**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE HIDRÁULICA E SANEAMENTO**

MARIA CLARA FAVA

**Modelo de Alerta Hidrológico com Base Participativa usando Sistema de Informações
Voluntárias para Previsão de Enchentes**

**Orientador:
Prof. Dr. Eduardo Mario Menciondo**

VERSÃO CORRIGIDA

**São Carlos, SP
Março, 2015**

MARIA CLARA FAVA

**Modelo de Alerta Hidrológico com Base Participativa usando Sistema de Informações
Voluntárias para Previsão de Enchentes**

*Dissertação apresentada à Escola de Engenharia de
São Carlos, da Universidade de São Paulo, como
parte dos requisitos para obtenção do título de
Mestre em Ciências: Engenharia Hidráulica e
Saneamento.*

VERSÃO CORRIGIDA

**São Carlos, SP
Março, 2015**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

F272m Fava, Maria Clara
Modelo de Alerta Hidrológico com Base Participativa
Usando Sistema de Informações Voluntárias para Previsão
de Enchentes / Maria Clara Fava; orientador Eduardo
Mario Menciondo. São Carlos, 2015.

Dissertação (Mestrado) - Programa de Pós-Graduação
e Área de Concentração em Hidráulica e Saneamento --
Escola de Engenharia de São Carlos da Universidade de
São Paulo, 2015.

1. Enchentes. 2. Previsão Hidrometeorológica. 3.
Informações Geográficas Voluntárias. 4. SWMM. I.
Título.

FOLHA DE JULGAMENTO

Candidata: Bacharela **MARIA CLARA FAVA**.

Título da dissertação: "Modelo de alerta hidrológico com base participativa usando sistema de informações voluntárias para previsão de enchentes".

Data da defesa: 27/03/2015

Comissão Julgadora:

Resultado:

Prof. Dr. **Eduardo Mario Mendiando**
(Orientador)
(Escola de Engenharia de São Carlos/EESC)

Aprovado

Prof. Dr. **João Porto de Albuquerque Pereira**
(Instituto de Ciências Matemáticas e de Computação/ICMC)

Aprovado

Dra. **Luz Adriana Cuartas Pineda**
(Centro Nacional de Monitoramento e Alertas de Desastres Naturais/CEMADEN)

Aprovado

Coordenadora do Programa de Pós-Graduação em Engenharia Hidráulica e Saneamento:
Profa. Associada **Maria Bernadete A. Varesche Silva**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Paulo César Lima Segantine**

DEDICATÓRIA

Aos meus pais, Maria Evaneide de Jesus Fava e Sidnei da Silva Fava por todo o amor, apoio e incentivo. Sendo eles minha eterna motivação para buscar ser alguém melhor.

AGRADECIMENTOS

Agradeço primeiramente aos meus pais, quem proporcionaram a oportunidade e os meios de estar aqui em São Carlos para a realização do meu Mestrado. Por sempre me incentivarem e aconselharem nos momentos difíceis e por sempre vibrarem junto comigo com as conquistas.

Ao meu irmão Aldo Felipe Fava pela amizade, incentivo e carinho de sempre. Por me ouvir e sempre torcer por mim. Por ser meu exemplo de pessoa boa e calma.

Ao meu namorado Carlos Alberto Monaco Neto pelo apoio e compreensão apesar da distância. Por ter me incentivado a ir atrás dessa realização, pela amizade, amor e carinho de sempre.

Ao meu orientador Eduardo Mario Mendiando, pela amizade e confiança depositada em mim. Por me ajudar a solucionar problemas desde antes do meu ingresso no PPG-SHS. Pelas muitas horas de orientação e por sempre ter se feito presente apoiando meu projeto, tirando dúvidas, resolvendo impasses durante a pesquisa e sempre me incentivando a buscar mais e melhores soluções.

Ao professor Vladimir Caramori B. de Souza pela orientação e contribuição na concepção inicial e desenvolvimento da minha pesquisa.

Ao meu amigo Narumi, quem me incentivou a seguir na área de pesquisa desde a minha iniciação científica. Por ter me impulsionado e ajudado a vir para São Carlos fazer o mestrado. Por ter me ajudado em todas as etapas da minha pesquisa, como amigo incentivador e também com sua ajuda intelectual.

Aos meus amigos de casa de São Carlos: Déia, Rê, Si, Aline, Lafa, Leite e Lucas. Obrigada por se tornarem minha família de São Carlos. Obrigada pelo apoio, incentivo e cuidados quando precisei.

As minhas amigas najas, cada uma seguindo seu caminho pós graduação, mas sendo amigas e apoios constantes. A todos os meus amigos de longa data, graduação e Nioaque.

Aos meus colegas de laboratório, integrantes e ex-integrantes do NIBH: Altair, Danie, Dulce, Denise, Guilherme, Gustavo, Jairo, Diego, Camilo, Aline e Narumi. Obrigada por todo o apoio tanto emocional como intelectual, por ajudarem na elucidação de muitos problemas e na realização de muitas tarefas, pela amizade e diversão no cotidiano do laboratório e por tornarem a jornada do Mestrado muito mais divertida.

A todos os funcionários e professores do departamento de Hidráulica e Saneamento. Em especial a Sá e Priscila por toda atenção e ajuda prestados.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pela bolsa concedida.

RESUMO

FAVA, M. C. (2015). *Modelo de Alerta Hidrológico com Base Participativa usando Sistema de Informações Voluntárias para Previsão de Enchentes*. São Carlos, 100p. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

Este trabalho apresenta uma nova proposta metodológica de previsão de enchentes: o Modelo de Alerta Hidrológico com Base Participativa (MAHP). O MAHP consiste em um modelo de previsão de enchentes em bacias urbanas que integra Informações Geográficas Voluntárias (VGI) e redes de sensores sem fio (WSN). A principal contribuição deste modelo é o uso de dados de fontes heterogêneas (sensores aliados a dados fornecidos por voluntários) com o objetivo de reduzir a incerteza na previsão de enchentes. O modelo MAHP foi dividido em módulos, cada um deles é responsável por uma atividade no processo de previsão de enchentes. Embora o modelo possua diversos módulos auxiliares, pode-se resumir o modelo MAHP em três módulos principais: aquisição de dados; previsão de precipitações e, por fim, o módulo responsável pela previsão das enchentes. Para o módulo de aquisição de dados foram desenvolvidas metodologias para uso de dados voluntários de nível da água e sensores medidores de nível foram instalados para a composição da rede de sensores sem fio em pontos estratégicos nos canais fluviais da cidade. No módulo de previsão da precipitação do modelo MAHP foram desenvolvidos dois *softwares* de previsão, sendo um modelo de previsão da precipitação conceitual e um empírico. Para o funcionamento do módulo responsável pela previsão das enchentes foi feita a modelagem da bacia urbana de São Carlos no modelo SWMM (*Storm Water Management Model*). As simulações chuva-vazão realizadas com a bacia modelada apresentaram ajustes satisfatórios quando comparadas com eventos de enchente reais. Como o uso de informações voluntárias na previsão de enchentes é um conceito bastante novo, outra importante contribuição do trabalho foi propor parâmetros espaço-temporais que influenciam na qualidade da previsão ocasionada pelo uso de dados VGI. Existem vários cenários e combinações de uso de informações voluntárias que podem influenciar na previsão de enchentes. Neste trabalho foi considerada apenas uma destas combinações. Devido à ausência de dados VGI reais em eventos de enchente recentes foram utilizados dados de nível medidos por sensores para simular dados voluntários. Foram levantadas diversas hipóteses para que a inserção de dados voluntários no modelo MAHP tenham maior influência na redução da incerteza na previsão de enchentes.

Palavras-chave: Enchentes, Previsão Hidrometeorológica, Informações Geográficas Voluntárias, SWMM.

ABSTRACT

FAVA, M. C. (2015). *Participative-Based Early Warning Model using Volunteer Geographic Information Systems for Flood Forecasting*. São Carlos, 100p. M. Sc. Dissertation. School of Engineering at São Carlos, University of São Paulo, São Carlos, Brazil.

This work presents a new approach for flood forecasting: Hydrological Alert Model with Participatory Base (HAMPB). The HAMPB consists of a flood forecasting model applied to urban basins integrating Volunteered Geographic Information (VGI) and Wireless Sensor Networks (WSN). The main contribution of this model is the use of heterogeneous data sources (conventional sensors and volunteered data) aiming to reduce the uncertainty in the flood forecasting. The HAMPB model was divided in modules, which are responsible for the forecasting process activities. The

Although the model has multiple auxiliary modules, we can summarize the HAMPB model in three modules: data acquisition; rainfall forecasting and, finally, the module responsible for flood forecasting. Telemetric water level sensors were installed at strategic points in river channels of the city to create the WSN. In order to use the volunteered information, a methodology was proposed to develop the acquisition module. The rainfall forecasting module consists of two forecasting models: an empirical model and a conceptual model. The conceptual prediction model presented closest predictions of observed rainfall compared to the forecast of the empirical model. In order to apply the flood forecasting methodology, we modelled the urban basin of São Carlos using SWMM model. The rainfall-runoff simulations performed with the basin model showed satisfactory adjustments compared with actual flood events. Since the use of voluntary information on flood forecasting is a fairly new concept, another important contribution of this work was the proposition of spatiotemporal parameters that influence on the forecast caused by the use of VGI data.

There are many scenarios and combinations which using volunteered information can be helpful in the flood forecasting. In this work we consider only one combination. Due to absence of real volunteered data, we use sensor data to simulate VGI data. Several hypotheses have been raised to the inclusion of volunteers in HAMPB data model to produce more relevant results than using traditional methods of forecasting.

Key-words: Flooding, Hidrometeorological Forecasting, Volunteered Geographic Information, SWMM.

LISTA DE TABELAS

Tabela 1: Parâmetros de caracterização das sub-bacias no modelo SWMM.	41
Tabela 2: <i>Curve numbers</i> de escoamento para áreas urbanas.....	42
Tabela 3: Parâmetros de caracterização dos nós no modelo SWMM.....	42
Tabela 4: Parâmetros de caracterização dos trechos no modelo SWMM.....	43
Tabela 5: Referências para n de Manning em diferentes conformações.	44
Tabela 6: Ajuste dos parâmetros do modelo conceitual.	47
Tabela 7: Desvio das simulações.	54
Tabela 8: Desvio das simulações	57
Tabela 9: Características das sub-bacias inseridas no SWMM.	86
Tabela 10: Características dos trechos inseridas no SWMM.	87

LISTA DE FIGURAS

Figura 1: Síntese dos objetivos, metodologias e resultados do trabalho.	4
Figura 2: Exemplo de previsão hidrológica por conjunto. (Cloke & Pappenger, 2009).	17
Figura 3: Arquitetura do modelo MAHP.	21
Figura 4: (a) Interface da plataforma Observatório Cidadão de Enchentes (Degrossi, et al. 2014). (b) Régua para aquisição de dados VGI (Fava et al. 2014).	22
Figura 5: Principais componentes que influenciam na previsão referentes a localização dos pontos VGI.	25
Figura 6: Diferentes disposições quanto a obtenção de dados voluntários. a) informações fornecidas em locais distintos. b) informações fornecidas em tempos distintos. c) Informações com diferentes níveis de confiabilidade.	26
Figura 7: Aquisição de dados VGI em diferentes instantes de tempo.	27
Figura 8: Fluxograma para a atribuição de peso aos fatores da equação de resultado da previsão com inserção de dados VGI de acordo com as condições de monitoramento da bacia.	28
Figura 9: Diferentes resíduos obtidos em função da combinação das variáveis espaço-temporais $x, y, \lambda, \varepsilon, \tau, \sigma, T_C$	29
Figura 10: (a) Sensor de nível remoto. Fonte: Fava <i>et al.</i> (2014). (b) Plataforma <i>Geodashboard</i> . Fonte: Horita <i>et al.</i> (2014).	30
Figura 11: Exemplo de evento simulado/ajustado no passado.	31
Figura 12: Ilustração da obtenção das curvas de correlação entre os valores observados e os valores medidos através da regressão linear. No exemplo, $n=4$	32
Figura 13: Frequência de valores dos dados simulados para o ponto de controle.	32
Figura 14: Redução da incerteza através do modelo MAHP. A hipótese é de que exista uma diminuição no IC (intervalo de confiança) com o novo modelo proposto.	36
Figura 15: Representação do Modelo Hidrológico e da topografia da bacia.	38

Figura 16: Bacia do Monjolinho, pontos de monitoramento (ZAFFANI, 2012).	39
Figura 17: (a) Medição de vazão em canal natural, Ponto 4 em 25/11/2013 (b) Medição de vazão em canal construído Ponto 7 em 14/10/2013.....	39
Figura 18: Detalhamento gráfico das batimetrias nos pontos 4 e 7.....	40
Figura 19: Delimitação da bacia do Monjolinho no ArcGis®.	41
Figura 20: Representação da modelagem matemática da bacia em estudo, onde cada número representa a discretização da sub-bacia.	45
Figura 21: Captura de tela do software de previsão da precipitação desenvolvido.....	47
Figura 22: Precipitação real vs previsões de precipitações através de modelos conceitual e empírico, São Carlos – SP (27/12/2003).....	49
Figura 23: Precipitação real acumulada vs previsões de precipitações acumuladas através de modelos conceitual e empírico.....	49
Figura 24: Pontos de monitoramento N-1, N-2 e N-3 utilizados nas simulações.	51
Figura 25: Gráfico dos níveis observados e simulados no ponto N-1 durante o evento de chuva dos dias 04/11/2013 e 05/11/2013.....	52
Figura 26: Gráfico dos níveis observados e simulados no ponto N-2 durante o evento de chuva dos dias 04/11/2013 e 05/11/2013.....	53
Figura 27: Gráfico dos níveis observados e simulados no ponto N-3 durante o evento de chuva dos dias 04/11/2013 e 05/11/2013.....	54
Figura 28: Simulações utilizando dados de sensores e dados VGI no ponto N-1.....	56

LISTA DE SÍMBOLOS

Siglas

AWIPS	<i>Advanced Weather Interactive Processing System</i>
BANN	<i>Bootstrap Artificial Neural Network</i>
BFS	Sistema de Previsão Bayesiano
CFL	Courant, Friedrichs & Lewy
CN	<i>Curve number</i>
DEM	Modelo Digital de Elevação
DI	Profundidade Impermeável [mm]
DP	Produndidade Permeável [mm]
ER	Erro relativo
FO	Função objetivo
IAHS	Associação Internacional de Ciências Hidrológicas
ICMC	Instituto de Ciências Matemáticas e de Computação
IDE	<i>Integrated Development Environment</i>
MAE	Erro médio absoluto
MAHP	Modelo de Alerta Hidrológico com Base Participativa
MSE	Erro Médio Quadrado
N-1 a N-3	Pontos de monitoramentos
NRSS	<i>National Resources Conservation Service</i>
NSE	Erro de Nash-Sutcliffe
OGC	<i>Open Geospatial Consortium</i>
PUB	<i>Prediction in Ungauged Basins</i>
RNA	Redes Neurais Artificiais
SCS	<i>Soil Conservation Service</i>
SDI	<i>Spacial Data Infrastructure</i>
SWMM	<i>Storm Water Management Model</i>
TNN	<i>Temporal Neural Networks</i>
USP	Universidade de São Paulo
VGI	<i>Volunteered Geographic Information</i>
WBANN	<i>Wavelet-Bootstrap Artificial Neural Network</i>

WSN	<i>Wireless Sensor Network</i>
%AI	Porcentagem de área superficial impermeável
%AIZero	Porcentagem da área impermeável sem armazenamento de depressão
%Slope	Declividade média da sub-bacia em porcentagem

Variáveis

A: Área [km²]

D_c : diâmetro crítico, abaixo do qual todas as partículas são evaporadas completamente antes de atingir o solo.

$\frac{dX(t)}{dt}$: variação temporal da massa de água no estado líquido [kg . m⁻² . s⁻¹]

g : gravidade [m/s/s]

$h_{p_i}^*(t)$: simulação no i -ésimo ponto sem monitoramento no instante t

i : utilizado como índice geral

$I(t)$: entrada de umidade devido à condensação do vapor contido no ar ascendente [kg . m⁻² . s⁻¹]

j : utilizado como índice geral

N_v : indicativo da força da velocidade de ascensão da base da nuvem

N_d : influência do processo de difusividade na nuvem

NI: n de manning para escoamento superficial na parcela impermeável da sub-bacia

NP: n de manning para escoamento superficial na parcela permeável da sub-bacia

n : pontos de observação

P : precipitação [mm]

P_0 : pressão

p_j^S : j -ésimo ponto de monitoramento por rede de sensores sem fio

p_c^S : c -ésimo ponto de controle do sensor sem fio

p_i^v : i -ésimo pontos de observação visual

$O_t(t)$ é a saída de umidade pelo topo da nuvem [kg . m⁻² _ s⁻¹].

