available at: <file:///C:/Users/Philco/Downloads/BPD-46-2004-Santa-Catarina-.pdf>

FINCK, J. S. **PREVISÃO EM TEMPO ATUAL DE NÍVEIS FLUVIAIS COM REDES NEURAIIS ARTIFICIAIS: Aplicação à bacia do rio Taquari-Antas/RS**. 2020. - Universidade Federal do Rio Grande do Sul, [s. l.], 2020.

GOERL, R. F.; MICHEL, G. P.; KOBIYAMA, M. Mapeamento de áreas susceptíveis a inundação com o modelo HAND e análise do seu desempenho em diferentes resoluções espaciais. **Revista Brasileira de Cartografia**, [s. l.], v. 69, p. 61–69, 2017.

GUASSELLI, L. A. *et al.* MODELAGEM HIDROLÓGICA E ESPACIALIZAÇÃO DE ÁREAS SUSCETÍVEIS ÀS INUNDAÇÕES NO MUNICÍPIO DE IGREJINHA , RS. **Geo UERJ**, [s. l.], n. 28, p. 353–380, 2016. Available at: <https://doi.org/10.12957/geouerj.2016.10984>

GUHA-SAPIR, D.; VOS, F.; BELOW, R. Annual disaster statistical review 2011. ... of **Disasters**, [s. l.], p. 52, 2012. Available at: http://cred.be/sites/default/files/2012.07.05.ADSR_2011.pdf

HANDMER, J. W. (viaf)64089799; PENNING-ROWSELL, E. C. **Hazards and the communication of risk**. [S. l.]: Aldershot (Hants) : Gower technical press, 1990. *E-book*.

HAPUARACHCHI, H. A. P.; WANG, Q. J.; PAGANO, T. C. A review of advances in flash flood forecasting. **Hydrological Processes**, [s. l.], v. 25, n. 18, p. 2771–2784, 2011. Available at: <https://doi.org/10.1002/hyp.8040>

HECHT-NIELSEN, R. Kolmogorov'S Mapping Neural Network Existence Theorem. *In: , 1987, San Diego. (IEEE & I. C. on N. Networks, Org.)* **Proceedings of the international conference on Neural Networks**. San Diego: IEEE Press New York, 1987. p. 11–14.

HECHT-NIELSEN, R. **Neurocomputing**. 1ªed. Boston: Addison-Wesley, 1990.

HENONIN, J. *et al.* Real-time urban flood forecasting and modelling - A state of the art. **Journal of Hydroinformatics**, [s. l.], v. 15, n. 3, p. 717–736, 2013. Available at:

<https://doi.org/10.2166/hydro.2013.132>

HICKS, F. E.; PEACOCK, T. Suitability of HEC-RAS for Flood Forecasting Suitability of HEC-RAS for Flood Forecasting. **Canadian Water Resources Journal**, [s. l.], v. 30, n. 2, p. 159–174, 2005. Available at: <https://doi.org/10.4296/cwrj3002159>

HU, M. J. C. **Application in the Adaline system to weather forecasting**. 1964. - Stanford, [s. l.], 1964.

IVANOV, V. Y. *et al.* Catchment hydrologic response with a fully distributed triangulated irregular network model. **Water Resources Research**, [s. l.], v. 40, n. 11, p. 1–23, 2004. Available at: <https://doi.org/10.1029/2004WR003218>

JHONG, B.; WANG, J.; LIN, G. An integrated two-stage support vector machine approach to forecast inundation maps during typhoons. **Journal of Hydrology**, [s. l.], v. 547, p. 236–252, 2017. Available at: <https://doi.org/10.1016/j.jhydrol.2017.01.057>

KABIR, S. *et al.* A deep convolutional neural network model for rapid prediction of fluvial flood inundation. **Journal of Hydrology**, [s. l.], v. 590, n. June, 2020. Available at: <https://doi.org/10.1016/j.jhydrol.2020.125481>

KABIR, S.; PATIDAR, S.; PENDER, G. A Machine Learning Approach for Forecasting and Visualizing Flood Inundation Information. **Proceedings of the Institution of Civil Engineers - Water Management**, [s. l.], p. 1–29, 2020. Available at: <https://doi.org/10.1680/jwama.20.00002>

KHALFALLAH, C. Ben; SAIDI, S. Spatiotemporal floodplain mapping and prediction using HEC-RAS - GIS tools : Case of the Mejerda river, Tunisia. **Journal of African Earth Sciences**, [s. l.], v. 142, p. 44–51, 2018. Available at: <https://doi.org/10.1016/j.jafrearsci.2018.03.004>

KITANIDIS, P. K.; BRAS, R. L. **Real time forecasting of river flows**. Cambridge: MIT Press, 1978.

KNEBL, M. R. *et al.* Regional scale flood modeling using NEXRAD rainfall, GIS, and HEC-HMS/ RAS: A case study for the San Antonio River Basin Summer 2002 storm event. **Journal of Environmental Management**, [s. l.], v. 75, n. 4, p. 325–336, 2005. Available at: <https://doi.org/10.1016/j.jenvman.2004.11.024>

KOBIYAMA, M. *et al.* **Prevenção de Desastres Naturais - Conceitos básicos**. 1. ed. [S. l.]: Organic Trading, 2006. v. 1

KOURGIALAS, N. N.; KARATZAS, G. P. Flood management and a GIS modelling method to assess flood-hazard areas—a case study. **Hydrological Sciences Journal**, [s. l.], v. 56, n. 2, p. 212–225, 2011. Available at: <https://doi.org/10.1080/02626667.2011.555836>

KRZYSZTOFOWICZ, R. A theory of flood warning systems. **Water Resources Research**, [s. l.], v. 29, n. 12, p. 3981–3994, 1993. Available at: <https://doi.org/10.1029/93WR00961>

LAPEDES, A. S.; FARBER, R. Nonlinear Signal Processing using Neural Networks: Prediction and System Modelling. In: , 1987, San Diego. **IEEE international conference on neural networks**. San Diego: [s. n.], 1987. Available at: <https://www.osti.gov/biblio/5470451-nonlinear-signal-processing-using-neural-networks-prediction-system-modelling>