Q : Vazão [m³/s]

$Q_s(i)$: vazões simuladas [m^3/s]

$Q_0(i)$: vazões observadas [m^3/s]

r : resultado da previsão com a incorporação de dados VGI

S_0 : inclinação do canal [adim.]

S_f : inclinação de atrito [adim.]

t : tempo [a unidade depende do contexto em que foi utilizada]

T_0 : temperatura [C]

T_d : temperatura do ponto de orvalho

x : localização do ponto VGI

y : número de pontos onde foram inseridas informações

v : velocidade [m/s]

V_p : velocidade terminal das partículas

y_{t+1} : previsão da variável y no instante $t + 1$

$\bar{y}$: média da variável y

$\forall$: qualquer

α : coeficiente da equação do modelo de precipitação

ε : número de observações no mesmo nó

$\varepsilon_1, \varepsilon_2, \varepsilon_3$ e ε_4 : variáveis que determinam a velocidade das partículas no modelo de precipitação conceitual

σ : erro inerente à coleta das informações

σ_y : desvio padrão da variável y

λ : confiabilidade das informações obtidas

ρ_y : coeficiente de autocorrelação

$\frac{\partial y}{\partial x}$: Variação entre a profundidade y pela distância longitudinal x

$\frac{\partial y}{\partial x}$: variação entre a velocidade v e a distância longitudinal x .

SUMÁRIO

1.	INTRODUÇÃO	1
2.	OBJETIVOS	4
2.1.	Objetivos Específicos	4
2.2.	Síntese Metodológica	4
3.	REVISÃO BIBLIOGRÁFICA	5
3.1.	Modelos de Previsão de Enchentes	5
3.1.1.	Modelos de previsão de enchentes conceituais	5
3.1.2.	Modelos de previsão não conceituais	10
3.2.	Previsão de enchentes X previsão de enxurradas	13
3.3.	Análise e redução de incertezas	13
3.4.	Avaliação da previsão.....	15
3.5.	Resiliência à Inundações	16
3.6.	Sistemas de Alerta	17
3.7.	Informação Colaborativa na Previsão Hidrológica	18
4.	METODOLOGIA	21
4.1.	Aquisição dos dados	21
4.1.1.	Dados VGI.....	22
4.1.2.	Critérios para uso de dados VGI.....	22
4.1.3.	Aplicação dos Cenários	28
4.1.4.	Dados WSN	29
4.1.5.	Proposta de relação entre dados VGI e WSN	30
4.1.6.	Dados das Estações Climatológicas	33
4.2.	Previsão da Precipitação	33
4.3.	Integração dos dados no modelo SWMM	35
4.4.	Avaliação dos Desvios do Modelo	36
5.	RESULTADOS E DISCUSSÃO	38
5.1	Levantamento das características da bacia	38
5.2	Modelagem da bacia do Monjolinho no SWMM	40
5.3	Previsão da precipitação	45

5.3.1. Previsão utilizando modelo conceitual	46
5.3.2. Previsão utilizando modelo empírico.....	48
5.3.3. Comparação da previsão entre o modelo conceitual e empírico.....	48
5.4 Previsão de enchente	50
5.4.1. Simulações no SWMM	50
5.4.2. Simulações utilizando dados VGI.....	55
6. CONCLUSÕES E RECOMENDAÇÕES	58
6.1. CONCLUSÕES	58
6.2. RECOMENDAÇÕES	60
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	62
ANEXOS	71
Anexo A.....	71
Anexo B	86

INTRODUÇÃO

Recentemente, tem-se observado uma crescente atenção dada aos desastres naturais e seu potencial impacto sobre o meio ambiente, principalmente devido à frequência com que esses eventos extremos têm ocorrido. É necessária a prevenção de desastres e redução da vulnerabilidade em locais com cenário de risco não só no âmbito geográfico-ambiental, mas também social.

É consenso que a ação de proteção de uma comunidade, além de envolver a participação de diversos atores, deve partir dos esforços de diversas políticas públicas e, nesse sentido, a coerência de ações entre órgãos públicos se torna importante para a prevenção de desastres. As políticas que agem na redução dos efeitos dos desastres atuam de forma desarticulada, o que despense recursos públicos em soluções paliativas (VENDRUSCOLO, 2007).

Para prevenir e mitigar esses impactos é fundamental a proposição de estudos interdisciplinares e testes de vulnerabilidade, a fim de identificar, simular e reproduzir as condições ambientais e a condição dos recursos hídricos derivados de cenários de mudanças climáticas. Fazendo estudos de métodos preventivos, os impactos causados por catástrofes podem ser em muito reduzidos. É importante que se prepare a população sobre como reagir em situações de desastre, de maneira que os prejuízos causados sejam minimizados.

A Associação Internacional de Ciências Hidrológicas (IAHS) lançou uma nova iniciativa para previsões de enchentes em bacias com monitoramento escasso (PUB – *Prediction in Ungauged Basins*). O programa científico PUB foca-se na estimação de incertezas nas previsões e em sua redução subsequente como tema principal (SIVAPALAN *et al.*, 2003). Para isso, devem se aprofundar estudos de métodos de previsão em curto prazo, preenchimento de dados em locais com informações escassas, estudos de vulnerabilidade e maior envolvimento da população nas medidas preventivas. Tendo expostos todos os problemas e necessidades atuais, é justificável a criação de um modelo de previsão hidrometeorológica que contemple as atuais demandas da Defesa Civil e outros órgãos competentes.

Usualmente, a qualidade das previsões hidrometeorológicas é diretamente ligada à quantidade de dados de monitoramento obtidos na bacia. Assim como em outros modelos estocásticos, é razoável supor que um número maior de dados (amostras) contribui para valores mais próximos da média populacional, e, conseqüentemente, para a redução da incerteza na previsão. Entretanto, a medição através da telemetria tradicional possui custos elevados se

instalados em diversos pontos, além de outros problemas, tais como garantia de segurança dos equipamentos.

Informações geográficas voluntárias (VGI - *Volunteered Geographic Information*) é um conceito recente e não possui muitos estudos de aplicação em modelos de previsão hidrológica. Comumente conhecido como “cidadãos como sensores”, o VGI consiste basicamente na obtenção de dados informados por voluntários. Apesar de dados VGI serem informados de forma pontual - ao contrário de dados de sensores, obtidos continuamente - este tipo de informação pode melhorar drasticamente a qualidade do modelo hidrológico, pois possibilita que o modelo parta de um estado inicial mais confiável. Além disso, o custo reduzido de implantação e manutenção do método VGI também são fortes incentivos para a adoção da técnica (POSER; DRANSCH, 2010). Uma das propostas inovadoras dos dados VGI consiste em agregar informações de voluntários às informações obtidas por sensores para redução da incerteza em um modelo de previsão de enchentes em curto prazo (FAVA *et al.*, 2014).

A ocorrência de enxurradas em trópicos úmidos é responsável pelos custos indiretos mais frequentes de enchentes. Segundo Brezková *et al.* (2011), modelos de previsão de curto e médio prazo necessitam de informações horárias ou diárias, e são altamente dependentes de informações com intervalos menores e em tempo real. Hapuarachchi, Wang e Pagano (2011) também comentam sobre a importância do monitoramento em tempo real. Em geral, os sistemas de previsão em curto prazo são associados a sistemas de alerta que priorizam disparos de alerta a quantificação de vazão.

Outro importante dado de entrada para a previsão das enchentes são informações de precipitação. Modelos tradicionais utilizam chuvas “probabilísticas” para a simulação de cenários de catástrofe, entretanto, no caso da previsão em curto prazo, a fidelidade das informações é crucial para a correta previsão. A utilização de dados de níveis em tempo real pode não ser suficiente para antever a enxurrada, principalmente em pequenas bacias, pois a alta intensidade da chuva faz com que o nível do rio suba rapidamente, e, conseqüentemente, fazendo com que o alerta não seja dado com a devida antecedência.

Um dos desafios encontrados no desenvolvimento de modelos de previsão de enchentes com uma complexidade maior de informações é a integração da dados de diferentes fontes. É necessário que se faça o tratamento, uniformização e validação de cada tipo de informação que são integradas ao modelo.

De forma concisa, o presente trabalho propôs a criação de um modelo de alerta a enchentes que consistiu na previsão hidrometeorológica utilizando dados obtidos através de redes

de sensores e dados colaborativos alimentado pela previsão de precipitação. Para designar o modelo proposto neste trabalho, será utilizada a sigla MAHP (Modelo de Alerta Hidrológico com Base Participativa).

1. OBJETIVOS

Desenvolver um Modelo de Alerta Hidrológico com base Participativa (MAHP) que integre informações geográficas voluntárias (VGI- *Volunteered Geographic Information*) e informações de sensores sem fio (WSN - *Wireless Sensor Network*) em bacias com dados escassos (PUB - *Prediction in Ungauged Basins*) para a emissão de alertas, objetivando a prevenção de riscos e danos causados por enchentes.

1.1. Objetivos Específicos

- Desenvolver uma metodologia de integração de dados de fontes híbridas, dados de redes de monitoramento WSN e dados VGI para o preenchimento de um banco de dados a ser utilizado no modelo de previsão;
- Avaliar modelos de previsão da precipitação conceituais e empíricos objetivando melhorar os resultados da previsão de enchentes;
- Avaliar a influência, as incertezas e imprecisões dos dados colaborativos na previsão de enchentes. Aplicar a metodologia em um estudo de caso real modelando a bacia urbana de São Carlos utilizando o software SWMM (*Storm Water Managament Model*).

1.2. Síntese Metodológica

A figura a seguir é um fluxograma dos objetivos, metodologias e resultados do trabalho. Estão descritos os objetivos específicos e todas as etapas metodológicas realizadas para que os resultados fossem alcançados.

Figura 1: Síntese dos objetivos, metodologias e resultados do trabalho.

2. REVISÃO BIBLIOGRÁFICA

Esta seção aborda o levantamento bibliográfico pertinente ao desenvolvimento deste trabalho, bem como a revisão atual da literatura científica sobre os temas propostos.

2.1. Modelos de Previsão de Enchentes

Os modelos de previsão de enchentes podem ser classificados em diversas categorias, de acordo com suas características e finalidades de uso. Tucci (1998) classifica os modelos hidrológicos em:

- **Concentrado ou distribuído:** modelos são ditos concentrados quando não levam em consideração a variabilidade espacial da bacia, enquanto os modelos distribuídos possuem parâmetros e variáveis espacialmente distribuídos. Cabe ressaltar, que a distribuição pode ser também temporal, podendo classificar os modelos em permanentes e transientes;
- **Estocástico ou determinístico:** modelos estocásticos possuem probabilidades associadas, trazendo como resultados intervalos de probabilidade. Enquanto modelos determinísticos produzem valores únicos (mesma saída) para uma mesma entrada;
- **Conceitual ou empírico:** Modelos conceituais são aqueles que possuem conceitos físicos agregados as suas funções de cálculo. Diferentemente dos modelos empíricos que são baseados em análises estatísticas como métodos de correlação e análise de regressão. Também se enquadram nesta categoria, métodos empíricos não-lineares como redes neurais artificiais.

Cada categoria de modelos de previsão de enchentes possuem recursos que devem ser levados em consideração para a escolha do modelo a ser adotado, como por exemplo, a simplicidade de uso, eficiência dos resultados e custos computacionais. Nas seções seguintes, realizou-se um levantamento dos modelos atuais e suas principais características.

2.1.1. Modelos de previsão de enchentes conceituais

Um modelo chuva-vazão bastante usado na literatura é o SWMM - *Storm Water Management Model* (ROSSMAN, 2009), desenvolvido pela Agência de Proteção Ambiental dos EUA. O SWMM é um modelo chuva-vazão capaz de simular eventos simples ou de período estendido, simulando aspectos quantitativos e qualitativos. O modelo tem sido utilizado amplamente no meio acadêmico devido aos resultados comparáveis aos modelos mais complexos

e superiores aos modelos mais simples. Além disso, o modelo é gratuito, possui código fonte aberto e um suporte amplo de usuários na Internet.

A partir de dados de precipitação e do sistema de drenagem considerado, o SWMM gera escoamentos e cargas de poluentes. O sistema pode apresentar condutos, canais abertos, armazenamento, tratamento, bombas e reguladores, entre outros dispositivos. O modelo é capaz de simular resposta a chuvas de intensidade variável no tempo, evaporação ou retenção de água, acúmulo de neve e derretimento, infiltração e percolação, reservação não-linear, sistemas de tamanho ilimitado, variadas formas de condutos e canais, vários regimes de escoamento, etc. Ao longo das simulações, o SWMM aplica os princípios de conservação de massa, energia e momento, sempre que apropriado, e de acordo com as opções de modelagem feitas pelo usuário (SHINMA, 2011).

Para simular a vazão, internamente o SWMM utiliza equações de Saint Venant para vazões de velocidade variada, turbulenta e dinâmicas (PETERSON; WICKS, 2006). As equações de Saint Venant representam os princípios da conservação do momento (Equação 3.1) e conservação de massa (Equação 3.2).

$$\frac{\partial y}{\partial x} + \frac{v}{g} \frac{\partial v}{\partial x} + \frac{1}{g} \frac{\partial v}{\partial t} = S_0 - S_f, \quad (\text{Eq. 3.1})$$

$$\frac{\partial Q}{\partial x} + \frac{\partial A}{\partial t} = 0, \quad (\text{Eq. 3.2})$$

sendo y a profundidade, v velocidade, x : distância longitudinal, t : tempo, g : aceleração da gravidade, S_0 : inclinação do canal, S_f : inclinação de atrito, A : área da seção em função de y , de acordo com a geometria do conduto, Q : vazão.

Os componentes de conservação do momento (Equação 3.1) representam a pressão hidrostática, aceleração convectiva, aceleração local, forças gravitacional e de fricção respectivamente. Representando os efeitos da turbulência e viscosidade, S_f é calculado no SWMM usando a equação de Manning (Equação 3.3):

$$S_f = \frac{Q^2}{\frac{1}{n} A^2 R^{\frac{4}{3}}} \quad (\text{Eq. 3.3})$$

onde n é o coeficiente de rugosidade de Manning e R o raio hidráulico.

Lee *et al.* (2010) compararam medições de cargas de poluentes com simulações efetuadas através dos modelos SWMM e HSPF (*Hydrologic Simulation Program – Fortran*). Os resultados do SWMM foram satisfatórios para áreas urbanas de pequena escala e o HSPF demonstrou resultados levemente superiores. Estudos comparativos também foram feitos entre o SWMM e modelos com lógica fuzzy e demonstraram a covalidação dos modelos com os dados medidos em campo (WANG; ALTUNKAYNAK, 2011). O modelo de lógica *fuzzy* para grandes eventos de chuva mostrou-se superior. No entanto, o SWMM pode produzir hidrogramas variantes no tempo, enquanto a lógica *fuzzy* é sujeita a limitações.

Elliott & Trowsdale (2006) compararam dez modelos de escoamento existentes em relação aos atributos relevantes para a modelagem, e consideraram os modelos MOUSE e SWMM adequados para uma ampla gama de usos em relação aos outros estudados, mas sendo bastante complexos para serem usados pelo público em geral.

Assim como em outros modelos, o SWMM necessita ser calibrado. Shinma (2011) desenvolveu um software de calibração multi-objetivo com esta finalidade. O calibrador possui a vantagem em relação aos outros métodos por aproveitar a característica multi-site do modelo SWMM. Esta técnica de otimização utilizada na calibração de modelos de bacias aninhadas tem mostrado resultados superiores à utilização de calibrações sequenciais de cada sub-bacia.

Beven *et al.* (1984) propuseram e avaliaram um modelo físico nomeado como TOPMODEL para a previsão de enchentes de três bacias no Reino Unido com áreas de 8km², 36km² e 10,5km². O modelo possui a vantagem de ser simples, sendo que foram utilizados somente dados de precipitação e evaporação estimados como dados de entrada. Segundo os autores, o modelo pode ser utilizado para bacias com dados escassos menores que 500km² e climas úmido-temperados. Os resultados foram eficiência de 97,2%, 64,4% e 98,3% respectivamente. Entretanto, a eficiência foi calculada para os dados ajustados e não houve validação, exceto para a segunda bacia, que foi a que obteve o pior resultado.

Paz *et al.* (2002) analisou a aplicação do método de diferenças (modelo Prev) nas bacias hidrográficas do rio Doce (MG) e do rio Uruguai (RS). O modelo Prev, desenvolvido no Instituto de Pesquisas Hidráulicas (IPH/UFRGS), trata-se de um modelo empírico e determinístico que realiza previsão de níveis ou vazões em tempo real, com base na propagação do escoamento, utilizando uma equação linear múltipla de diferenças das variáveis envolvidas. O modelo Prev mostrou um erro de 9% da vazão de pico aplicado à bacia do rio Doce. E obteve melhores resultados na previsão da vazão no rio Uruguai com valores de erro inferiores a 3% da vazão de

pico devido à proximidade na magnitude dos eventos utilizados nas fases de calibração e validação do modelo.