- LEONARD, M. *et al.* A compound event framework for understanding extreme impacts. **WIREs Clim Change**, [s. l.], v. 5, n. February, p. 16, 2014. Available at: <https://doi.org/10.1002/wcc.252>
- LINTOTT, C. M. HEC-RAS 2D-An accessible and capable modelling tool. *In:* , 2017. **Water New Zealand's 2017 Stormwater Conference**. [S. l.: s. n.], 2017. p. 20. Available at: https://www.waternz.org.nz/Attachment?Action=Download&Attachment_id=2515
- LIZ, M. S. M. de. **Influência do rio Caveiras nas inundações dos rios Carahá e Ponte Grande**. 161 f. 2018. - Universidade do Estado de Santa Catarina (UDESC), [s. l.], 2018.
- LUCCHESI, L. V.; DE OLIVEIRA, G. G.; PEDROLLO, O. C. Attribute selection using correlations and principal components for artificial neural networks employment for landslide susceptibility assessment. **Environmental Monitoring and Assessment**, [s. l.], v. 192, n. 2, 2020. Available at: <https://doi.org/10.1007/s10661-019-7968-0>
- MACCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, [s. l.], v. 5, p. 115–133, 1943.
- MACEDO, P. A. O. y E. S. Procesos y riesgos geológicos. **Ii Curso Internacional De Aspectos Geológicos De Protección Ambiental**, [s. l.], n. January 2005, p. 114–137, 1987.
- MACHADO, N. C. **Retroanálise da propagação decorrente da ruptura da barragem do fundão com diferentes modelos numéricos e hipóteses de simulação**. 188 f. 2017. - Universidade Federal de Minas Gerais (UFMG), [s. l.], 2017.
- MAKRAKIS, M. C. **Mapeamento e Análise de Áreas Suscetíveis a Inundações Do Município De Lages-SC**. 106 f. 2017. - Universidade Federal do Rio Grande do Sul (UFRGS), [s. l.], 2017.
- MALIK, M. I.; AHMAD, F. Flood Inundation Mapping and Risk Zoning of the Swat River Pakistan using HEC-RAS Model. **Lasbela. Uni. J. Sci**, [s. l.], v. 3, p. 45–52, 2014.
- MIGNOT, E.; LI, X.; DEWALS, B. Experimental modelling of urban flooding: A review. **Journal of Hydrology**, [s. l.], v. 568, p. 334–342, 2019. Available at: <https://doi.org/10.1016/j.jhydrol.2018.11.001>
- MILLER, J. D.; HUTCHINS, M. The impacts of urbanisation and climate change on urban flooding and urban water quality: A review of the evidence concerning the United Kingdom. **Journal of Hydrology: Regional Studies**, [s. l.], v. 12, n. June, p. 345–362, 2017. Available at: <https://doi.org/10.1016/j.ejrh.2017.06.006>
- MINNS, A. W.; HALL, M. J. Modélisation pluie-débit par des réseaux neuroneaux artificiels. **Hydrological Sciences Journal**, [s. l.], v. 41, n. 3, p. 399–417, 1996. Available at: <https://doi.org/10.1080/02626669609491511>
- MINSKY, M.; PAPERT, S. **Perceptrons: An introduction to computational geometry**. 1. ed. Cambridge (EUA): Cambridge Press, 1969.
- MISHRA, A. K.; COULIBALY, P. DEVELOPMENTS IN HYDROMETRIC NETWORK DESIGN: A REVIEW. **Reviews of Geophysics**, [s. l.], v. 47, n. 2, p. 1–24, 2009. Available at: <https://doi.org/10.1029/2007RG000243>.1.INTRODUCTION

- MODERN, I. M.; PHYSICS, I.; EXPERI-, T. A. Hebb, D. O. The organization of behavior: A neuropsychological theory. New York: John Wiley and Sons, Inc., 1949. 335 p. \$4.00. **Science Education**, [s. l.], v. 34, n. 5, p. 336–337, 1950. Available at: <https://doi.org/10.1002/sce.37303405110>
- MONTE, B. E. O. *et al.* Modelagem hidrológica e hidráulica aplicada ao mapeamento de áreas inundáveis. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 21, n. 1, p. 152–167, 2016. Available at: <https://doi.org/10.21168/rbrh.v21n1.p152-167>
- MONTE, B. E. O. *et al.* Terminology of natural hazards and disasters: A review and the case of Brazil. **International Journal of Disaster Risk Reduction**, [s. l.], v. 52, 2021. Available at: <https://doi.org/10.1016/j.ijdr.2020.101970>
- MORIASI, D. N. *et al.* Hydrologic and water quality models: Performance measures and evaluation criteria. **Transactions of the ASABE**, [s. l.], v. 58, n. 6, p. 1763–1785, 2015. Available at: <https://doi.org/10.13031/trans.58.10715>
- MOSAVI, A.; OZTURK, P.; CHAU, K. W. Flood prediction using machine learning models: Literature review. **Water (Switzerland)**, [s. l.], v. 10, n. 11, p. 1–40, 2018. Available at: <https://doi.org/10.3390/w10111536>
- MUTHUSAMY, M. *et al.* Understanding the effects of Digital Elevation Model resolution in urban fluvial flood modelling. **Journal of Hydrology**, [s. l.], v. 596, n. February, 2021. Available at: <https://doi.org/10.1016/j.jhydrol.2021.126088>
- NASH, J. E.; SUTCLIFFE, I. V. River flow forecasting through conceptual models Part I - A discussion of principles. **Journal of Hydrology**, [s. l.], v. 10, p. 282–290, 1970.
- NEAL, J. C. *et al.* Distributed whole city water level measurements from the Carlisle 2005 urban flood event and comparison with hydraulic model simulations. **Journal of Hydrology**, [s. l.], v. 368, n. 1–4, p. 42–55, 2009. Available at: <https://doi.org/10.1016/j.jhydrol.2009.01.026>
- NETO, S. L.; CORDEIRO, M. T. A. Análise do comportamento de sistemas urbanos por meio de componentes de sistemas hidrológicos. **GEOUSP: Espaço e Tempo (Online)**, [s. l.], v. 19, n. 1, p. 142–155, 2015. Available at: <https://doi.org/10.11606/issn.2179-0892.geousp.2015.99771>
- NETO, S. L. R.; RODRIGUES, M. A Taxonomy of Strategies for Developing Spatial Decision Support System. *In*: WOJTKOWSKI, W. .; WRYCZA, S.; ZUPANCIC, J. (org.). **Systems Development Methods for Databases, Enterprise Modeling, and Workflow Management**. Boston: Springer, 1999. p. 139–155. Available at: https://doi.org/https://doi.org/10.1007/978-1-4615-4261-2_9
- NETO, Silvio Luis Rafaeli. **Meta 2 - Estudo Hidrológico: Modelagem Hidrológica**. Lages: [s. n.], 2019a.
- NETO, Silvio Luis Rafaeli. **Meta 2 – Estudo Hidrológico: Volumes e Tempos de Recorrência UDESC/CAV**. Lages: [s. n.], 2019b.
- NETO, Silvio Luis Rafaeli. **Um modelo conceitual de sistema de apoio à decisão espacial para gestão de desastres por inundações**. 234 f. 2000. - Universidade de São Paulo, [s. l.], 2000.
- NETO, Sílvia Luis Rafaeli. **Meta 4 - Modelagem Hidrodinâmica: Cenários I e II**. Lages: [s. n.], 2019c.