Corrêa *et al.* (2007) utilizaram um modelo simples de chuva-vazão para fazer previsão da onda de cheia com 24 horas de antecedência. Mapearam-se as linhas d'água ao longo do rio para identificação das áreas de risco de inundação. Na calibração do modelo, os erros observados ficaram em torno de 2%. Devido à falta de estações fluviométricas na bacia desejada, o trabalho utilizou dados de uma estação fluviométrica 268 km distantes do local real. O trabalho fez uma correlação dos níveis no sentido de transferir a variação relativa diária de vazão da estação de montante para a de jusante. Foi feita a relação de variação diária de vazão e aplicou-se essa taxa na vazão medida na estação em Porto Velho para então transformar a vazão prevista em cota prevista através da curva-chave da estação.

Shamir *et al.* (2010) aprimoraram um método de previsão de enchentes amplamente usado no Japão e Coreia, conhecido como Método da Função de Armazenamento ou *Storage Function Method* (SFM). Os detalhes do método são melhor discutidos em Lee e Kim (2000) e Bae e Chung (2000). A contribuição dos autores foi a inclusão da técnica do filtro de Kalman estendido no modelo SFM. O método foi aplicado em uma bacia de 4500 km². Apesar dos resultados apresentarem boas previsões na maior parte da série histórica, o modelo mostrou resultados pobres para eventos em que ocorriam altas vazões, tornando o método inviável para a tarefa de previsão de enchentes.

Brocca *et al.* (2011) fizeram uma revisão dos principais modelos que utilizam chuva-vazão. Notou-se que os métodos mais simples apresentam resultados modestos, enquanto os métodos mais complexos, apesar do melhor desempenho, possuem a desvantagem de necessitarem de uma gama maior de dados de entrada, desencorajando o seu uso.

Em seu artigo técnico, Akinci & Erdogan (2014) relatam que a Turquia ainda carece de um sistema de previsão de enchentes e mapas de inundações e descrevem o sistema desenvolvido atualmente pelo serviço meteorológico do país. De acordo com os autores, este tipo de sistema deve estar integrado com tecnologias de infraestruturas de dados espaciais (SDI do inglês *Spatial Data Infrastructure*). Tais tecnologias são criadas para disponibilizar dados geoespaciais ou de outra natureza, através de camadas de dados padronizados utilizando a Internet e é uma evolução natural dos sistemas SIG (sistemas de informações geográficas). O uso do SDI é útil pois permite a interoperabilidade entre diferentes órgãos dentro de um mesmo país, ou até mesmo entre agências internacionais que busquem a cooperação mútua. O desenvolvimento do padrão SDI é livre para qualquer entidade, sendo que um dos padrões SDI mais utilizados é de

responsabilidade da *Open Geospatial Consortium (OGC)*. Trabalhos recentes concordam que o desenvolvimento de plataformas padronizadas através do SDI são de grande vantagem (Kurzbach *et al.* 2009; Lecca *et al.* 2011; Sunkpho *et al.* 2011) e utilizam o padrão SDI proposto pela OGC.

O radar meteorológico é um instrumento que infere a chuva a partir da radiação retroespalhada pelo hidrometeoros suspensos na atmosfera (BATTAN, 1973). Como esta potência é proporcional à concentração de gotas de chuva ao diâmetro à sexta potência, a conversão para taxa de precipitação se torna um problema físico (qual é a distribuição de tamanho de gotas) e matemático (minimização do erro da estimativa de precipitação) (ANAGNOSTOU; PATHAK; MORALES, 2011). Adicionalmente, a resolução do volume iluminado pelo radar impõe restrições na resolução das estimativas de precipitação, pois à medida que se afasta o volume aumenta. Finalmente, os radares meteorológicos são equipamentos sofisticados de alto custo que requerem manutenções periódicas e equipes permanentes para operação, o que limita o seu uso extensivo. Entretanto, com os avanços tecnológicos atuais, soluções mais simplificadas podem ser aplicadas para centros urbanos de pequeno e médio porte ou mesmo bacias hidrográficas pequenas (MARZANO *et al.*, 2010). Kitzmiller *et al.* (2013) realizaram um estudo com as principais técnicas de previsão de precipitação com o uso de radares. Dentre os principais métodos, destacam-se o Radar de Vigilância Climática – 1988 Doppler (WSR-88D), o Sistema de Processamento de Precipitação (PPS), o Sistema Avançado de Processamento Interativo (AWIPS - *Advanced Weather Interactive Processing System*), algoritmo estimador multisensor (MPE) que utiliza uma combinação de sensores para previsão de precipitação. Gonçalves (2009) propôs um modelo de previsão de precipitação aprimorado utilizando informações geradas por sistemas de radar meteorológico, acopladas a um modelo de previsão hidrometeorológica, seguido por um modelo de transformação de chuva em vazão. O modelo de previsão de precipitação foi uma adaptação de outro modelo, inicialmente proposto por Georgakakos & Bras (1984) e aplicado por Andrade (2006). O modelo de previsão de precipitação considera a nuvem como um reservatório de água condensada, na qual a variação temporal da massa de água no estado líquido é expressa por uma equação de entradas e saídas de umidade.

$$\frac{dX(t)}{dt} = I(t) - O_t(t) - O_b(t) \quad (\text{Eq. 3.4})$$

em que $\frac{dX(t)}{dt}$ é a variação temporal da massa de água no estado líquido presente no interior da nuvem [$\text{kg} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$]; $I(t)$ é a entrada de umidade devido à condensação do vapor contido no ar ascendente [$\text{kg} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$]. $O_t(t)$ é a saída de umidade pelo topo da nuvem [$\text{kg} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$]. $O_b(t)$ é a saída de umidade pela base da nuvem.

Gonçalves (2009) utilizou também variáveis de tempo medidas na superfície: temperatura (T_0), pressão (P_0) e temperatura do ponto de orvalho (T_d). Estas variáveis como dados de entrada do modelo.

2.1.2. Modelos de previsão não conceituais

Os modelos de previsão inteligentes são aqueles que utilizam técnicas de aprendizado de máquina. Os estudos atuais desta área têm demonstrado bons resultados. Entretanto, o uso das redes neurais artificiais, assim como qualquer outro método de previsão, exige a análise crítica dos dados. Enquanto os modelos tradicionais correlacionam diretamente entradas de precipitação com vazão ou derivam seu processamento de equações de balanço de massa, redes neurais artificiais produzem sua resposta baseada no ajuste destes coeficientes, chamados de pesos sinápticos, que não possuem significado físico (Feng & Lu 2010). Tais modelos são conhecidos como modelos caixa-preta. A eficiência do método ocorre devido à supervisão do processo de aprendizado. Nem todos os dados observados são usados no treinamento. Os dados são divididos entre dados de treinamento e validação, sendo que os dados de validação são usados de forma externa para impedir que o modelo sofra *overtraining* (treinamento demasiado que torna o modelo incapaz de generalizar as saídas para novas entradas).

Campolo, Andreussi & Soldati (1999) utilizaram redes neurais para prever o comportamento do rio Tagliamento, Itália, durante períodos de chuva intensa. Utilizando somente dados históricos de precipitação e níveis dos rios, a rede neural treinada foi capaz de realizar previsões bastante precisas (MSE menores que 4%, NSE de 0.98). As previsões possuíam passos de uma hora e a previsão foi feita para até dez horas, entretanto o modelo foi capaz de prever satisfatoriamente até no máximo de 5 horas. Embora a rede neural tenha previsto o comportamento do nível do rio na seção satisfatoriamente, o estudo foi aplicado somente a um estudo de caso. A eficiência deste tipo de previsão é dependente do *lag* entre o nível de água e a chuva, que é característico para cada evento de enchente, além de depender de outros fatores, como a saturação da bacia.

Napolitano *et al.* (2010) fizeram um estudo comparativo de previsão de enchentes utilizando dois métodos. O primeiro foi um método de chuva-vazão que foi calibrado em tempo real durante cada evento de cheia via procedimento adaptativo. E o segundo método usado foi um modelo dirigido por dados usando redes neurais artificiais (modelo TNN - *Temporal Neural Networks*). As redes neurais *feed-forward* treinadas com *backpropagation* e regularização bayesiana foram desenvolvidas usando um conjunto de dados histórico. Ambos os modelos foram usados para prever as vazões mais significantes que ocorreram em Roma no período de novembro de 2005 a dezembro de 2008. Os modelos apresentaram boa previsão para horizontes de 12 horas (R^2 de 0,87 a 0,95) e resultados um pouco inferiores para previsão de 18 horas.

Garcia-Bartual (2002) fizeram a previsão de cheias em uma bacia de 460 km² utilizando redes neurais artificiais. O sistema foi monitorado por seis pluviômetros e as vazões medidas através da profundidade a cada meia hora. A previsão foi realizada para períodos de 1, 2 e 3 horas através do uso de diferentes topologias de redes neurais. Embora os resultados tenham sido satisfatórios (R^2 de 0,8 a 0,95), os modelos de previsão neurais foram treinados com doze séries de dados sintéticos e apenas uma série de dados reais. Uma das características das redes neurais é a necessidade de um conjunto de dados suficientes para realizar o treinamento do modelo.

Nayak *et al.* (2005) propuseram um modelo de previsão da vazão de um rio utilizando uma técnica computacional neuro-*fuzzy*. A técnica consiste em combinar a proposta de computação nebulosa (*fuzzy*) e técnicas de redes neurais artificiais. A técnica neuro-*fuzzy* mostrou resultados um pouco superiores do que com as duas técnicas usadas separadamente. Posteriormente, o modelo *fuzzy* também foi utilizado por Ren *et al.* (2010). Os autores realizaram um estudo utilizando um método de previsão integrando um modelo de classificação por *fuzzy* e um modelo hidrológico conceitual usando redes neurais artificiais. O modelo *fuzzy* foi usado para classificar enchentes históricas em termos de picos e profundidade da vazão, e o modelo hidrológico conceitual foi calibrado para cada classe de enchentes. A rede neural utilizada foi do tipo *back-propagation* e foi treinada usando dados de chuva em tempo real e as saídas do modelo de classificação *fuzzy*. Baseado na classificação online, um conjunto de parâmetros apropriados do modelo hidrológico foi automaticamente escolhido para produzir a previsão de enchentes em tempo real. Os resultados demonstraram que a classificação dos dados em grupos tornou a previsão das redes neurais superior ao método tradicional com dados não classificados.

Toth *et al.* (2000) fizeram um estudo comparativo entre métodos de previsão de chuvas. As comparações foram feitas com os modelos auto-regressivo de média móvel (ARMA), redes neurais artificiais (RNA) e o método não-paramétrico dos vizinhos mais próximos. O trabalho

comparou as vantagens e limitações de cada técnica, analisando previsões de 1 até 6 horas. Os resultados demonstraram que a maior acurácia foi obtida pelas RNAs.

Chau *et al.* (2005) realizaram um estudo comparativo entre diversos modelos de previsão de enchentes. Foram testados dois modelos empíricos baseados em algoritmos genéticos e redes neurais artificiais, uma rede adaptativa baseada em sistema de inferência *fuzzy* (ANFIS) e um modelo de regressão linear empírico. Os métodos foram utilizados para previsão de enchentes em um canal do rio Yangtze na China. Os modelos que utilizam algoritmos genéticos e redes neurais foram bastante superiores ao modelo de regressão, entretanto demandam mais esforço computacional. O modelo ANFIS atingiu o resultado ótimo, entretanto este método necessita de mais parâmetros do que os demais métodos.

Posteriormente, Nguyen *et al.* (2013) testaram a eficiência da previsão do modelo ANFIS incluindo dados de níveis de água de três estações a montante dos pontos de interesse em um rio da China. Contrariando as expectativas, a inclusão de novas informações no modelo não contribuíram para a melhoria das previsões na maioria dos casos. Os resultados das previsões foram superiores somente com a inclusão dos dados de uma das estações pois a grande contribuições das vazões dos tributários fizeram com que a correlação entre os níveis de água das estações a montante e dos pontos de interesse diminuíssem, limitando a efetividade da inclusão dos dados a montante como informação de entrada. Além disso, mesmo neste caso em que as previsões foram superiores, foram somente por curtos períodos de tempo. Os autores também concluíram que a utilização de dados medidos em tributários não melhoram os resultados das previsões, pois as contribuições de vazões dos tributários não foram significantes o suficiente para o volume total do rio.

Sehgal, Sahay & Chatterjee (2014) modificaram o modelo ANFIS adicionando componentes *wavelets* discretos para as previsões. Segundo os autores, as propriedades dos *wavelets* em decompor sinais seriam úteis para aprimorar o desempenho das previsões, pela filtragem de ruídos existentes dentro de dados reais. O estudo foi aplicado a duas bacias hidrográficas na Índia, visando realizar a previsão da enchente com um dia de antecedência. A nova metodologia proposta demonstrou resultados superiores aos obtidos através do modelo ANFIS original em diversos testes, sendo útil principalmente pela melhoria das previsões nos dias em que os níveis de água foram mais intensos. No entanto, a metodologia aplicada a grandes bacias, com tempos de concentração iguais ou superiores a 3 dias tiveram pouco impacto nos resultados.

2.2. Previsão de enchentes x previsão de enxurradas

Segundo Mendingo (2005), as enxurradas são causadas por precipitação elevada e geralmente de curta duração (chuvas torrenciais), e ocorrem em áreas que muitas vezes são relativamente pequenas. Nas enchentes, o transbordamento do curso do rio é geralmente resultado de precipitação abundante e prolongada sobre uma grande área. A ocorrência de enxurradas em trópicos úmidos é responsável pelos custos indiretos mais frequentes de enchentes.

Diversos estudos demonstram que a previsão de enchentes não é uma tarefa trivial e que vem sendo aprimorada ao longo do tempo. No entanto, a previsão de enxurradas é ainda mais complexa pois envolve não somente a ocorrência, mas também a previsão do instante do tempo e a magnitude do evento.

Segundo Březková (2011), eventos relâmpagos que ocasionam enxurradas são quase impossíveis de serem previstos até mesmo em curto prazo. O autor lista os principais métodos de previsão de enxurradas. Em geral, os métodos são muito semelhantes aos métodos de previsão de enchentes (simulação hidrológica, monitoramento via eco-radar, algoritmos inteligentes etc.). A principal diferença está na velocidade da aquisição das informações. Enquanto em modelos de previsão de curto e médio prazo necessitam de informações horárias ou diárias, os modelos de previsão de enxurradas são altamente dependentes de informações com intervalos menores e em tempo real. Hapuarachchi *et al.* (2011) também comentam sobre a importância do monitoramento em tempo real. Em geral, os sistemas de previsão de enxurrada são associados a sistemas de alerta que priorizam disparos de alerta à quantificação de volumes.

Broxton *et al.* (2014) propuseram um modelo de previsão de enxurradas em tempo real e o aplicaram para pequenas e médias bacias rurais no Estado de Nova Iorque – EUA. O modelo estudado leva em consideração, além da precipitação, a vazão do derretimento da neve. Segundo os próprios autores, os resultados foram modestos e necessitam de mais estudos. Assim como nos estudos anteriores, os autores concluem que para este tipo de previsão é necessário principalmente o aperfeiçoamento da previsão da precipitação com uso de radares.

2.3. Análise e redução de incertezas

A quantificação, compreensão e redução de incertezas na previsão de modelos hidrológicos é um grande desafio científico e operacional. Incertezas nas previsões hidrológicas podem se originar de diversas fontes (Montari *et al.* 2009): (1) aleatoriedade inerente à natureza;

(2) erros na estrutura do modelo; (3) erros nos valores dos parâmetros do modelo; (4) erros nos dados (dados de entrada previstos ou usados na calibração).

A estatística bayesiana tem sido utilizada nos últimos anos para integração de diversas fontes de incerteza (Huard & Mailhot 2008; Renard *et al.* 2010). Além da utilização direta da estatística bayesiana, um novo modelo foi proposto recentemente conhecido como sistema de previsão bayesiano (BFS) que fornece uma metodologia geral para previsão probabilística via qualquer modelo hidrológico determinístico. O BFS decompõe a incerteza total preditiva associada com o preditor em incertezas de precipitação e incertezas hidrológicas. A incerteza da precipitação, assumidamente a incerteza dominante na previsão, é relacionada com a previsão da precipitação média da bacia. Todas as outras fontes de incertezas hidrológicas são agregadas em uma única incerteza. Biondi & Luca (2011) aplicaram o método BFS em uma pequena bacia na Itália. Os resultados foram eficazes em identificar e quantificar os intervalos de confiança e os níveis de incerteza, em horários de pico.