NETO, Sílvio Luis Rafaeli. **Meta 7 - Geoprocessamento: Aerolevantamento da Planície Topográfica de Inundações**. Lages: [s. n.], 2019d.

NETO, Sílvio Luis Rafaeli *et al.* Modelagem Hidráulica Dos Eventos De Inundações Em Lages (SC). *In:* , 2015, Porto Alegre. **VI Congresso Brasileiro de Gestão Ambiental**. Porto Alegre: IBEAS - Instituto Brasileiro de Estudos Ambientais, 2015. p. 1–7.

NETO, Sílvio Luís Rafaeli *et al.* Efficacy of Rainfall-Runoff Models in Loose Coupling Spatial Decision Support Systems Modelbase. **Water Resources Management**, [s. l.], v. 33, n. 3, p. 889–904, 2019. Available at: <https://doi.org/10.1007/s11269-018-2086-2>

OLIVEIRA, G. G. de *et al.* Simulações Hidrológicas com Diferentes Proporções de Área Controlada na Bacia Hidrográfica. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 18, n. 3, p. 193–204, 2013. Available at: <https://doi.org/10.21168/rbrh.v18n3.p193-204>

OLIVEIRA, G.; PEDROLLO, O.; CASTRO, N. O Desempenho das Redes Neurais Artificiais (RNAs) para Simulação Hidrológica Mensal. **Revista Brasileira de Recursos Hídricos**, [s. l.], v. 19, n. 2, p. 251–265, 2014. Available at: <https://doi.org/10.21168/rbrh.v19n2.p251-265>

PADILHA, V. L. **Modelagem Hidrológica orientada por eventos de inundação em Lages/SC**. 172 f. 2017. - Universidade do Estado de Santa Catarina (UDESC), [s. l.], 2017.

PAGANO, T. C. *et al.* Challenges of Operational River Forecasting. **Journal of Hydrometeorology**, [s. l.], v. 15, n. 4, p. 1692–1707, 2014. Available at: <https://doi.org/10.1175/jhm-d-13-0188.1>

PAIVA, R. C. D.; COLLISCHONN, W.; BUARQUE, D. C. Validation of a full hydrodynamic model for large-scale hydrologic modelling in the Amazon. **Hydrological Processes**, [s. l.], v. 27, n. 3, p. 333–346, 2011. Available at: <https://doi.org/10.1002/hyp>

PAN, T. *et al.* Hybrid neural networks in rainfall-inundation forecasting based on a synthetic potential inundation database. **Natural Hazards and Earth System Sciences**, [s. l.], v. 11, p. 771–787, 2011. Available at: <https://doi.org/10.5194/nhess-11-771-2011>

PAQUIER, A.; BAZIN, P. H. Estimating uncertainties for urban floods modelling. **La Houille Blanche**, [s. l.], n. 6, p. 13–18, 2014. Available at: <https://doi.org/10.1051/lhb/2014057>

PARKER, D.; FORDHAM, M. An evaluation of flood forecasting, warning and response systems in the European Union. **Water Resources Management**, [s. l.], v. 10, n. 4, p. 279–302, 1996. Available at: <https://doi.org/10.1007/BF00508897>

PEDROLLO, M. *et al.* ALERTA HIDROLÓGICO DA BACIA DO RIO CAÍ concepção e implantação do sistema. *In:* , 2011, Porto Alegre. **XIX Simpósio Brasileiro de Recursos Hídricos**. Porto Alegre: [s. n.], 2011. p. 1–14. Available at: bit.ly/39Merj9

PEDROLLO, O. C. Previsão de curto prazo de níveis com redes neurais artificiais para a cidade de Estrela (RS) : resultados preliminares. *In:* , 2017. **XXII Simpósio Brasileiro de Recursos Hídricos**. [S. l.: s. n.], 2017. p. 1–8. Available at:

<https://lume.ufrgs.br/handle/10183/173852>

PEDROLLO, O.; PEDROLLO, M. Sistema de alerta de cheias da bacia do rio Caí: Previsão de níveis com redes neurais artificiais. *In:* , 2013, Porto Alegre. (L. A. Guaselli, G. G. Oliveira, & R. de C. M. Alves, Org.) **Eventos Extremos no Rio Grande do Sul: inundações e movimentos de massa**. Porto Alegre: Evangraf, 2013. p. 101–120.