Um passo natural após identificar e quantificar os níveis de incerteza é sua redução. Tiwari & Chatterjee (2010a) aprimoraram o modelo de previsão utilizando redes neurais através da incorporação dos parâmetros de incerteza. A incerteza paramétrica é quantificada através do uso de técnicas de *bootstrap*. A técnica de *bootstrap* é um procedimento computacional que usa reamostragem com substituição para reduzir a incerteza. Esta é considerada a técnica mais simples, pois não necessita de cálculos complexos para derivadas e inversão de matrizes hessianas envolvidas nos métodos lineares ou soluções de Monte Carlo de integrais envolvidas nas propostas Bayesianas (Dybowski & Roberts, 2000). Posteriormente, Tiwari & Chatterjee (2010b) desenvolveram uma rede neural híbrida *wavelet-bootstrap* (WBANN) para previsão de vazões em horizontes de uma hora. Os *wavelets* foram utilizados para decompor séries de dados temporais em diferentes componentes para capturar informações úteis em vários níveis de resolução. Foram usados cinco anos de dados de nível de água de cinco estações de monitoramento em uma bacia de Mahanadi, Índia. Os dados foram decompostos em subséries por transformada discreta *wavelet* e em seguida montadas para a criação de uma nova série. O método de amostragem por *bootstrap* foi usado para gerar diferentes conjuntos de dados que são usadas como entrada para o modelo neural. A performance do modelo WBANN foi comparada com três diferentes modelos de redes neurais: as redes neurais artificiais, redes neurais baseadas em *wavelet* (WANN) e redes neurais baseadas em *bootstrap* (BANN). Os resultados mostraram que os modelos híbridos WBANN e BANN produzem resultados melhores que os modelos ANN e WANN tradicionais. WBANN simulou os picos de nível de água melhor que os modelos ANN,

WANN e BANN e, o desempenho geral do modelo WBANN foi mais preciso e confiável quando comparado aos demais modelos.

Diferentes técnicas podem ser utilizadas para corrigir o erro na previsão de enchentes, como por exemplo, o filtro de Kalman, métodos baseados em redes neurais e lógica *fuzzy* e métodos autoregressivos, sendo que cada método possui suas vantagens e desvantagens. Segundo Wu *et al.*, (2012), o filtro de Kalman possui alto custo computacional. Redes neurais e modelos autoregressivos apresentam resultados semelhantes para correção do erro da enchente de acordo um estudo realizado por Xiong and O'Connor (2002). Segundo estes autores, a eficiência do modelo autoregressivo não é melhorada significativamente por nenhum dos outros métodos testados.

Além da correção direta no erro da enchente, uma outra categoria de soluções tem sido proposta por diversos pesquisadores: a composição multi-modelo ou *multi-model composition* (MC). Esta proposta consiste na simulação das vazões de forma sincronizada através de diversos modelos distintos de forma a produzir um resultado integrado superior aos gerados individualmente (Hsu *et al.*, 2009; Shamseldin *et al.*, 2007; Fernando *et al.* 2011). Posteriormente, Chen *et al.* (2015) propuseram uma técnica combinada entre as metodologias de correção do erro da enchente com as metodologias MC. A técnica foi aplicada a diversas bacias na China e os resultados mostraram que o uso das metodologias combinadas são mais eficazes do que o uso das técnicas de forma serial.

2.4. Avaliação da previsão

O uso de expressões como “bom ajuste” ou “previsão satisfatória” são comuns na literatura sobre modelos de previsões. Entretanto, existem diferentes opiniões sobre o que é considerado satisfatório ou não entre os modeladores. Alguns autores classificam a qualidade da previsão em intervalos de acordo com os desvios entre as simulações e os dados reais. A maior crítica desta abordagem é a subjetividade deste tipo de critério, pois a qualidade da previsão depende, em grande parte, da finalidade a qual o modelo se propõe a prever.

Murphy (1993) sugere três fatores para verificar a eficiência de uma previsão, são eles:

- **Consistência:** consiste na capacidade intrínseca e particular do modelador, ou, julgamento interno. Estes conhecimentos são baseados no raciocínio e senso crítico do modelador e dificilmente podem ser expressos numericamente ou estatisticamente.
- **Qualidade:** é o grau de correspondência entre as previsões e os dados reais. Assim, quanto

maior a proximidade da correspondência, maior a qualidade da previsão. Este fator pode ser expresso através de medidas como o erro médio absoluto (MAE), coeficiente de Nash-Sutcliffe entre outros.

- Valor: o ganho econômico e/ou outros benefícios percebidos pelos tomadores de decisão através das previsões. Embora a previsão não possua valor intrínseco, esta passa a adquirir valor através da sua habilidade de influenciar nas ações dos tomadores de decisão. O valor das previsões pode ser medida através de diferentes unidades. Por exemplo, pode ser medido em termos de benefícios econômicos ou despesas ou em termos de ganhos ou perdas não monetários (e.g. vidas salvas ou perdidas).

Segundo Murphy (1993), a melhor avaliação se dá através do alto nível de relação entre esses três fatores. Assim, uma boa medida de ajuste deve considerar diversas atividades relacionadas ao processo de previsão, incluindo a formulação, avaliação e comunicação com os modeladores e pessoal experiente.

2.5. Resiliência as Inundações

Segundo as Nações Unidas, o Brasil figura entre os países com maior incidência de sinistros devido às inundações. Os custos econômicos totais, diretos e indiretos, chegam até 3% do PIB e os danos comprometem o equivalente a 11% de fontes de arrecadação. O Brasil registra anualmente centenas de mortes por afogamento, enxurradas, alagamentos e acidentes em vales de inundação (MENDIONDO *et al.*, 2013).

Vulnerabilidade é o estado de um sistema exposto a riscos, condicionado por fatores biofísicos e socioculturais, em diferentes escalas temporais e espaciais, combinado com sua capacidade de resposta (INCLINE, 2013). A determinação de situações de risco em recursos hídricos advindos das alterações climáticas é feita através da capacidade da bacia do rio de adaptação e organização, incluindo a capacidade de se recuperar de desastres. Assim, há uma necessidade de se construir a resiliência a riscos na sociedade, através de uma avaliação participativa dos riscos, vulnerabilidades e capacidades relacionadas com o planejamento de ações por parte das comunidades.

Segundo Vis *et al.* (2003), gestão dos riscos de inundação com base na capacidade de resiliência é uma boa alternativa, pois as estratégias de resiliência são mais flexíveis e oferecem mais oportunidades para a natureza e desenvolvimento da paisagem. No entanto, a implementação requer enormes investimentos em curto prazo, enquanto que os resultados só

ficarão claros ao longo de períodos de tempo relativamente longos. Resiliência é a capacidade do sistema urbano ou comunidade a resistir, mudar ou adaptar-se a fim de obter um nível de funcionamento e estrutura aceitável ou novo. Isto é determinado pelo grau em que o sistema social é capaz de organizar-se, e a sua capacidade para aumentar a sua capacidade de aprendizagem e de adaptação, incluindo a capacidade para recuperar de uma catástrofe (MENDIONDO, 2010).

2.6. Sistemas de Alerta

Atualmente, verifica-se um crescente interesse no uso de modelos matemáticos de previsão de tempo em centros operacionais e sistemas de previsão de enchentes (CLOKE; PAPPENBERGER, 2009). Esses modelos de previsão incorporam em sua maioria os sistemas de alerta, responsáveis pela emissão de avisos dos níveis de risco a ocorrência de catástrofes. Um sistema de alerta consiste basicamente em um modelo hidrológico alimentado por dados meteorológicos (obtidos através de monitoramento, observação visual ou previsão meteorológica) capaz de prever a vazão com um nível de probabilidade associado. Após a obtenção da vazão prevista, os dados são classificados em vazões normais ou que apresentam determinado nível de risco.

Figura 2: Exemplo de previsão hidrológica por conjunto. (Clope & Pappenger, 2009).

Redes de sensores sem fio ou WSN (do inglês *Wireless Sensor Networks*) são ferramentas para apoiar o monitoramento ambiental. WSN são compostas por pequenos computadores programáveis conhecidos como "partículas" que estão equipados com tecnologias de rede sem fio de baixa potência e sensores de monitoramento (HUGHES *et al.*, 2011).

Este tipo de ferramenta apresenta grande vantagem comparada com outros métodos de monitoramento. O conceito de rede nos pontos de monitoramento permite maior robustez na aquisição dos dados. Sensores remotos tradicionais enviam os dados de forma serial, submetendo a informação para o sensor mais próximo, até que alcancem uma estação central. Nos casos em que há falha em um sensor, toda a transmissão dos dados fica comprometida, enquanto nas redes de sensores sem fio (WSN), os dados podem seguir rotas alternativas, aumentando a confiança do sistema.

Horita *et al.* (2014) desenvolveram um framework para sistemas WSN denominado AGORA-GeoDash. O framework é composto por três camadas responsáveis por adquirir dados de campo, processar e exibir os dados de modo padronizado.

Furquim *et al.* (2014) realizaram uma investigação utilizando técnicas de classificação com aprendizado de máquina para auxiliar na previsão de enchentes utilizando dados obtidos através de uma WSN. Através deste estudo, os autores demonstraram que diferentes técnicas de previsão levam a resultados bastante diferentes, sendo que o melhor resultado foi obtido através do uso de uma rede neural multi-camadas.

2.7. Informação Colaborativa na Previsão Hidrológica

No desenvolvimento de sistemas de gestão de desastres e construção de sistemas de alerta são utilizadas diversas informações a respeito do estado do ambiente estudado, de maneira integrada, para que se possa fazer a relação com as mudanças climáticas e os problemas associados.

Nesse conjunto de informações são utilizados dados coletados de medições e de condições físicas da bacia. Para o funcionamento de modelos de previsão em curto prazo é imprescindível que se tenham dados locais e, em tempo real, para as tomadas de decisão na mitigação de desastres. Um problema crucial é a disponibilidade de medidores de dados em todos os pontos considerados estratégicos. Com a evolução dos meios de comunicação, surge a possibilidade de interação e recebimento de informações por grupos de pessoas que estejam passando pelos locais de risco. Goodchild (2007) definiu o termo VGI (do inglês, *Volunteered Geographic Information*)

como dados geográficos digitais gerados por cidadãos comuns a fim de publicar suas observações e conhecimento na web.

Ao contrário dos dados obtidos via sensores, os dados voluntários não são adquiridos em intervalos regulares, e sim, informados de forma esporádica. Em seguida, os dados obtidos via VGI e os valores reais medidos são inseridos no modelo para a previsão. Em posse dos dados previstos, é possível calcular estatisticamente os intervalos de confiança entre os valores reais e estimados. Esta informação fornece dados probabilísticos para as iterações seguintes do modelo de previsão para o preenchimento dos pontos em que não existe a medição em tempo real.

A informação obtida visualmente vai além da utilidade da informação pontual. Ainda é possível utilizar estes dados, em conjunto com dados de monitoramento para desenvolver métodos de previsão correlacionando as informações disponíveis. O preditor estima dados nos pontos em que a informação é escassa, fornecendo assim parâmetros importantes das condições do local na iminência da ocorrência de um desastre. Essas informações ajudam a obter uma resposta mais eficaz e imediata. Para que a relação entre os dados medidos pelos sensores e as VGI resultem em previsões e informações confiáveis, é necessário fazer um equacionamento relacionando o estado nos pontos conhecidos com o estado dos pontos dependentes das VGI. Fazendo a relação entre os valores podem-se associar as informações reduzindo a incerteza sobre os dados provenientes de observações.

Dentre as principais vantagens do método VGI, destaca-se a capacidade de aumentar a área de abrangência de informações disponíveis, pois a quantidade de sensores é um recurso limitado. Através do VGI, locais importantes podem ser monitorados com o auxílio da população, enquanto os sensores podem ser reaproveitados em locais de difícil acesso ou com menor densidade populacional (GOODCHILD, 2007).

Além dessa vantagem, a obtenção de dados visuais possui a vantagem de ser uma solução de baixo custo, pois a informação é obtida sem a necessidade de instalação de medidores, registradores e transmissores de dados. Pode-se listar também como vantagem, o baixo nível de intrusão do método, pois não exige a construção de suportes específicos para fixação dos equipamentos, além de eliminar a necessidade de mecanismos para garantir a segurança dos equipamentos. Tendo também a vantagem do fator social, pois a participação da comunidade no monitoramento possui elementos de conscientização.

Inegavelmente informações fornecidas por voluntários possuem importância no manejo de desastres. Conforme relatado por Poser & Dransch (2010), informações VGI permitiram que voluntários organizassem ajuda rapidamente através de fóruns na Internet durante o grande

terremoto na província de Sichuan, China em 2008, apenas um minuto após o ocorrido. Caso semelhante ocorreu durante um incêndio no sul da Califórnia em 2007, em que os moradores afetados julgaram que as informações voluntárias foram mais úteis do que o noticiário nacional ou sites oficiais do governo. Os autores realizaram um estudo para a construção de mapas de inundação entrevistando 1700 voluntários aleatórios de uma região inundada por telefone e compararam com um mapa gerado através de modelos hidráulicos. O mapa gerado através das informações voluntárias resultou em erros menores do que os obtidos através da modelagem. Entretanto, mesmo as informações voluntárias apresentaram-se enviesadas.

Cortes *et al.* (2013) realizaram uma revisão das recentes iniciativas da comunidade europeia a respeito de métodos e técnicas para prevenção e gerenciamento de enchentes. Dentre as diversas técnicas mostradas, destacam-se metodologias de sistemas de alertas e sistemas de suporte a decisão. Além disso, os autores mencionam dados VGI como uma fonte de dados complementar de informação e afirmam que existe o desafio da integração destes dados à infraestrutura de dados espaciais (SDI) atuais para melhoria dos sistemas, no entanto, sem aplicarem na prática.

Schade *et al.* (2013) propuseram uma metodologia para integração dos dados VGI dentro de plataformas *online* inclusive para o gerenciamento de enchentes. Entretanto, os autores utilizam o VGI somente por meio de dados minerados de redes sociais como o Flickr, utilizando a extração de *geotags* para compor os dados voluntários.

Apesar de todas as vantagens, o método VGI também possui desvantagens. Ao contrário da rede de sensores, não existe a possibilidade da realização de planos de amostragem. Os dados são adquiridos de acordo com a disponibilidade dos observadores voluntários. Em geral, os dados são informados com menos frequência durante a noite e em situações de mau tempo, a não ser que exista interesse direto do observador.

Além disso, diferente da rede de sensores, os dados não são obtidos através de medidores calibrados. Os dados informados pela população estão sujeitos à adição de incertezas temporais e nos valores físicos, por despreparo e algumas vezes, até mesmo de modo intencional.

3. METODOLOGIA

Este trabalho propôs um novo modelo denominado Modelo de Alerta Hidrológico com base participativa (MAHP). A construção deste modelo consistiu em integrar dados de redes de monitoramento com sensores sem fio (WSN - *Wireless Sensor Network*) e dados de sistemas geográficos de informações com base voluntária de usuários (VGI - *Volunteered Geographic Information*) e aplicar o modelo na previsão de cheias em bacias urbanas, integrando algoritmos simplificados de previsão hidrometeorológica.

A aplicação do modelo consistiu nas seguintes etapas: (i) Aquisição de dados; (ii) Previsão da precipitação; (iii) Integração dos dados no Modelo SWMM; (iv) Avaliação dos desvios do modelo e comparação dos resultados.

Figura 3: Arquitetura do modelo MAHP.

3.1. Aquisição dos dados

Os dados de campo são obtidos por diferentes fontes de dados e por diferentes meios (Figura 3), portanto necessitam ser tratados e padronizados. Nas seções seguintes serão descritos os detalhes pertinentes a aquisição e uso dos diferentes tipos de dados utilizados no modelo.

3.1.1. Dados VGI

Para a obtenção de dados VGI, existe um sistema desenvolvido por Degrossi *et al.* (2014). Os dados são informados esporadicamente via aplicativo de celular chamado **Ushaidi** ou através do website: www.agora.icmc.usp.br/enchente (Figura 4a). O voluntário pode informar o nível atual do rio ou uma escala de índice de perigo proposta por Rotava, Menciondo e Souza (2013). A plataforma aqui citada foi testada e amostrada com um grupo controlado de voluntários, mas os dados VGI utilizados nas simulações foram dados medidos por sensores devido à falta de tempo para um melhor estudo e também períodos de chuva adequados para a coleta das informações. Régua linimétrica instaladas nas paredes dos canais são utilizadas para a leitura das informações VGI como mostra a Figura 4b.

(a)

(b)

Figura 4: (a) Interface da plataforma Observatório Cidadão de Enchentes (Degrossi, *et al.* 2014).
(b) Régua para aquisição de dados VGI (Fava *et al.* 2014).

3.1.2. Critérios para uso de dados VGI

A minimização dos desvios entre as simulações e os valores medidos em campo, e, consequentemente a maior precisão nas previsões são em função dessas variáveis que serão descritas detalhadamente a seguir. Embora as régua tenham sido instaladas e os sistemas para

inserção dos dados voluntários tenha sido desenvolvidos, não existem dados VGI suficientes para verificara eficiência do método. Portanto, dados de sensores foram adotados como dados VGI. Conforme mencionado, espera-se que a incorporação de informações VGI contribuam para melhorar os resultados das previsões do modelo hidrometeorológico. Entretanto, a qualidade da melhoria depende de uma série de fatores, como por exemplo, o local informado ou a quantidade de informações fornecidas.

A elaboração teórica das variáveis que influenciam na qualidade dos dados VGI não é trivial. Algumas variáveis, como a credibilidade da informação, é citada por outros autores, conforme citado na revisão. Entretanto, outras variáveis são inerentes ao campo de estudo, neste caso, a hidrologia e necessitaram de levantamentos e reflexões.

A partir disto três situações foram propostas de acordo com as condições de monitoramento da bacia: (i) bacias com dados escassos; (ii) bacias monitoradas com modelagem e não calibradas; (iii) bacias monitoradas com modelagem e calibradas.

(i) Bacias com dados escassos - em bacias com pouco ou nenhum monitoramento, o peso das informações VGI possui grande importância, pois qualquer informação é melhor do que nenhuma, seja ela antes ou durante os eventos de chuva e em qualquer localidade da bacia são muito úteis para os tomadores de decisão.

(ii) Bacias monitoradas com modelagem e não calibradas – Estas bacias estão mais aptas para realizar a previsão de enchentes do que as bacias da primeira condição, pois através do modelo pode-se representar eventos na bacia. As informações VGI nesse caso podem ser muito úteis em momentos sem a ocorrência de chuvas, pois são oportunas para calibrar as condições iniciais dos níveis dos rios. Informações durante todo o evento de cheia (da ascensão ao declínio da onda de cheia) são importantes e podem contribuir para melhorar a previsão de enchentes. Os dados anteriores ao momento do pico podem ajudar a prevê-lo e os dados informados após o pico de cheia podem ser utilizados na calibração do modelo, para que as simulações de previsão de enchentes possam ser mais precisas em um evento posterior.

(iii) Bacias monitoradas com modelagem e calibradas – Nestes casos o uso de informações VGI deve ser utilizado com cautela e nesta condição existe a maior necessidade de preparo no tratamento dos dados adquiridos. Informações voluntárias fornecidas nos instantes em que os níveis da água não estão em ascensão possuem pouca utilidade para fins de previsão, pois espera-se que, em bacias calibradas, as simulações de níveis já estejam próximas aos valores reais. Durante eventos de enchente, os dados fornecidos antes dos momentos de pico podem ser utilizadas para melhorar a previsão desde que os dados obtidos advenham de locais relevantes

(locais com alta correlação com o ponto informado e/ou sensíveis, locais próximos a pontos de alagamento, etc.).

Tendo isso em vista, listou-se os principais fatores que supostamente podem influenciar nos resultados e concluiu-se que a previsão responde a seguinte função (Equação 4.1):

$$r = f(x, y, \lambda, \varepsilon, \tau, \sigma, T_C) \quad (\text{Eq. 4.1})$$

sendo:

r : resultado da previsão com a incorporação de dados VGI

x : localização do ponto VGI

y : número de pontos onde foram inseridas informações

λ : confiabilidade das informações obtidas

ε : número de observações no mesmo nó

τ : o instante em que a informação foi fornecida

σ : erro inerente à coleta das informações

T_C : Tempo de Concentração da bacia

Para analisar os fatores da função que influenciam no resultado da previsão é importante antes avaliar qual a condição de monitoramento da bacia, pois de acordo com isso os pesos e importância dados a cada fator mudam.

Localização do ponto VGI (x)

O local do ponto de monitoramento influencia diretamente nos resultados das previsões. A distância do ponto cuja informação foi fornecida a um ponto de interesse pode interferir nas vazões amortecendo ou acumulando excessivamente o volume escoado. A Figura 5 ilustra os principais componentes existentes em uma bacia. Níveis VGI informados próximos à nascente em geral localizam-se distantes dos pontos de interesse (pontos de alagamento). O mesmo ocorre, caso a régua seja instalada em afluentes, devido à baixa contribuição para o fluxo principal. Assim, os pontos que possuem maior relevância e que são os melhores candidatos para a instalação de réguas localiza-se nas confluências e nas proximidades dos pontos de alagamento. Cabe também listar nesta seção, a geometria da bacia.

Figura 5: Principais componentes que influenciam na previsão referentes a localização dos pontos VGI.

Número de informações ao longo do tempo (y)

A contribuição dos pontos VGI pode ser dividida quantitativamente e qualitativamente. Entre os fatores quantitativos está a quantidade de dados voluntários informados ao longo de um evento. Informações atualizadas temporalmente e espacialmente podem fornecer valores reais sobre a situação instantânea da bacia e a incorporação destas informações podem reduzir consideravelmente as incertezas das previsões. A Figura 6 (a) ilustra um exemplo de dois observadores informando os níveis em locais distintos da bacia.

Confiabilidade das informações obtidas (λ)

A vantagem dos sistemas VGI é que qualquer cidadão pode informar dados para o modelo de previsão. Entretanto, é necessário classificar os dados obtidos de acordo com a confiabilidade do voluntário. Pessoas qualificadas como funcionários da defesa civil e voluntários treinados

forneem dados mais precisos do que cidadãos comuns. Sendo assim, atribui-se pesos para classificar a qualidade dos dados. A Figura 6 (c) mostra dois voluntários fornecendo informações sobre um mesmo ponto. Os diferentes pesos atribuídos aos voluntários são indicados pelas variáveis λ_1 e λ_2 .

Figura 6: Diferentes disposições quanto a obtenção de dados voluntários. a) informações fornecidas em locais distintos. b) informações fornecidas em tempos distintos. c) Informações com diferentes níveis de confiabilidade.

Número de observações no mesmo nó (ε)

Assim como as demais informações espaço-temporais, a quantidade de informações influencia na qualidade das previsões. Caso dados conflitantes sejam informados no mesmo ponto e no mesmo instante de tempo, pode-se corrigi-los através de interpolações ou priorizando dados com pesos superiores (λ), demonstrando assim a forte relação e importância da frequência de dados e dos pesos. A Figura 6 (b) e 6 (c) mostra voluntários informando valores no mesmo nó em tempos distintos (τ_1 e $\tau_1 + \Delta t$) e ao mesmo tempo respectivamente.

Instante em que a informação é fornecida (τ)

O instante de tempo em que as informações são fornecidas possui grande importância na qualidade das previsões. O instante de tempo influencia nos resultados de duas maneiras: através

do intervalo de aquisições (intervalos menores implicam em frequências de dados maiores). Além disso, o momento em que os dados ocorrem durante alguma situação que possui significado físico como ascendência do nível, pico máximo, etc. A Figura 7 exemplifica dados VGI informados em quatro momentos diferentes.

Figura 7: Aquisição de dados VGI em diferentes instantes de tempo.

Erro inerente as informações (σ)

Assim como em qualquer aquisição de dados, a obtenção dos dados VGI está sujeita a erros aleatórios. Diversas fontes de erro podem ser listadas como erro na visualização das réguas, erros na régua (instalação inclinada, falta de precisão, nível inicial acima ou abaixo do zero, erro na digitação dos dados, erro na transmissão, etc.).

Tempo de Concentração da bacia (T_c):

O tempo de concentração da bacia tem uma influência muito grande no uso das informações VGI e também na previsão de enchentes. O tempo de concentração influencia diretamente no

tempo que se tem para emitir o alerta após o início do evento de chuva. Bacias com tempo de concentração maior propiciam que as operações de previsão, emissão de alerta e/ou medidas mitigatórias sejam iniciadas de modo menos afobado. Bacias com tempos de concentração menores são mais difíceis de se trabalhar na previsão de enchentes. O tempo de resposta destes tipos de bacia aos eventos extremos de chuva é bastante curto, portanto a previsão deve ser precisa e muito rápida. Assim, dados fornecidos durante os eventos de chuva são menos úteis.

A Figura 8 mostra um fluxograma de acordo com as três situações de monitoramento da bacia: (i) bacias sem monitoramento; (ii) bacias monitoradas com modelagem e não calibradas; (iii) bacias monitoradas com modelagem e calibradas.

Figura 8 - Fluxograma para a atribuição de peso aos fatores da equação de resultado da previsão com inserção de dados VGI de acordo com as condições de monitoramento da bacia.

3.1.3. Aplicação dos Cenários

Conforme conjecturado neste trabalho, a influência da incorporação dos dados VGI na resposta das previsões de enchentes depende de diversos fatores (Equação 4.1). A Figura 9 ilustra as combinações dos diversos fatores que influenciam na previsão de enchentes e os respectivos erros entre o valor previsto e o real para cada uma dessas combinações. Para que se quantifique estes erros é necessário fazer a verificação empírica do resultado das combinações.

Figura 9: Diferentes resíduos obtidos em função da combinação das variáveis espaço-temporais $x, y, \lambda, \varepsilon, \tau, \sigma, T_C$.

Neste trabalho não foi feito o desenvolvimento e avaliação de todos os cenários possíveis. Foram selecionadas algumas combinações de cenários, que, com os dados disponíveis julga-se serem as de ocorrência mais comuns em ambientes preparados para o recebimento de dados VGI.

3.1.4. Dados WSN

Os dados WSN foram obtidos através de nós da rede de sensores sem fio, que consistem em sensores de níveis instalados em alguns pontos na bacia (Figura 10a). Estes dados são enviados através da rede móvel para um banco de dados no Instituto de Ciências Matemáticas e

de Computação (ICMC) da USP. Os dados podem ser visualizados através da plataforma *Geodashboard*: Monitoramento dos Rios de São Carlos, que mostra o mapa da cidade, a localização dos sensores, gera gráficos dos níveis medidos e também contém a série histórica de medição, disponível em: <http://www.agora.icmc.usp.br:8080/AgoraSADEv2/> (Figura 10b).

Figura 10: (a) Sensor de nível remoto. Fonte: Fava *et al.* (2014). (b) Plataforma *Geodashboard*. Fonte: Horita *et al.* (2014).

3.1.5. Proposta de relação entre dados VGI e WSN

Para a utilização de dados voluntários (VGI) e dados de sensores (WSN) inicialmente foram feitos estudos teóricos sobre o uso de dados voluntários relacionados com dados de sensores. Foi desenvolvida uma metodologia para integrar informações voluntárias a modelos de previsão em curto prazo, apresentando uma solução para o preenchimento de dados espacialmente em locais onde não se têm sensores de monitoramento. A metodologia proposta não especificou o modelo de previsão a ser adotado, deixando em aberto as possibilidades para modelos simples ou complexos. Esta etapa foi desenvolvida somente de forma teórica, pois nem todas as hipóteses e soluções propostas foram testadas no presente trabalho.

Considerando n pontos de observação visual p_i^v para $\forall i \in [1, n]$ e k pontos de monitoramento por rede de sensores sem fio p_j^s para $\forall j \in [1, k]$. Escolhe-se um ponto de controle p_c^s para $k \geq c \geq 1$ entre os pontos de monitoramento. Dado um evento simulado ajustado de vazão com dados adquiridos de uma série histórica do ponto p_c^s obtém-se parâmetros otimizados para um modelo chuva-vazão da bacia em estudo (Figura 11). Partindo do princípio que se o

modelo teve resultados satisfatórios para o conhecido ponto p_c^s , e os pontos p_i^v estão situados na mesma bacia pode-se concluir que o modelo também prevê bons resultados para estes pontos, pois eles contribuem diretamente para o resultado simulado em p_c^s . Essa correlação utilizando o modelo chuva-vazão deve ser feita em todos os pontos p_j^s e integrados ao modelo hidrológico de previsão, exemplificado neste trabalho somente para um ponto (p_c^s).

Figura 11: Exemplo de evento simulado/ajustado no passado.

Tendo obtido as curvas através do modelo chuva-vazão, faz-se uma regressão linear entre as curvas obtidas em p_c^s com as curvas dos demais pontos p_i^v , resultando em uma reta que relaciona os valores das vazões em cada ponto sem monitoramento com o ponto conhecido p_c^s (Figura 12).

Obtidas as curvas de correlação, verifica-se que as informações colaborativas de VGI podem ser usadas para uma série de finalidades:

i) Aprimoramento e atualização em tempo real das previsões nos pontos monitorados (p_j^s), ou seja, a informação obtida colaborativamente dará como resposta um valor estimado no ponto conhecido para ser utilizada no modelo para prever o valor do nível no instante $t + 1$, dando mais confiabilidade ao modelo de previsão.

ii) Estimativa reversa, no qual se usará o valor obtido através de sensores no conhecido ponto p_c^s para estimar os valores dos níveis dos pontos não monitorados p_i^v através da curva de correlação entre eles, podendo assim preencher as lacunas de informação destes pontos em tempo real, já que estes não possuem monitoramento, somente esporádicas informações fornecidas por transeuntes.

Figura 12: Ilustração da obtenção das curvas de correlação entre os valores observados e os valores medidos através da regressão linear. No exemplo, $n=4$.

Através das curvas de correlação dos valores, o valor estimado dos níveis nos pontos onde não se tem monitoramento $h_{p_i^v}^*(t)$ retornará um valor de nível simulado $h_{p_{c,i}}^s(t)$ para o mesmo instante no ponto de controle. Aplicando uma estatística bayesiana a estes valores de nível simulados para o ponto de controle obtém-se a frequência de valores, podendo assim determinar a probabilidade de ocorrência de dado evento crítico em função do nível monitorado em outro ponto da bacia em uma previsão $h_{c|l}^*(t+1)$, Figura 13.

Figura 13: Frequência de valores dos dados simulados para o ponto de controle.

3.1.6. Dados das Estações Climatológicas

O modelo MAHP utiliza dados de estações climatológicas localizadas na superfície para a estimativa da precipitação. A previsão da precipitação é utilizada como dado de entrada no modelo chuva-vazão do SWMM.

Os dados das estações meteorológicas são variáveis climáticas compostas por temperatura do ar, umidade relativa, pressão atmosférica e também valores de precipitação. Existe uma plataforma Estação Climatológica localizada na Faculdade de Direito de São Carlos (FADISC) e possui coordenadas 22°01'07"S e 47°51'40"W que faz a coleta destes dados.

3.2. Previsão da Precipitação

A previsão da precipitação será feita de duas maneiras, explicadas a seguir:

A primeira maneira será com o ajuste dos dados anteriores para previsão do próximo instante através do cálculo de médias móveis. Para realizar a previsão da precipitação da hora seguinte, será utilizada a proposta de Georgakakos & Bras (1984), que consiste em relacionar os dados de precipitação anteriores por meio de uma regressão linear uni-variável de *lag* 1 sobre a variável que se deseja prever, analogamente ao apresentado por Andrade (2006) na Equação 4.2:

$$y_{t+1} = \bar{y} + (y_t - \bar{y}) \cdot \rho_y + \varepsilon_1 \cdot \sigma_y \cdot \sqrt{(1 - \rho_y^2)} \quad (\text{Eq. 4.2})$$

sendo y_{t+1} o valor da previsão no instante $t+1$, $\bar{y}$ é a média da variável y , ε_1 é um erro aleatório entre 0 e 1, σ_y é o desvio padrão da variável y , e ρ_y é o coeficiente de autocorrelação de *lag* 1 dado pela Equação 4.3:

$$\rho_y = \frac{\sum_{t=1}^{n-1} (y_t - \bar{y}) \cdot (y_{t+1} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (\text{Eq. 4.3})$$

sendo n o número de intervalos considerado para a autocorrelação.

A segunda maneira para realizar a previsão é através da utilização de dados da estação climatológica exclusivamente. O modelo de previsão de precipitação utilizando somente dados climatológicos será baseado no que foi inicialmente proposto por Georgakakos & Bras (1984) e

aplicado por Andrade (2006) sem a adição das informações de radar. Uma estação climatológica fornece valores de temperatura pressão e umidade relativa e através destes é possível prever uma precipitação um passo à frente. Para isso são inicialmente calculados temperatura, pressão e umidade relativa um passo à frente através de uma correlação entre os valores anteriores dos mesmos, e com a junção destes três fatores climatológicos é obtida a precipitação um passo à frente. Resultados iniciais desse modelo de previsão estão descritos por Fava *et al.* (2014).

De acordo com o modelo de previsão proposto por Georgakakos e Bras (1984), duas variáveis adimensionais necessitam ser calculadas:

N_v e N_d . A primeira variável é definida como um indicativo da força da velocidade de ascensão na base da nuvem. E a segunda variável é a medida da influência do processo de difusividade.

$$N_v = \frac{V_\beta c}{\alpha} \quad (\text{Eq. 4.4})$$

onde V_β é a velocidade terminal das partículas; c é um coeficiente que varia linearmente com a altura da nuvem e α é um coeficiente [$\alpha = 3500 \text{ S}^{-1}$].

$$N_d = c D_c \quad (\text{Eq. 4.5})$$

onde D_c é o diâmetro crítico, abaixo do qual todas as partículas são evaporadas completamente antes de atingir o solo.