PÉREZ-SÁNCHEZ, J. *et al.* Evaluating Hydrological Models for Deriving Water Resources in Peninsular Spain. **Sustainability**, [s. l.], v. 11, n. 10, 2019. Available at: <https://doi.org/https://doi.org/10.3390/su11102872>

RANA, I. A. *et al.* Disaster management cycle and its application for flood risk reduction in urban areas of Pakistan. **Urban Climate**, [s. l.], v. 38, n. February, p. 1–12, 2021. Available at: <https://doi.org/10.1016/j.uclim.2021.100893>

REGO, T. L.; BARROS, J. R. Alagamentos E Inundações Em Goiânia: Uma Análise a Partir Da Imprensa Local E Dos Registros Da Defesa Civil. **Formação (Online)**, [s. l.], v. 1, n. 21, p. 170–185, 2014. Available at: <https://doi.org/10.33081/formação.v1i21.2358>

REILLY, D. L.; COOPER, L. N. An Overview of Neural Networks: Early Models to Real World Systems. **An Introduction to Neural and Eletronic Networks**, [s. l.], p. 300–321, 1990. Available at: https://doi.org/10.1142/9789812795885_0023

RIBEIRO, C. B. de M.; LIMA, R. N. de S. Simulação de inundações urbanas a partir da integração de técnicas de geoprocessamento à modelagem hidráulica e hidrológica. **Revista de Geografia**, [s. l.], v. 2, n. 1, p. 1–9, 2011.

RITTER, A.; MUÑOZ-CARPENA, R. Performance evaluation of hydrological models: Statistical significance for reducing subjectivity in goodness-of-fit assessments. **Journal of Hydrology**, [s. l.], v. 480, p. 33–45, 2013. Available at: <https://doi.org/10.1016/j.jhydrol.2012.12.004>

RJEILY, Y. A. *et al.* Flood forecasting within urban drainage systems using NARX neural network. **Water Science and Technology**, [s. l.], v. 76, n. 9, p. 2401–2412, 2017. Available at: <https://doi.org/10.2166/wst.2017.409>

ROSENBLATT, F. The Perceptron: A probabilist model for information storage and organization in the brain. **Psychological Review**, [s. l.], v. 65, n. 6, p. 386–408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning Internal Representations by Error Propagation. *In:* RUMELHART, D. E. ; MCCLELLAND, J. L. (org.). **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**. [S. l.]: MIT Press, 1986. v. 1, p. 318–362. Available at: <https://doi.org/10.7551/mitpress/5236.001.0001>

SAKSENA, S.; MERWADE, V. Incorporating the effect of DEM resolution and accuracy for improved flood inundation mapping. **Journal of Hydrology**, [s. l.], v. 530, p. 180–194, 2015. Available at: <https://doi.org/10.1016/j.jhydrol.2015.09.069>

SANTOS FINCK, J.; CORREA PEDROLLO, O. Facing Losses of Telemetric Signal in Real Time Forecasting of Water Level using Artificial Neural Networks. **Water Resources Management**, [s. l.], v. 35, n. 3, p. 1119–1133, 2021. Available at: <https://doi.org/10.1007/s11269-021-02782-x>

- SARI, V.; CASTRO, N. M. dos R.; PEDROLLO, O. C. Estimate of Suspended Sediment Concentration from Monitored Data of Turbidity and Water Level Using Artificial Neural Networks. **Water Resources Management**, [s. l.], v. 31, p. 4909–4923, 2017. Available at: <https://doi.org/10.1007/s11269-017-1785-4>
- SARTORI, A.; NETO, F. L.; GENOVEZ, A. M. Classificação Hidrológica de Solos Brasileiros para a Estimativa da Chuva Excedente com o Método do Serviço de Conservação do Solo dos Estados Unidos Parte 1 : Classificação. **RBRH - Revista Brasileira de Recursos Hídricos**, [s. l.], v. 10, n. 4, p. 5–18, 2005.
- SAVAGE, J. *et al.* Quantifying the importance of spatial resolution and other factors through global sensitivity analysis of a flood inundation model. **Water Resources Research**, [s. l.], v. 52, n. 11, p. 9146–9163, 2016. Available at: <https://doi.org/10.1002/2015WR018198>. Received
- SILVA, E. D. **Previsão Hidroeconômica de curto prazo com modelo de Redes Neurais Artificiais: Aplicação à Bacia do Rio Caí**. 131 f. 2019. - Universidade Federal do Rio Grande do Sul, [s. l.], 2019.
- SINGH, J. *et al.* Hydrological modeling of the Iroquois River watershed using HSPF and SWAT. **Journal of the American Water Resources Association**, [s. l.], v. 41, n. 2, p. 343–360, 2004. Available at: <https://doi.org/10.1111/j.1752-1688.2005.tb03740.x>
- ŠPITALAR, M. *et al.* Analysis of flash flood parameters and human impacts in the US from 2006 to 2012. **Journal of Hydrology**, [s. l.], v. 519, n. PA, p. 863–870, 2014. Available at: <https://doi.org/10.1016/j.jhydrol.2014.07.004>
- TAMIRU, H.; DINKA, M. O. Application of ANN and HEC-RAS model for flood inundation mapping in lower Baro Akobo River Basin, Ethiopia. **Journal of Hydrology: Regional Studies**, [s. l.], v. 36, p. 100855, 2021. Available at: <https://doi.org/10.1016/j.ejrh.2021.100855>
- TENG, J. *et al.* Flood inundation modelling: A review of methods, recent advances and uncertainty analysis. **Environmental Modelling and Software**, [s. l.], v. 90, p. 201–216, 2017. Available at: <https://doi.org/10.1016/j.envsoft.2017.01.006>
- TENG, J. *et al.* Rapid Inundation Modelling in Large Floodplains Using LiDAR DEM. **Water Resources Management**, [s. l.], v. 29, p. 2619–2636, 2015. Available at: <https://doi.org/10.1007/s11269-015-0960-8>
- TINH, N. Van. A Flood Forecasting Model Based on Artificial Neural Network. **East African Scholars J Eng Comput Sci**, [s. l.], v. 2, n. 10, p. 1249–1252, 2019. Available at: <https://doi.org/10.1109/carpi.2012.6356559>
- TUCCI, Carlos E M. Água No Meio Urbano. **Livro água doce**, [s. l.], p. 1–40, 1997.
- TUCCI, Carlos Eduardo Morelli. **Hidrologia: Ciência e aplicação**. 4. ed. Porto Alegre: ABRH, 2009.
- TUCCI, Carlos Eduardo Morelli. **Modelos hidrológicos**. 2. ed. Porto Alegre: Editora da Universidade/UFRGS, 2005. *E-book*.
- UNISDR. Developing Early Warning Systems : A Checklist. *In:* , 2006, Bonn, Germany. **Third International Conference on Early Warning**. Bonn, Germany: United Nations, 2006. p. 1–13.