A velocidade (V_β) é calculada em função das variáveis ε_1 , ε_2 e ε_3 . E o diâmetro médio da base da nuvem (c) é calculado em função da velocidade (V_β) e da variável ε_4 conforme explicado por Andrade (2006). Finalmente são utilizadas as seguintes equações para o cálculo da precipitação (P):

Para: $N_D \geq N_v$

$$P = \frac{X}{\delta Z_c} v_p \left[\frac{1 - \left(\frac{N_v}{4}\right) \left(1 + N_D + \frac{N_D^2}{2}\right) + \frac{N_D^3}{8}}{e^{N_v}} \right] \quad (\text{Eq. 4.6})$$

Para: $N_D < N_v$

$$P = \frac{X}{\delta Z_c} v_p \left[\frac{1 + \frac{3}{4}N_v + \frac{N_v^2}{4} + \frac{N_v^3}{24} + \frac{N_D^3}{24}}{e^{N_v}} \right] \quad (\text{Eq. 4.7})$$

3.3. Integração dos dados no modelo SWMM

As séries históricas dos pontos da rede WSN de São Carlos foram utilizadas como dados de entrada para o modelo SWMM. O modelo então gera a previsão de nível para estes pontos e para todos os outros nós da bacia.

Até esta parte do trabalho, explicou-se como são coletadas as informações através da rede WSN, bem como os dados voluntários e como esses dados são integrados pelo modelo MAHP. Também apresentou-se como o SWMM realiza seus cálculos de previsão de vazões e níveis, utilizando os dados de sensores como dados de entrada. Através dos módulos de previsão de precipitação e com os dados dos sensores, o MAHP já é capaz de realizar as previsões. A partir desta etapa, utiliza-se o módulo VGI do modelo MAHP, com a finalidade de modificar a bacia modelada no SWMM, atualizando seus parâmetros com as informações VGI no momento em que são fornecidas pelos voluntários.

Após atualizar o modelo da bacia com a informação VGI recém informada, o modelo MAHP realiza a simulação das previsões para os instantes seguintes.

O modelo MAHP para fazer a previsão de enchentes utiliza as informações de precipitação obtidas do módulo de previsão da precipitação como entrada para simulação de chuva-vazão no SWMM. Com a chuva prevista, os níveis simulados pelo SWMM são uma previsão do estado da bacia para aquele evento de chuva previsto. No presente trabalho, as duas etapas foram analisadas de forma separada para que os erros e desvios de cada módulo fossem analisados separadamente. A previsão da precipitação foi feita e os erros e desvios calculados, mas as precipitações previstas resultantes não foram utilizadas nas simulações. Nas simulações chuva-vazão no SWMM foram utilizados hidrogramas de chuva medidos.

Os hidrogramas de chuva e dados físicos (rugosidades das áreas, coeficientes de infiltração, etc) foram utilizados como dados de entrada para a modelagem da bacia no SWMM. Após modelagem da bacia, efetuou-se a calibração manual do modelo. A calibração consistiu na minimização da diferença do erro entre as vazões obtidas no modelo e as vazões medidas em campo. Para tanto, são utilizados como dados de calibração, os dados medidos pelos sensores

WSN e pelos dados VGI. O modelo simulará o nível em todos os pontos da bacia, sempre considerando a vazão inicial em cada trecho.

Com a inclusão de dados VGI no modelo hidrometeorológico, espera-se uma redução das incertezas na previsão de nível e maior confiabilidade na emissão de alertas, quando detectado alto índice de perigo. Com a atualização de uma informação em local onde não há monitoramento por sensor, somente uma estimativa feita automaticamente pelo modelo, faz com que seja ajustada a diferença de erro através das curvas de correlação, não só do nó onde foi feita a observação, mas em todos os nós da bacia, dando assim maior confiabilidade na previsão (Figura 14).

Figura 14: Redução da incerteza através do modelo MAHP. A hipótese é de que exista uma diminuição no IC (intervalo de confiança) com o novo modelo proposto.

3.4. Avaliação dos Desvios do Modelo

Após realizar as previsões pode-se comparar os resultados obtidos através das simulações utilizando exclusivamente dados WSN e com a contribuição dos dados VGI. Diversos critérios têm sido utilizados para calcular os desvios entre os modelos e os valores reais na literatura. Embora possuam finalidade semelhantes, existem métodos mais apropriados para determinadas funções. Neste trabalho, os erros serão calculados e avaliados de acordo com os métodos mais utilizados na literatura. Para comparar o erro relativo nas vazões de pico e profundidade dos níveis utiliza-se o erro relativo (ER) para um valor arbitrário x utiliza-se a Equação 4.8:

$$ER = \frac{x_0 - x_s}{x_0} \quad (\text{Eq. 4.8})$$

sendo x_0 o valor observado de uma variável hidrológica e x_s o valor simulado da mesma variável.

Para as vazões é comum o uso do cálculo do erro da raiz média dos quadrados ou RMSE (*Root Mean Square Error*) definido como (4.12) (CHOI; BALL, 2002) são considerados melhores resultados quando encontrados valores próximos a 0:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n [Q_0(i) - Q_s(i)]^2}{n}} \quad (\text{Eq. 4.9})$$

sendo $Q_s(i)$ e $Q_0(i)$ as vazões simuladas e observadas respectivamente e n o número de observações na série de dados.

Outro método de avaliação bastante utilizado é o coeficiente de Nash-Sutcliffe (Equação 4.10). Este método é considerado útil por ser sensível a valores extremos, e portanto pode não ser eficiente para séries de dados com *outliers*. São considerados melhores os valores próximos a 1.

$$E = 1 - \frac{\sum_{i=1}^n [Q_0(i) - Q_s(i)]^2}{\sum_{i=1}^n [Q_0(i) - \bar{Q}_0]^2} \quad (\text{Eq. 4.10})$$

Existe também o coeficiente de Nash-Sutcliffe para vazões baixas. Matematicamente, o uso de logaritmos (Equação 4.11) nos termos faz com que amortecem-se os picos, privilegiando o ajuste para vazões menores:

$$E = 1 - \frac{\sum_{i=1}^n [\ln Q_0(i) - \ln Q_s(i)]^2}{\sum_{i=1}^n [\ln Q_0(i) - \ln \bar{Q}_0]^2} \quad (\text{Eq. 4.11})$$

sendo $\bar{Q}_0$ a média das vazões observadas e $Q_s(i)$ e $Q_0(i)$ já definidas.

4. RESULTADOS E DISCUSSÃO

5.1 Levantamento das características da bacia

O modelo MAHP será aplicado à bacia urbana do Monjolinho, São Carlos, com um grande número de tributários que contribuem em uma única unidade de drenagem. Foram instalados sensores de nível em pontos estratégicos da bacia que compõem a WSN e réguas linimétricas para a aquisição de dados VGI. Também foram realizados levantamentos topobatimétricos das que foram incorporadas ao modelo. A bacia foi modelada utilizando o software SWMM (*Storm Water Management Model*). O modelo faz cálculo de chuva-vazão e simulação de cenários.

Figura 15: Representação do Modelo Hidrológico e da topografia da bacia.

O estudo de viabilidade, testes e instalação da rede de sensores sem fio em São Carlos já vinha sendo estudada por Degrossi *et al.* (2013) onde descrevem que o Brasil tem a característica de rios de grande extensão, dificultando, assim, o uso de alguns sensores e apontando as soluções encontradas para a aplicação da rede de sensores na bacia em estudo.

Para a modelagem da bacia urbana do Monjolinho foi necessário fazer o levantamento topobatimétrico das sessões de interesse para a descrição no modelo. Para a escolha dos locais a serem medidos foram adotados os pontos definidos por Zaffani (2012) visando dar prosseguimento a trabalhos já realizados (Figura 16).

Figura 16: Bacia do Monjolinho, pontos de monitoramento (ZAFFANI, 2012).

Em cada um dos quinze pontos foi feita a batimetria das seções, o levantamento da declividade do canal, medidas a vazão nas verticais e calculadas as vazões dos canais pelo método da Meia Seção. Foram feitas três campanhas de medição de vazão, nos dias 02/09/2013, 14/10/2013 e 25/11/2013. Foram também instaladas réguas linimétricas nos quinze pontos para a coleta de dados voluntários.

(a)

(b)

Figura 17:(a) Medição de vazão em canal natural, Ponto 4 em 25/11/2013 (b) Medição de vazão em canal construído Ponto 7 em 14/10/2013.

Figura 18: Detalhamento gráfico das batimetrias nos pontos 4 e 7.

Nas três campanhas de campo foram avaliadas as condições do leito dos canais e do entorno destes. De acordo com as condições dos canais foram estimados os coeficientes de rugosidade. Com auxílio das informações coletadas em campo e de imagens de satélite do Google Earth[®] foram determinados os CN da bacia, que posteriormente foram utilizados para modelagem no SWMM.

5.2 Modelagem da bacia do Monjolinho no SWMM

Para a modelagem da bacia foi utilizado um Modelo Digital de Elevação (DEM), disponibilizado pela NASA através do programa ASTER versão 2 com resolução de 30m (NASA, 2001). O Sistema de Informação Geográfica (SIG) ArcGis[®] com o auxílio da extensão ArcSWAT foram utilizados para a delimitação da bacia de São Carlos utilizando o modelo digital de elevação obtido (DEM).

Foi feito o desenho da rede fluvial da bacia, extração das informações de elevação, coordenadas geográficas, comprimento dos afluentes e corpo hídrico principal, declividades, área

total da bacia e área das sub-bacias (Figura 19). As sub-bacias foram delimitadas de acordo com os 15 pontos de monitoramento (Figura 16), sendo cada um dos pontos considerado o exutório de cada sub-bacia. Cada sub-bacia possui características determinadas pelos parâmetros descritos na Tabela 1.

Figura 19: Delimitação da bacia do Monjolinho no ArcGis®.

Tabela 1: Parâmetros de caracterização das sub-bacias no modelo SWMM.

Parâmetro	Unidade
Área	ha
Largura	m
Declividade	%
Áreas impermeáveis	%
Coeficiente de rugosidade de Manning para áreas impermeáveis	-
Coeficiente de rugosidade de Manning para áreas permeáveis	-
Profundidade de armazenamento em depressões em áreas impermeáveis	mm
Profundidade de armazenamento em depressões em áreas permeáveis	mm
Áreas impermeáveis sem armazenamento em depressões	%
Curve Number (CN) do modelo de infiltração	-

A área de cada sub-bacia, largura e declividade foram dados extraídos do DEM da bacia do Monjolinho. O valor CN para o modelo de infiltração foi estimado segundo a tabela de valores apresentada por Cronshey (1986):

Tabela 2: *Curve numbers* de escoamento para áreas urbanas.

Tabela 27. Curva numbers de escoamento para áreas urbanas.					
Tipo de cobertura e condição hidrológica	% de área impermeável	CN para grupos de solo			
		A	B	C	D
Áreas urbanas completamente desenvolvidas					
Espaços abertos (parques, campos de golfe, cemitérios, etc)					
Condições pobres (cobertura vegetal < 50%)		68	79	86	89
Condições medianas (cobertura entre 50% a 75%)		49	69	79	84
Condições boas (cobertura > 75%)		39	61	74	80
Áreas impermeáveis					
Estacionamentos pavimentados, rodovias, etc		98	98	98	98
Valetas		83	89	92	93
Terreno com cascalho		76	85	89	91
Distritos urbanos					
Distritos comerciais	85	89	92	94	95
Distritos industriais	72	81	88	91	93
Distritos residenciais por lote médio					
1/8 acre	65	77	85	90	92
1/4 acre	48	61	75	83	87
1/3 acre	30	57	72	81	86
1 acre	20	51	68	79	84
2 acres	12	46	65	77	82

Adaptado de: Cronshey (1986).

Em cada nó que fica nas saídas e entradas dos trechos de canais representados pelo modelo possuem características determinadas pelos parâmetros descritos na Tabela 3.

Tabela 3: Parâmetros de caracterização dos nós no modelo SWMM.

Parâmetro	Unidade
Afluência	m ³ /s
Altitude	m
Altura máxima do fluxo para que extravase o canal	m
Altura inicial do corpo d'água	m

A valores de afluência foram calculados de acordo com os valores de vazão aferidos nas campanhas de campo realizadas. A altitude foi extraída do DEM da bacia do Monjolinho e as alturas máxima e inicial do corpo d'água foram estimadas de acordo com a batimetria feita na sessão próxima ao nó.

Em cada trecho que liga os nós dos canais representados pelo modelo possuem características determinadas pelos parâmetros descritos na Tabela 4.

Tabela 4: Parâmetros de caracterização dos trechos no modelo SWMM.

Parâmetro	Unidade
Profundidade máxima da sessão transversal	(m)
Comprimento	(m)
Coefficiente de Manning para rugosidade em canais	-
Vazão inicial	m³/s

Os valores de profundidade máxima da sessão transversal foram estimados através das batimetrias feitas nas campanhas de campo. O comprimento de cada trecho foi extraído do DEM da bacia do Monjolinho. O coeficiente de rugosidade de Manning para canais foi estimado de acordo com os valores da Tabela 5. Os valores de vazão utilizados foram os valores medidos em campo.

A bacia foi modelada utilizando o software SWMM (*Storm Water Management Model*). O modelo faz cálculo de chuva-vazão e simulação de cenários. Foram considerados na modelagem 35 nós e 15 sub-bacias com áreas de drenagem variando entre 0,011 e 2,18 km². A área total da bacia é de 76,8 km² e possui densidade populacional de 194,53 hab/km². Apresenta altitude média de 856 metros em relação ao nível do mar e um solo considerado de alta permeabilidade. A discretização das sub-bacias foi feita de maneira bem simples, e contendo pouquíssimos nós, isso se deu por não se ter dados coletados em outros pontos além dos que foram na modelagem adicionados, sendo assim, optou-se por fazer o modelo de forma simplificada, mas aplicando-se informações medidas em campo em todos os pontos.

Tabela 5: Referências para n de Manning em diferentes conformações.

Escoamento superficial		
Tipo de superfície	Coeficiente	
Sarjeta de concreto	0,016	
Asfalto liso	0,013	
Asfalto áspero	0,016	
Pavimento de concreto liso	0,013	
Pavimento de concreto áspero	0,015	
Pasto, grama baixa	0,040	
Pasto, grama alta	0,050	
Áreas cultivadas	0,030	
Regiões muito arborizadas	0,150	
Regiões com média arborização	0,040	
Cursos d'água naturais		
Curso d'água	Mínimo	Máximo
Seção regular	0,030	0,070
Fundo de cascalho, seixos e poucos matacões	0,040	0,050
Fundo de seixos com matacões	0,050	0,070
Seção irregular com poços	0,040	0,100
Canais escavados sem revestimento		
Tipo de canal	Mínimo	Máximo
Terra, limpo, fundo regular	0,028	0,033
Terra com capim nos taludes	0,035	0,060
Sem manutenção	0,050	0,140
Canais revestidos		
Revestimento do canal	Mínimo	Máximo
Concreto	0,013	0,016
Gabião manta	0,022	0,027
Gabião caixa	0,026	0,029
VSL	0,015	0,017
Rip-rap	0,035	0,040
Pedra argamassada	0,025	0,040
Grama	0,150	0,410

Adaptado de Chow (1959).

Na modelagem optou-se pelo modelo de infiltração baseado na Curva Número do SCS. Este método é uma aproximação adotada a partir da Curva Número (CN) do NRSS (*National Resources Conservation Service*) para estimativa do escoamento superficial. O modelo de propagação de fluxo adotado foi o da onda dinâmica.

Figura 20: Representação da modelagem matemática da bacia em estudo, onde cada número representa a discretização da sub-bacia.

5.3 Previsão da precipitação

Um software integrado ao módulo *Brain* foi desenvolvido para realizar a previsão da precipitação utilizando dois métodos: o modelo físico proposto por Georgakakos & Bras (1984) e o método de autocorrelação univariada, que utiliza três passos anteriores para prever o próximo passo (*lag* 3). Os códigos foram desenvolvidos em linguagem C padrão utilizando a IDE gratuita Code::Blocks e o compilador GNU GCC para Windows.

Para avaliar as previsões, escolheu-se um dia arbitrário com dados de precipitação, que foram utilizados como dados de entrada em ambos os modelos para avaliação das previsões. Os dados estavam originalmente amostrados com frequência de 10 minutos e foram convertidos para intervalos de uma hora. Embora as previsões com pequenos intervalos apresentem resultados melhores, optou-se por intervalos de uma hora, pois, para objetivos de previsão de enchentes, é

necessário intervalos de tempo espaçados o suficiente para que as medidas necessárias possam ser tomadas.

Os resultados das previsões foram subdivididos em (i) Previsão da precipitação utilizando modelo conceitual de Georgakakos & Bras (1984); (ii) Previsão da precipitação utilizando o modelo empírico; (iii) Comparação dos resultados de previsão da precipitação de cada método.

5.3.1. Previsão utilizando modelo conceitual

A previsão de precipitação utilizando dados climatológicos proposta inicialmente por Georgakakos & Bras (1984) foi aplicada por Andrade (2006). A estação meteorológica fornece valores de temperatura, pressão e temperatura do ponto de orvalho e com estes dados é calculada a previsão da precipitação um passo em frente.

O método conceitual exige o ajuste dos parâmetros ε_1 , ε_2 , ε_3 e ε_4 . Nos trabalhos realizados por Andrade (2006) e Gonçalves (2009), estes parâmetros foram ajustados de forma manual, entretanto, para que as previsões apresentassem melhores resultados, os parâmetros foram otimizados com o auxílio de algoritmos genéticos. Algoritmos genéticos são métodos de busca e otimização inspirados na teoria da evolução natural (Goldberg, 2006). O software de otimização foi desenvolvido com auxílio da biblioteca GALib para C++ (Wall, 1996). Foram utilizados o esquema de AG *Steady-state* (populações sobrepostas), algoritmo de seleção *RouletteWheel* (seleção da roleta), operador de *crossover SinglePointCrossover* (recombinação de ponto único) e operador de mutação *SwapMutator*. Os parâmetros de execução do AG foram população inicial de 150 indivíduos; 10000 gerações; probabilidade de crossover de 80%; probabilidade de mutação: 2% e taxa de substituição populacional de 60%. A função objetivo da otimização consistiu em maximizar o coeficiente de eficiência E de Nash-Sutcliffe (Equação 5.1):

$$\begin{aligned} \text{FO} &= \max E \\ \text{s.a.} \quad &\begin{cases} \varepsilon_1 \min \leq \varepsilon_1 \leq \varepsilon_1 \max \\ \varepsilon_2 \min \leq \varepsilon_2 \leq \varepsilon_2 \max \\ \varepsilon_3 \min \leq \varepsilon_3 \leq \varepsilon_3 \max \\ \varepsilon_4 \min \leq \varepsilon_4 \leq \varepsilon_4 \max \end{cases} \end{aligned} \quad (\text{Eq. 5.1})$$

O *software* foi desenvolvido com duas funções objetivo: (i) utilizando o coeficiente de eficiência de Nash-Sutcliffe e (ii) o coeficiente de Nash-Sutcliffe para baixas vazões. O objetivo

do trabalho é a previsão de enchentes então utilizou-se o coeficiente Nash-Sutcliffe tradicional por ser o mais apropriado para o caso.

A Figura 21 mostra a tela principal do software desenvolvido. A parte do programa responsável pelo cálculo da previsão da precipitação foi feita utilizando o código legado do trabalho de Andrade (2006), o programa foi alterado em algumas partes para adaptar-se a nova interface e à otimização dos parâmetros aqui descrita. Para testar o modelo de previsão, escolheu-se uma data com uma precipitação aleatória para ser utilizada como dado de entrada do modelo.

Figura 21: Captura de tela do software de previsão da precipitação desenvolvido.

O software realizou a otimização para previsão e finalizou a execução após aproximadamente 4 horas. Os valores obtidos para os parâmetros são listados na Tabela 6.

Tabela 6: Ajuste dos parâmetros do modelo conceitual.

Parâmetro	Valor ótimo encontrado
ε_1	0,00403
ε_2	62725,06
ε_3	0,95496
ε_4	0,00028

5.3.2. Previsão utilizando modelo empírico

O segundo método de previsão da precipitação foi através da autocorrelação univariada de *lag* 3. Outro software foi desenvolvido e acoplado ao módulo Brain para a execução das previsões.

A metodologia proposta pelo Georgakakos & Bras (1984) é usada para executar a previsão de chuva para a próxima hora, que consiste em relacionar os dados de precipitação anteriores através de uma regressão linear univariada para se fazer a previsão. A autocorrelação consistiu na previsão do instante $t+1$ através da regressão linear nos 3 instantes anteriores (t , $t-1$ e $t-2$) de um vetor fornecido. O vetor consistiu nos mesmos dados de precipitação utilizados para a previsão utilizando o modelo conceitual.

5.3.3. Comparação da previsão entre o modelo conceitual e empírico

Após as simulações dos modelos de previsões, foram calculados os desvios entre os valores observados e simulados. A previsão utilizando o modelo conceitual apresentou coeficiente E de 0,2229, enquanto utilizando o modelo empírico foi de -0,1621. A Figura 22 mostra o gráfico com o resultado das previsões. A linha azul mostra a precipitação real do dia em mm. O modelo conceitual é mostrado com a linha vermelha e a linha verde mostra a previsão utilizando o modelo empírico. Visualmente verifica-se que o modelo conceitual aproxima-se mais da precipitação real do que o modelo empírico. No entanto, no instante com o pico de precipitação (8h), o modelo conceitual subestimou o valor real. O modelo empírico apresentou valores mais próximos aos reais nos horários posteriores ao pico da precipitação, pois utiliza-se dos dados históricos, sendo assim, este modelo acompanha a série real, sem apresentar dados destoantes, no entanto, os dados sempre serão atrasados em relação aos dados reais, sendo prejudicados nos instantes de chuva intensa.

Figura 22: Precipitação real vs previsões de precipitações através de modelos conceitual e empírico, São Carlos – SP (27/12/2003).

Figura 23: Precipitação real acumulada vs previsões de precipitações acumuladas através de modelos conceitual e empírico.

Embora o modelo conceitual tenha apresentado um grande desvio na previsão nos horários de pico, o modelo foi capaz de estimar o volume total precipitado de forma satisfatória. A Figura 23 mostra o gráfico da precipitação acumulada prevista pelos dois métodos utilizados e a precipitação acumulada real. A precipitação prevista através do modelo conceitual apresentou melhor aderência aos dados reais comparados ao modelo empírico. O volume acumulado real no período foi de 11,53mm, enquanto o volume previsto pelo método conceitual foi de 10,10mm, demonstrando que o método conceitual é bastante eficiente para previsões diárias. O volume acumulado no final do período através do método empírico foi de 15,72mm.

5.4 Previsão de enchente

Esta seção irá apresentar as simulações de chuva-vazão feitas no modelo SWMM. Serão apresentados os seguintes resultados: (i) Simulações usando chuvas medidas em eventos extremos de chuva ocorridos na cidade de São Carlos, verificando o ajuste da bacia modelada em relação ao evento realmente ocorrido; (ii) Simulações usando chuvas medidas em eventos extremos de chuva ocorridos na cidade de São Carlos inserindo dados VGI para verificação da influência dessas informações nos resultados.

5.4.1. Simulações no SWMM

Foram feitas simulações para o evento de chuva dos dias 04/11/2013 e 05/11/2013. O hidrograma de chuva utilizado foi fornecido pelo Instituto Nacional de Meteorologia (INMET). Os dados são obtidos através de uma estação meteorológica automática localizada em São Carlos – SP a uma altitude de 863 m, Latitude 21°57'S e Longitude 47°52'W. Os dados não passaram por um processo de consistência (ainda não tinham sido validados pelo Instituto).

As simulações foram feitas em três pontos distintos da bacia. Os três pontos estão representados na Figura 24 como N-1, N-2 e N-3. Nos três pontos existem sensores de monitoramento de nível que enviam dados em tempo real, com os quais foi possível se fazer a aferição do erro das simulações feitas utilizando o SWMM.

O ponto de monitoramento N-1 está localizado no Córrego do Monjolinho logo após a confluência com os córregos Santa Maria do Leme e Tijuco Preto. O ponto de monitoramento N-2 está localizado no exutório da bacia urbana neste trabalho modelada. O ponto de monitoramento N-3 está localizado no Córrego Santa Maria do Leme antes de virar um contribuinte do Córrego do Monjolinho.

Figura 24: Pontos de monitoramento N-1, N-2 e N-3 utilizados nas simulações.

A Figura 25 mostra o gráfico dos níveis medidos pelo sensor de pressão no ponto N-1 e os valores simulados pelo modelo. Houve falha na leitura do sensor entre as 04h40min da manhã do dia 04/11/2013 até aproximadamente às 07h40min da manhã do mesmo dia. Por ser um período sem chuva a falha não influenciou na análise. Outra falha de leitura ocorreu entre 00h05min e 07h30min da manhã do dia 05/11/2013, durante o decréscimo da onda de cheia ocasionada pela chuva. Nota-se apesar do período sem medições que o modelo está simulando valores inferiores aos reais durante o decréscimo. Durante os picos os valores foram relativamente superestimados, tendo um ajuste ideal no pico das 14h30min. Como o objetivo da previsão é detectar os picos onde acontecem alagamentos, considera-se esse um bom resultado, pois o maior pico de cheia foi simulado adequadamente neste evento.

Figura 25: Gráfico dos níveis observados e simulados no ponto N-1 durante o evento de chuva dos dias 04/11/2013 e 05/11/2013.

A Figura 26 mostra o gráfico dos níveis medidos pelo sensor de pressão no ponto N-2 e os valores simulados pelo modelo. Houve falha na leitura do sensor no começo da série, começando a leitura dos dados reais às 10h40min. Por ser um período sem chuva a falha não influenciou na análise. Este ponto de monitoramento fica no exutório da bacia e é um ponto de grande interesse por se tratar de um local que tem histórico de alagamento em eventos chuvosos extremos. O primeiro pico às 12h00min o valor simulado foi superestimado, já o pico seguinte das 15h00min o valor simulado ficou um pouco abaixo do real. Os resultados mostram a necessidade de alguns ajustes no modelo, em sessões e canais a montante da localização deste ponto. Por se tratar de um ponto no extremo da bacia, ele depende do bom ajuste de todos os canais da bacia.

Figura 26: Gráfico dos níveis observados e simulados no ponto N-2 durante o evento de chuva dos dias 04/11/2013 e 05/11/2013.

O gráfico dos níveis medidos pelo sensor de pressão no ponto N-3 e os valores de nível simulados pelo modelo (Figura 27) mostram um bom ajuste nessa sessão aos pequenos picos de nível devido à chuva um bom ajuste aos níveis normais (condição sem chuva). Os grandes picos não tiveram uma resposta condizente do modelo. Necessitam-se mais testes para determinar as causas de não se refletir os picos reais. Podem ter sido ocasionadas por um mal ajuste dos parâmetros físicos do modelo, este evento de chuva pode ter ocorrido mais intensamente na região à jusante deste ponto de monitoramento, etc.

Figura 27: Gráfico dos níveis observados e simulados no ponto N-3 durante o evento de chuva dos dias 04/11/2013 e 05/11/2013.

A Tabela 7 mostra o cálculo do desvio entre os dados observados e simulados utilizando NSE - Eficiência Nash-Sutcliffe (valores mais próximos de 1 são melhores) e RMSE - Erro Quadrático Médio (valores mais próximos de 0 são melhores).

Tabela 7: Desvio das simulações.

	NSE	RMSE
Sensor N-1	0.755	0.253
Sensor N-2	0.618	0.188
Sensor N-3	0.551	0.372

Observando-se os valores da tabela, podemos ver que o melhor ajuste foi no ponto N-1 se considerarmos a Eficiência Nash-Sutcliffe e no ponto N-2 se considerarmos o Erro Quadrático Médio, sendo maior o erro no ponto N-3 em qualquer uma das duas estatísticas. Como a Eficiência Nash-Sutcliffe é mais sensível aos erros nos picos, considera-se que o ponto N-1 foi o que obteve um melhor ajuste para os objetivos do presente estudo.

Os pontos N-1 e N-2 estão localizados no mesmo canal, no córrego do Monjolinho, o ponto N-2 está mais a jusante e fica no exutório da bacia urbana considerada nesse estudo. O

ponto N-2 está sujeito a maiores incertezas, já que ele tem o acumulo de vazões de todos os contribuintes da bacia. Os dois pontos N-1 e N-2 são muito importantes para esse estudo pois se encontram em locais onde já foram registrados alagamentos durante diversos eventos de chuva extremos. O ponto N-3 encontra-se no córrego Santa Maria do Leme, e necessitam-se mais estudos para que se faça um melhor ajuste no modelo, que seja capaz de descrever mais fielmente os picos ocorridos neste ponto.

5.4.2. Simulações utilizando dados VGI

Para a simulação utilizando dados VGI, foram executadas duas simulações para comparar a eficiência da nova metodologia utilizando dados de precipitação intensa dos dias 04/11/2013 e 05/11/2013. Considerando a Equação 4.1 [$r = f(x, y, \lambda, \varepsilon, t, \sigma)$], já descrita anteriormente, existem seis fatores considerados capazes de influenciar nos resultados utilizando dados VGI. Estes fatores estão listados a seguir e é feita a descrição de como eles foram avaliados para o caso sendo estudado no presente trabalho:

x : localização do ponto VGI – as informações VGI foram informadas no ponto N-1 que fica a montante do ponto de simulação N-2.

y : número de pontos onde foram inseridas informações – todas as informações foram feitas no mesmo nó N-1.

λ : confiabilidade das informações obtidas – as informações não advieram de informantes, foram retiradas de valores medidos por sensores de nível (para efeitos de estudo) sendo assim consideradas 100% confiáveis.

ε : número de observações no mesmo nó – as informações foram inseridas regularmente de duas em duas horas no nó N-1, num total de 19 informações no decorrer de 24 horas. Sendo que 4 informações não foram inseridas devido aos períodos sem medição.

τ : o instante em que a informação foi fornecida – as informações foram inseridas durante todo o evento de chuva, abrangendo o início do evento, o momento de pico e o decréscimo da onda de cheia.

σ : erro inerente à coleta das informações – não foi considerado nenhum erro referente a leitura das informações, já que essas foram adquiridas através de sensores já calibrados.

T_C : Tempo de Concentração da bacia – O tempo de concentração da bacia urbana de São Carlos é de duas horas.

O objetivo principal desta etapa é testar uma combinação de fatores que influenciam no resultado da previsão e verificar a eficiência da contribuição de dados VGI nessa simulação. A Figura 28 mostra os resultados obtidos. A linha azul representa o nível de água observada no ponto N-2. As outras duas linhas são os níveis simulados utilizando o modelo original (linha verde) e a simulação com modelo atualizado com dados VGI (linha vermelha). Os espaços sem pontos nas linhas, são períodos onde se teve falha do sensor, não tendo medição do valor real de nível naqueles instantes. As duas simulações permanecem muito perto ao longo de toda a série histórica com os valores da linha vermelha (com dados VGI) ligeiramente acima da linha verde.

Figura 28: Simulações utilizando dados de sensores e dados VGI no ponto N-1.

Visualmente, as duas previsões foram bastante semelhantes entre si. Isto ocorre devido ao decaimento da celeridade do sistema de cálculo do SWMM (condição CFL, melhor descrita em Courant; Friedrichs & Lewy, 1928), fazendo com que os valores atualizados dentro do modelo sejam amortecidos pelos cálculos internos. Os resultados obtidos levam as seguintes conclusões:

(i) O rápido decaimento da função ilustrada pelo gráfico demonstra que a hipótese proposta não é

adequada para bacias com baixos tempos de concentração e grandes passos de simulação pois tal amortecimento faz com que a informação nova inserida seja perdida ao longo do tempo. (ii) Para o caso da metodologia ser utilizada nas bacias com altos tempos de concentração, as réguas linimétricas devem ser instaladas nos cursos principais dos rios, pois a contribuição de braços secundários pode ter pouca influência nas vazões e níveis totais. (iii) O uso de correlações entre as informação voluntárias fornecidas em um ponto na bacia com todos os outros pontos a jusante dessa informação é uma possibilidade a ser investigada para que os dados VGI tenham um peso maior na redução da incerteza na previsão de enchentes, conforme a metodologia teórica proposta. (iv) a inserção do dado VGI só é eficiente se o modelo hidrológico estiver modelado de forma satisfatória. Sabe-se que os resultados das simulações dependem da sinergia entre todos os parâmetros envolvidos, e, mesmo valores errados podem levar a simulações coerentes. Nestes casos, a inclusão dos dados VGI pode levar resultados que não correspondem à realidade. Estes resultados foram consistentes com o trabalho desenvolvido por Nguyen *et al.* (2013) discutido na revisão bibliográfica.

Ambas as simulações apresentaram um bom ajuste nos picos, mas ao contrário das expectativas, as simulações utilizando dados VGI não apresentaram muita vantagem em relação a simulação utilizando o modelo original. Analisando o gráfico (Figura 28) percebe-se que os níveis de água simulados em ambos os casos apresentam valores acima dos valores observados nas primeiras horas, indicando a necessidade de mais ajustes no modelo. O módulo do modelo MAHP que atualiza os valores de nível no arquivo de entrada altera o valor do nível inicial no ponto onde foi dada a informação, de modo a minimizar a diferença entre o nível informado (dados VGI) e a simulação no nó.

A Tabela 6 mostra o valor do desvio entre os dados observados e simulados utilizando NSE - Eficiência Nash-Sutcliffe (valores mais próximos a 1 são melhores) e RMSE - Erro Quadrático Médio (valores mais próximos a 0 são melhores).