UNISDR. **Terminology on Disaster Risk Reduction**. Geneva: United Nations, 2009.
Available at: <https://doi.org/10.1021/cen-v064n005.p003>

USACE, U. S. A. C. of E. **HEC-RAS - River Analysis System**. Davis, CA: Institute of Water Resources, 2016a.

USACE, U. S. A. C. of E. **Hydrologic Modeling System HEC-HMS: Users Manual**. Davis, CA: [s. n.], 2016b.

VOGL, T. P. *et al.* Accelerating the convergence of the back-propagation method. **Biological Cybernetics**, [s. l.], v. 59, n. 4–5, p. 257–263, 1988. Available at: <https://doi.org/10.1007/BF00332914>

WEI, Y. *et al.* Artificial neural network based predictive method for flood disaster. **Computers and Industrial Engineering**, [s. l.], v. 42, n. 2–4, p. 383–390, 2002.
Available at: [https://doi.org/10.1016/S0360-8352\(02\)00047-5](https://doi.org/10.1016/S0360-8352(02)00047-5)

WIDROW, B.; HOFF, M. E. Adaptive Switching Circuits. *In:* , 1960, Los Angeles. **IRE WESCON Convention Record**. Los Angeles: New York: Institute of Radio Engineers, 1960. p. 96–104.

ZHANG, G.; PATUWO, B.; HU, M. Forecasting with artificial neural networks: The state of the art. **International Journal of Forecasting**, [s. l.], v. 14, n. 1, p. 35–62, 1998. Available at: [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)

APÊNDICE B – DISTRIBUIÇÃO ESPACIAL DA CHUVA PARA A VAZÃO DE PICO DOS EVENTOS DE INUNDAÇÃO

Figura 1B - Distribuição espacial da chuva para a vazão de pico do evento de 2005.

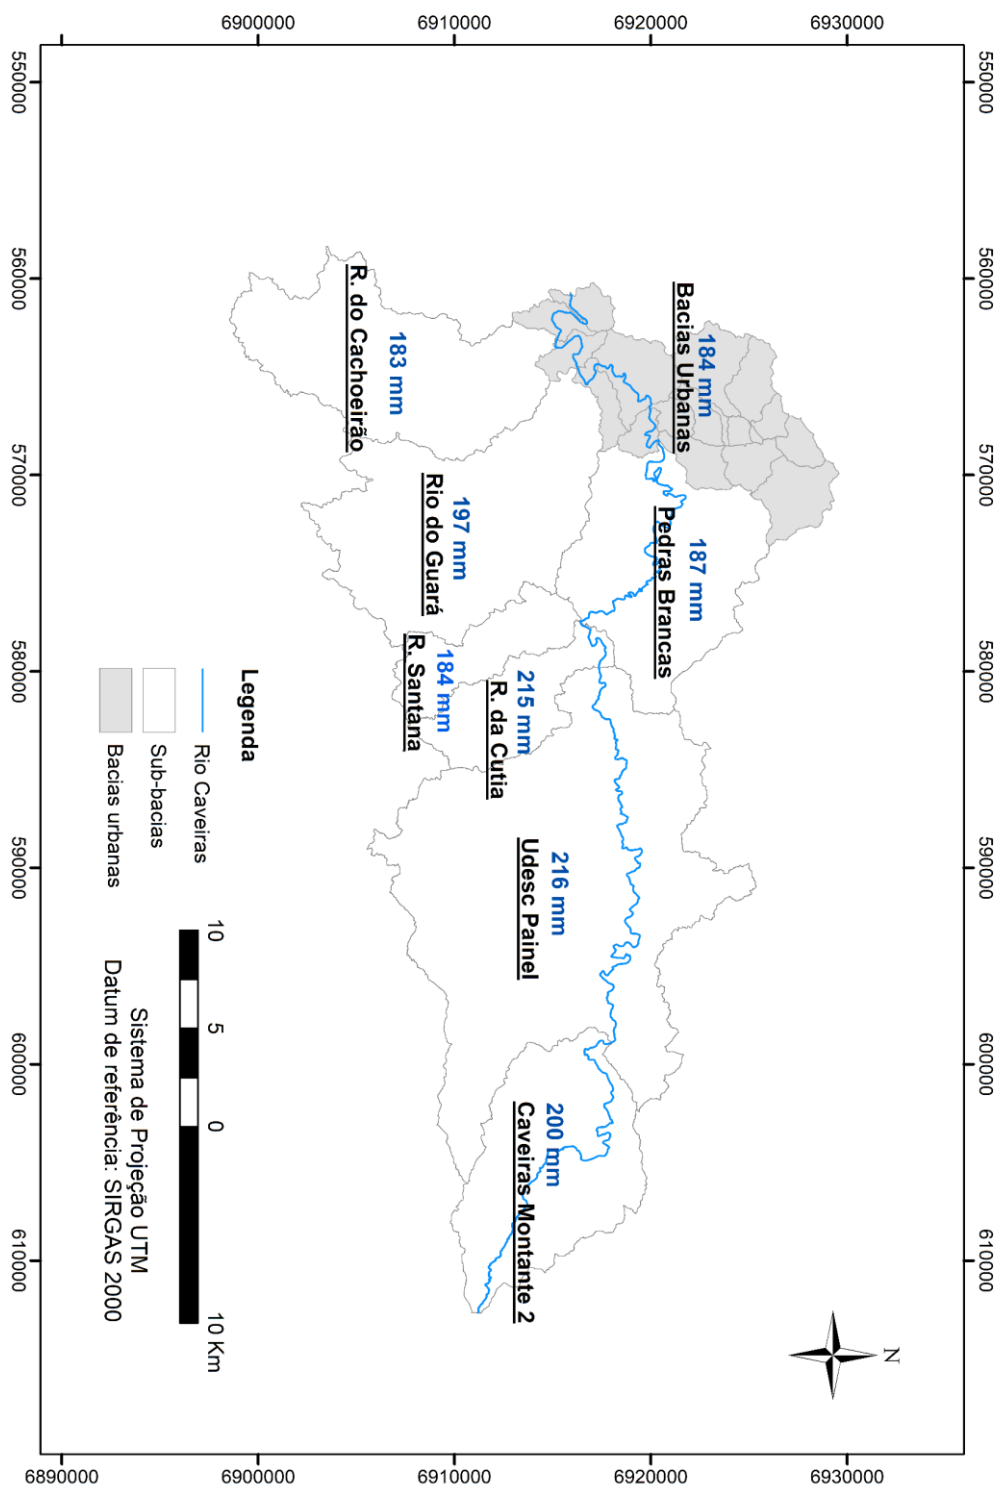


Figura 2B - Distribuição espacial da chuva para a vazão de pico do evento de 2011.

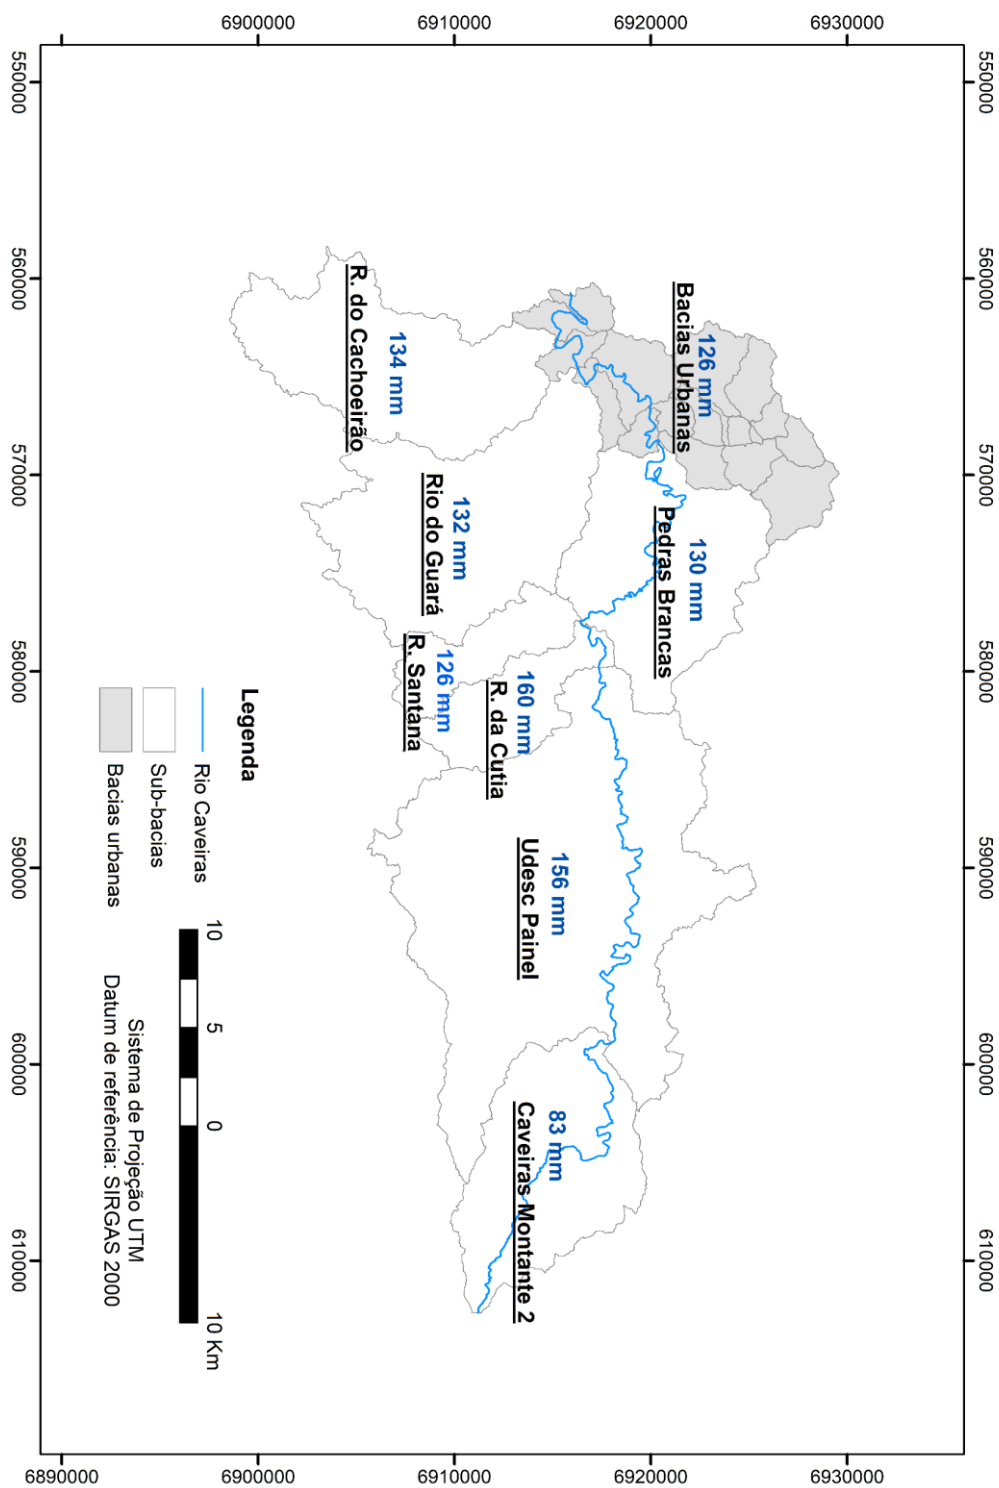
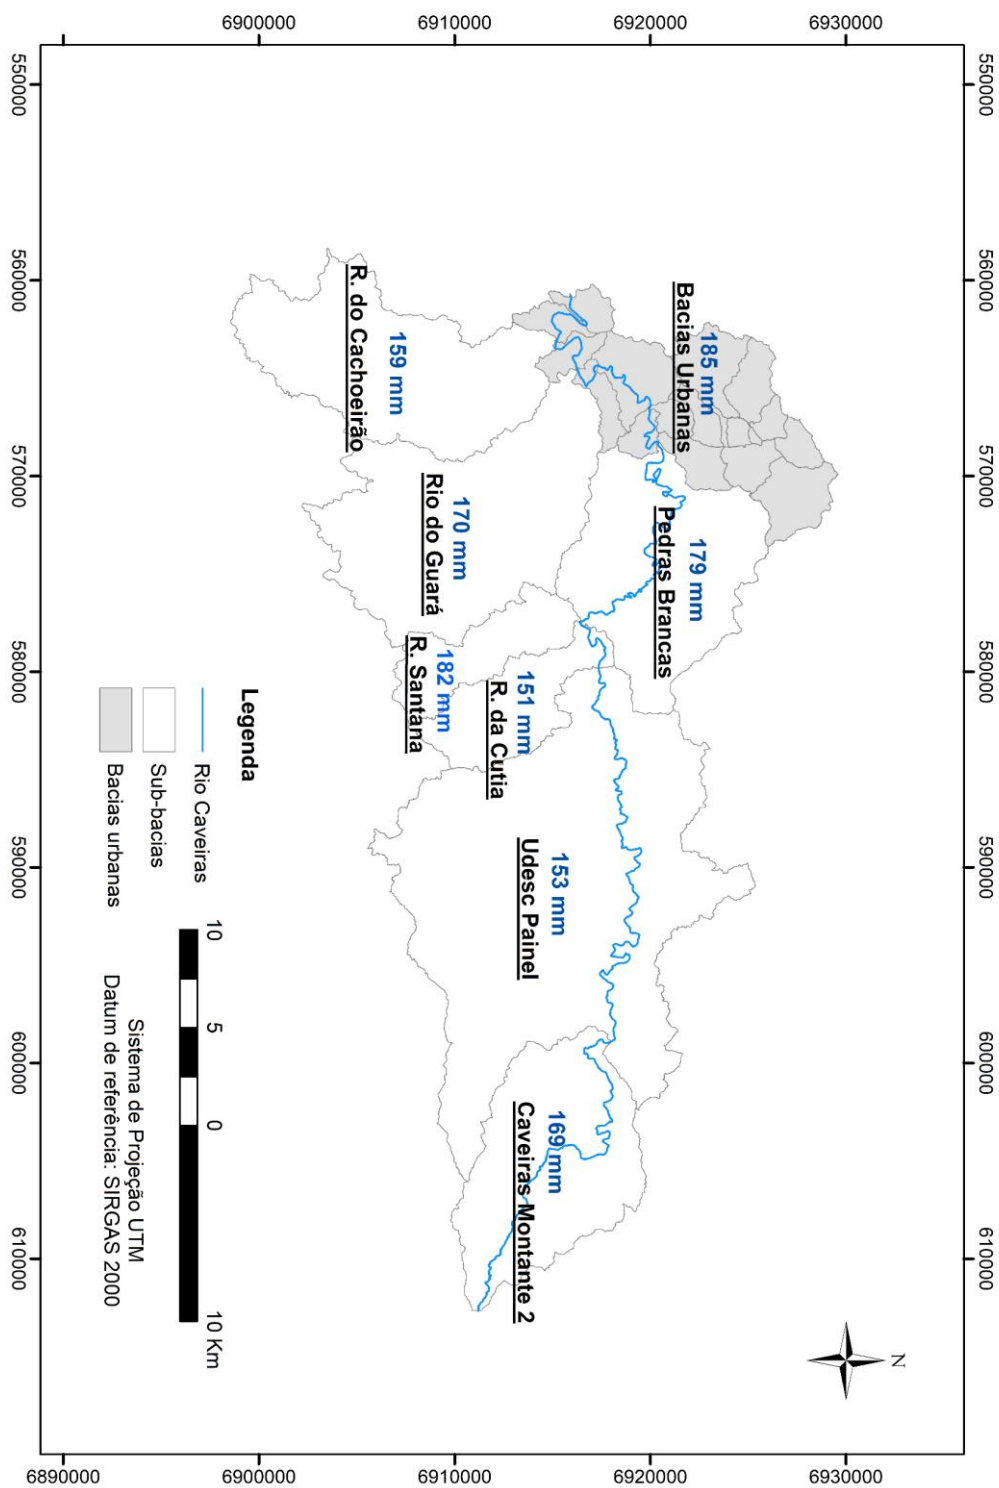


Figura 3B - Distribuição espacial da chuva para a vazão de pico do evento de 2017.



APÊNDICE C – PARÂMETROS UTILIZADOS PARA SIMULAÇÃO HIDROLÓGICA NO HEC-HMS

- Parâmetros da interceptação pela vegetação

Unidade Hidrológica	Max Canopy Storage (mm)
Aeroporto	4,44
Batalhão	1,78
Boqueirão	2,69
Caveiras Montante 2	3,82
Chácaras	2,91
Coração	2,84
Cotovelo	2,79
Duque de Caxias	4,68
Entre Rios	5,11
Ferrovia	3,79
Fórum Nereu Ramos	2,21
Passo Fundo	4,26
Pedras Brancas	7,67
Ponte Velha	2,04
Presidente Vargas	2,32
Reservatório	2,42
Ribeirão do Cachoeirão	7,59
Ribeirão da Cutia	4,23
Ribeirão Santana	7,40
Rio do Gurá	4,39
Rodovia BR-282	3,67
SC LA SR 03 CPRM	2,55
Tributo	3,68
Túnel	2,15
UDESC Paineis	3,37

Fonte: (NETO, 2019a)

- Parâmetros de armazenamento máximo nas depressões do terreno

Tabela 2C - Valores de armazenamento máximo nas depressões da superfície do terreno (mm) para as unidades hidrológicas da bacia hidrográfica do Sistema Ponte Velha.

Unidade Hidrológica	Max Storage (mm)
Aeroporto	8,87
Batalhão	2,11
Boqueirão	4,24
Caveiras Montante 2	11,31
Chácaras	4,43
Coração	10,27
Cotovelo	4,14
Duque de Caxias	2,6
Entre Rios	8,84
Ferrovia	9,03
Fórum Nereu Ramos	4,18
Passo Fundo	4,47
Pedras Brancas	13,04
Ponte Velha	10,49
Presidente Vargas	5,30
Reservatório	4,88
Ribeirão do Cachoeirão	12,38
Ribeirão da Cutia	11,57
Ribeirão Santana	11,13
Rio do Gurá	4,79
Rodovia BR-282	8,99
SC LA SR 03 CPRM	6,58
Tributo	8,30
Túnel	9,83
UDESC Painei	10,78

Fonte: (NETO, 2019a)

- Parâmetros de escoamento superficial direto

Tabela 3C – Valores de CN para as unidades hidrológicas da bacia hidrográfica do Sistema Ponte Velha

Unidade Hidrológica	CN	Taxa de impermeabilização
Aeroporto	65,75	15
Batalhão	66,13	64
Boqueirão	78,88	43
Caveiras Montante 2	79,13	2
Chácaras	93,77	20
Coração	71,97	2
Cotovelo	61,50	11
Duque de Caxias	88,01	64
Entre Rios	64,39	10
Ferrovia	80,75	43
Fórum Nereu Ramos	71,05	64
Passo Fundo	81,87	13
Pedras Brancas	56,46	3
Ponte Velha	65,85	5
Presidente Vargas	67,68	64
Reservatório	76,87	29
Ribeirão do Cachoeirão	78,21	2
Ribeirão da Cutia	53,05	3
Ribeirão Santana	75,38	2
Rio do Gurá	73,62	2,5
Rodovia BR-282	90,32	40
SC LA SR 03 CPRM	76,59	51
Tributo	81,11	20
Túnel	63,51	8
UDESC Paineis	70,16	2

Fonte: (NETO, 2019a)

- Parâmetros de escoamento base

Tabela 4C – Valores da constante de recessão (k) para as unidades hidrológicas da bacia hidrográfica do Sistema Ponte Velha

Unidade Hidrológica	k
Aeroporto	0,7245
Batalhão	0,7307
Boqueirão	0,7261
Caveiras Montante 2	0,8479
Chácaras	0,6385
Coração	0,7441
Cotovelo	0,872
Duque de Caxias	0,8371
Entre Rios	0,9396
Ferrovia	0,7751
Fórum Nereu Ramos	0,8958
Passo Fundo	0,5234
Pedras Brancas	0,8025
Ponte Velha	0,7256
Presidente Vargas	0,8759
Reservatório	0,6981
Ribeirão do Cachoeirão	0,7026
Ribeirão da Cutia	0,7664
Ribeirão Santana	0,7725
Rio do Gurá	0,7991
Rodovia BR-282	0,7121
SC LA SR 03 CPRM	0,9044
Tributo	0,7494
Túnel	0,8798
UDESC Paineel	0,9906

Fonte: (NETO, 2019a)

- Parâmetros da propagação da onda de cheia nos canais

Tabela 5C – Dados de entrada no modelo hidrológico utilizando o método de propagação de onda cheia de Muskingum-Cunge.

Canal	Initial Type	Initial Discharge (m ³ /s)	Lenght (m)	Slope (mm)	Manning`s (n)	Space-Time Method	Index Method	Index Flow (m ³ /s)	Shape	Width (m)
Trecho 1	Specified discharge	0,0081162	30188,33	0,012813	0,066	Auto Dx Auto Dy	Flow	2,7514	Trapezoid	50
Trecho 2	Specified discharge	0,0081162	19973,59	0,019627	0,066	Auto Dx Auto Dy	Flow	3,0309	Trapezoid	40
Trecho 3	Specified discharge	0,0081162	34938,49	0,09198	0,066	Auto Dx Auto Dy	Flow	3,9933	Trapezoid	20
Trecho 4	Specified discharge	0,0081162	9381,31	0,009532	0,066	Auto Dx Auto Dy	Flow	0,12627	Trapezoid	7
Trecho 5	Specified discharge	0,0081162	6055,74	0,011303	0,066	Auto Dx Auto Dy	Flow	0,17083	Trapezoid	7
Trecho 6	Specified discharge	0,0081162	6427,52	0,024563	0,066	Auto Dx Auto Dy	Flow	0,22028	Trapezoid	7
Trecho 7	Specified discharge	0,0081162	5672,85	0,027419	0,066	Auto Dx Auto Dy	Flow	4,0222	Trapezoid	30
Trecho 8	Specified discharge	0,0081162	3707,74	0,028398	0,066	Auto Dx Auto Dy	Flow	0,0772848	Trapezoid	5
Trecho 9	Specified discharge	0,0081162	1488,28	0,031495	0,066	Auto Dx Auto Dy	Flow	0,0804428	Trapezoid	5
Trecho 10	Specified discharge	0,0081162	2414,84	0,013563	0,066	Auto Dx Auto Dy	Flow	0,093223	Trapezoid	15
Trecho 11	Specified discharge	0,0081162	2037,22	0,017264	0,066	Auto Dx Auto Dy	Flow	0,18785	Trapezoid	17
Trecho 12	Specified discharge	0,0081162	3353,66	0,01341	0,066	Auto Dx Auto Dy	Flow	0,21902	Trapezoid	20
Trecho 13	Specified discharge	0,0081162	3357,09	0,008794	0,066	Auto Dx Auto Dy	Flow	0,24505	Trapezoid	20

Trecho 14	Specified discharge	0,0081162	8874,21	0,016195	0,066	Auto Dx Auto Dy	Flow	4,3693	Trapezoid	30
Trecho 15	Specified discharge	0,0081162	5872,66	0,020058	0,066	Auto Dx Auto Dy	Flow	5,4145	Trapezoid	30
Trecho 16	Specified discharge	0,0081162	8073,47	0,012847	0,066	Auto Dx Auto Dy	Flow	4,411	Trapezoid	40
Trecho 17	Specified discharge	0,0081162	6145,53	0,019835	0,066	Auto Dx Auto Dy	Flow	6,2244	Trapezoid	45
Trecho 18	Specified discharge	0,0081162	3760,36	0,03888	0,066	Auto Dx Auto Dy	Flow	6,26	Trapezoid	45