Tabela 8: Desvio das simulações

	NSE	RMSE
Simulação sem VGI	0.875	0.272
Simulação com VGI	0.768	0.255

5. CONCLUSÕES E RECOMENDAÇÕES

5.1. CONCLUSÕES

De acordo com os resultados obtidos e considerando os objetivos traçados no capítulo 2, as conclusões do trabalho são descritas a seguir:

Objetivo: Desenvolver uma metodologia de integração dos dados de redes de monitoramento WSN e dados VGI para o preenchimento de um banco de dados a ser utilizado no modelo de previsão.

Os dados provenientes da rede de sensores sem fio WSN foram implementados no modelo de forma satisfatória. Os dados auxiliaram na modelagem da bacia no modelo SWMM, fornecendo valores iniciais de nível para o modelo e auxiliaram na calibração manual da bacia. Foram utilizados eventos de chuva extrema medidos pelos sensores para avaliar os desvios nas simulações.

Os sensores da rede WSN não registraram alguns períodos de dados devido ao mal funcionamento dos sensores e problemas na transmissão dos dados. Apesar das vantagens teóricas da medição através da rede WSN na prática os sensores precisam de manutenção preventivas e corretivas continuamente.

A metodologia de inserção de dados VGI proposta no trabalho e a análise das diferentes combinações de como a informação é dada foram importantes para o desenvolvimento de uma hipótese do uso de dados VGI para a previsão de eventos extremos. Mais estudos são necessários para validar a hipótese proposta neste trabalho.

Objetivo: Avaliar modelos de previsão da precipitação conceituais e empíricos objetivando melhorar os resultados da previsão de enchentes.

Foram desenvolvidos dois *softwares* para previsão da precipitação. O modelo conceitual e o modelo empírico baseados no código desenvolvido por Andrade (2006) que implementa o modelo físico de Georgakakos & Bras (1984). Os códigos desenvolvidos possuem a vantagem de serem automatizados, inserindo os dados de entrada e gerando as respostas de forma automática, visando em próximos trabalhos a implantação de uma previsão de enchentes em tempo real.

Diferentemente do *software* desenvolvido por Andrade (2006), o modelo conceitual desenvolvido no presente trabalho é capaz de ajustar seus parâmetros internos através do auxílio

de algoritmos genéticos. Esta inovação foi eficiente pois ajudou na redução do tempo despendido através do ajuste manual, além de buscar parâmetros quasi-ótimos. O ajuste dos parâmetros através de algoritmos genéticos foi também essencial para automatização do modelo de previsão.

Os modelos de previsão da precipitação encontraram resultados de ajuste satisfatórios, sendo válidos para utilização na previsão de enchentes. Necessitam-se mais estudos sobre o modelo, utilizando outros eventos de chuva e com maiores combinações, testando a eficiência do modelo para diferentes tipos de chuva (chuvas com diferentes intensidades e durações).

Objetivo: Avaliar a influência dos dados colaborativos na previsão de enchentes. Aplicar a metodologia em um estudo de caso real modelando a bacia urbana de São Carlos utilizando o software SWMM (Storm Water Managment Model).

As informações VGI foram testadas para utilização um evento onde houve inundação na bacia urbana de São Carlos. No teste realizado foi feita apenas uma combinação de fatores que influenciam no resultado da previsão de enchentes dentre diversas possibilidades existentes. Os resultados mostraram que não houve grande influência o uso das informações voluntárias. O levantamento na literatura mostra que existe interesse no uso das informações voluntárias para a previsão de enchentes, mas não se tem um estudo onde elas foram efetivamente aplicadas, sendo mais comuns para uso após ocorrência do evento. Neste trabalho foi analisado apenas um evento de chuva, com duração de 48 horas, são necessárias análises com outras e maiores séries históricas para se ter resultados mais conclusivos sobre a influência dos dados VGI na previsão de enchentes. O resultado obtido da inserção dos dados voluntários mostra a necessidade de se testar todas as possibilidades de combinação de fatores para que se determine quais condições são mais propícias para que se tenha uma influência significativa do uso das informações voluntárias. Conclui-se também a necessidade de usar correlações entre as informação voluntárias fornecidas em um ponto na bacia com todos os outros pontos a jusante dessa informação para que assim a informação voluntária tenha um peso maior na redução da incerteza na previsão de enchentes.

Objetivo Geral: Desenvolver um Modelo de Alerta Hidrológico com base Participativa (MAHP) que integre informações geográficas voluntárias (VGI- Volunteered Geographic Information) e informações de sensores sem fio (WSN - Wireless Sensor Network) em bacias com dados escassos (PUB - Prediction in Ungauged Basins) para a emissão de alertas, objetivando a prevenção de riscos e danos causados por eventos extremos.

O objetivo geral do trabalho foi a construção do modelo MAHP. Para o funcionamento do modelo foi necessário o estudo das metodologias dos dados VGI, dados WSN, do Modelo SWMM e da previsão da precipitação. Cada uma destas metodologias foram estudadas e avaliadas separadamente, para que a acurácia de cada módulo fosse avaliada.

As informações VGI não apresentaram melhorias nas simulações para os eventos estudados neste trabalho, entretanto, através do estudo foi possível concluir que o decaimento da celeridade influencia diretamente na previsão.

O modelo MAHP é bastante inovador pois integra diversas fontes de dados, e pode ser facilmente replicado em outros estudos de caso. O uso de informações voluntárias é uma área recente e com poucos trabalhos publicados principalmente quando usados para prevenção de eventos extremos.

5.2. RECOMENDAÇÕES

Necessitam mais estudos para avaliar o uso das informações de nível em tempo real, para que atualizem automaticamente as condições iniciais do modelo chuva-vazão SWMM. Em trabalhos futuros recomenda-se o desenvolvimento de um software que adeque e atualize essas informações automaticamente para o funcionamento *online* do MAHP.

Os dados de sensores não estão com as séries históricas completas pois a instalação dos mesmos é recente. Necessitam-se mais estudos sobre o funcionamento dos sensores, alimentação da bateria, redução de necessidade de manutenção, entre outros.

A metodologia de inserção de dados VGI proposta no trabalho e a análise das diferentes combinações de como a informação é dada foram importantes para o desenvolvimento de uma hipótese do uso de dados VGI para a previsão de eventos extremos. Recomenda-se em trabalhos futuros mais estudos sobre o tema para validar a hipótese proposta de reduzir a incerteza na previsão de enchentes utilizando dados voluntários.

Os resultados das simulações utilizando dados VGI demonstram a necessidade de mais pesquisas nas maneiras de se inserir as informações e também sobre o funcionamento do modelo SWMM para que se consiga uma influência maior dos dados voluntários na previsão de eventos extremos. Para isso é necessário uma série histórica maior para que todas as combinações e tipos de eventos possam ser isolados e comparados para que se avalie a influência em cada tipo de evento através da análise de sensibilidade dos dados. Recomenda-se em estudos futuros testar a

influência da informação VGI na previsão de enchentes do modelo MAHP utilizando outros modelos chuva-vazão no lugar do SWMM.

Conforme verificado na revisão da literatura, a incorporação de informações provenientes de radar de tempo é de grande importância para a redução da incerteza na previsão da precipitação. Recomenda-se em trabalhos futuros a incorporação de dados de radar meteorológico no modelo de previsão de chuvas do MAHP para melhorar os resultados de previsão da precipitação, pois esta é uma etapa muito importante na emissão de alertas de enchente.

Em estudos futuros recomenda-se a automatização total do modelo MAHP e avaliação da eficácia do modelo quando integrados todos os seus módulos. E a aplicação do modelo com informações em tempo real para avaliação de seu funcionamento em situações reais.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ANAGNOSTOU, E. N.; KRAJEWSKI, W. F.; SMITH, J. (1999). Uncertainty quantification of mean-areal radar-rainfall estimates. *Journal of Atmospheric and Oceanic Technology*, v. 16, n. 2, p. 206–215.

AKINCI, H.; ERDOĞAN, S. Designing a flood forecasting and inundation-mapping system integrated with spatial data infrastructures for Turkey. *Natural hazards*, v. 71, n. 1, p. 895-911, 2014.

ANDRADE, J. P. M. (2006). *Previsão hidrometeorológica visando sistemas de alerta antecipado de cheias em bacias urbanas*. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP. 99p.

BATTAN, L. J. (1973). *Radar observation of the atmosphere*. University of Chicago Press, 324 pp.

BEVEN, K. J. *et al.* (1984). Testing a physically-based flood forecasting model (TOPMODEL) for three UK catchments. *Journal of Hydrology*, v. 69, n. 1, p. 119-143.

BIONDI, D.; De LUCA, D. L. (2011). A Bayesian approach for real-time flood forecasting. *Physics and Chemistry of the Earth, Parts A/B/C*.

BŘEZKOVÁ, L., ŠÁLEK, M., NOVÁK, P., KYZNAROVÁ, H., & JONOV, M. (2011). New methods of flash flood forecasting in the Czech Republic. In *Environmental Software Systems. Frameworks of eEnvironment* (pp. 550-557). Springer Berlin Heidelberg.

BROCCA, L.; MELONE, F.; MORAMARCO, T. (2011). Distributed rainfall-runoff modelling for flood frequency estimation and flood forecasting. *Hydrological Processes*, 25(18), 2801-2813.

BROXTON, Patrick *et al.* (2014). An All-Season Flash Flood Forecasting System for Real-Time

Operations. *Bulletin of the American Meteorological Society*, v. 95, n. 3, p. 399-407.

CAMPOLO, M.; ANDREUSSI, P.; SOLDATI, A. (1999). River flood forecasting with a neural network model. *Water resources research*, v. 35, n. 4, p. 1191-1197.

CHAU, K. W.; WU, C. L.; LI, Y. S. (2005). Comparison of several flood forecasting models in Yangtze River. *Journal of Hydrologic Engineering*, v. 10, n. 6, p. 485-491.

CHEN, Lu *et al.* (2015) Real-time error correction method combined with combination flood forecasting technique for improving the accuracy of flood forecasting. *Journal of Hydrology*, v. 521, p. 157-169.

CHOI, K; BALL, J. E. (2002). Parameter estimation for urban runoff modelling. *Urban water*, v. 4, n. 1, p. 31-41, 2002.

CHOW (1959). *Open-Channel Hydraulics*. McGraw-Hill. New York. xviii + 680 pp. Illus. ISBN 1-9328461-8-2

CLOKE, H.L.; PAPPENBERGER, F. (2009). Ensemble flood forecasting: A review. In: *Journal of Hydrology*, 375, p.613-626.

CORRÊA, A.C.S. *et al.* (2007). Modelo de previsão de cheias do rio Madeira na área urbana de Porto Velho – RO. In *anais do I Simpósio de Recursos Hídricos do Norte e Centro-Oeste*, Cuiabá.

CORTES, V. J.; FRIGERIO, S.; SCHENATO, L.; PASUTO, A. (2013). Review of the current risk management strategies in Europe for hydro-meteorological hazards at protection and emergency level. *Conversion of Large Scale Wastes into Value-added Products*, Taylor & Francis Group, p. 238. ISBN 978-0-416-62144-1.

COURANT, R.; FRIEDRICHS, K.; LEWY, H. (1928). Über die partiellen Differenzgleichungen der mathematischen Physik. *Mathematische Annalen*, v. 100, n. 1, p. 32-74.

CRONSHEY, R. (1986). *Urban hydrology for small watersheds*. US Dept. of Agriculture, Soil Conservation Service, Engineering Division, 1986.

DEGROSSI, L. C.; AMARAL, G. G.; VASCONCELOS, E. S. M.; ALBUQUERQUE, J. P.; UHEYAMA, J. (2013). Using Wireless Sensor Networks in the Sensor Web for Flood Monitoring in Brazil. Publishing in *ISCRAM Conference – Baden-Baden, Germany, May*.

DEGROSSI, L. C.; ALBUQUERQUE, J. P.; FAVA, M. C.; MENDIONDO, E. M. (2014). Flood Citizen Observatory: a crowdsourcing-based approach for flood risk management in Brazil. Publishing in *SEKE - 26th International Conference on Software Engineering and Knowledge Engineering – Vancouver, Canada, July*.

DYBOWSKI, R.; ROBERTS, S.J. (2000). *Confidence and prediction intervals for feed forward neural networks*. In: Dybowski, R., Gant, V. (Eds.), *Clinical Applications of Artificial Neural Networks*. Cambridge University Press.

ELLIOTT, A. H.; TROWSDALE, S. A. (2006). A review of models for low impact urban stormwater drainage. *Environmental Modelling & Software* 22 (2007) 394 – 405.

FAVA, M. C. *et al.* (2014). Integration of information technology systems for flood forecasting with hybrid data sources. In: *6th International Conference on Flood Management*, São Paulo, Brazil. [S.l.: s.n.].

FENG, L. H.; LU, J. (2010). The practical research on flood forecasting based on artificial neural networks. *Expert Systems with Applications*, 37(4), 2974-2977.

FERNANDO, A.; SHAMSELDIN, A.; ABRAHART, R. (2011). Use of gene expression programming for multi-model combination of rainfall-runoff models. *J. Hydraul. Eng.* 17 (9), 975–985.

FURQUIM, G. *et al.* (2014). Combining wireless sensor networks and machine learning for flash flood nowcasting. In: *28th International Conference on Advanced Information Networking and Applications*. Victoria, Canada: [s.n.].

GARCIA-BARTUAL, R. (2002). *Short term river flood forecasting with neural networks*. Universidad Politecnica de Valencia, Spain, 160-165.

GEORGAKAKOS, K. P.; BRAS, R. L. (1984a). A hydrologically useful station precipitation model, 1. Formulation. *Water Resources Research*, v. 20, n. 11, p. 1585-1596.

GOLDBERG, David E. (2006). *Genetic algorithms in search, optimization & Machine Learning*. Pearson Education India.

GONÇALVES, M. F. (2009). *Previsão de chuva com auxílio de radar de tempo visando a um sistema de alerta antecipado de cheias em áreas urbanas*. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP. 246 p.

GOODCHILD, M. F. (2007). Citizens as Sensors: The World of Volunteered Geographic. In: *Geo-Journal*, p. 211 - 221.

HAPUARACHCHI, H. A. P.; WANG, Q. J., & PAGANO, T. C. (2011). A review of advances in flash flood forecasting. *Hydrological Processes*, 25(18), 2771-2784.

HORITA, F. E. A.; *et al.* (2014). AGORA-Geodash: A Geosensor Dashboard for Real-time Flood Risk Monitoring. Publishing in *11th International ISCRAM Conference – University Park, Pennsylvania, USA, May*.

HSU, K.L.; MORADKHANI, H.; SOROOSHIAN, S. (2009). A sequential Bayesian approach for hydrologic model selection and prediction. *Water Resour. Res.* 45.

HUARD, D.; MAILHOT, A. (2008). Calibration of hydrological model GR2M using Bayesian uncertainty analysis. *Water Resour. Res.* 44, W02424.

HUGHES, D.; *et al.* (2011). A middleware platform to support river monitoring using wireless sensor networks. In: *J Braz Comput Soc* 17:85–102.

INCLINE – Interdisciplinary CLimate INvEstigation Center. (2013). Conceito de Vulnerabilidade, In: *Oficina Interdisciplinar do Incline para discussão e construção conjunta do conceito de vulnerabilidade*, IAG/USP, São Paulo, 8-9 Abril 2013. Disponível em <www.incline.iag.usp.br>.

KITZMILLER, D. *et al.* (2013). Radar and multisensor precipitation estimation techniques in national weather service hydrologic operations. *Journal of Hydrologic Engineering*, American Society of Civil Engineers, v. 18, n. 2, p. 133–142.

KURZBACH, S., PASCHE, E., LANIG, S., & ZIPF, A. (2009). Benefits of grid computing for flood modeling in service-oriented spatial data infrastructures. *GIS Science*, 3, 89-97.

LECCA, G.; PETITDIDIER, M., HLUCHY, L.; IVANOVIC, M., KUSSUL, N.; RAY, N.; THIERON, V.; Grid computing technology for hydrological applications, *Journal of Hydrology*, Volume 403, Issues 1–2, 6 June 2011, Pages 186-199, ISSN 0022-1694.

LEE, S., YOON, C., JUNG, K., & HWANG, H. (2010). Comparative evaluation of runoff and water quality using HSPF and SWMM.

MARZANO, F. *et al.* (2010). Hydrorad project: integrating x-band mini-radar networks and hydro-meteorological forecast models in Moldova territory. In: *6th European conference on radar in meteorology and hydrology*, Sibiu, Romania. [S.l.: s.n.].

MENDIONDO, E. M. (2005). Flood risk management of urban waters in humid tropics: early warning, protection and rehabilitation. In *Workshop on Integrated Urban Water Management in Humid Tropics* (pp. 1-14).

MENDIONDO, E. M. (2010). *Integrated Urban Water Management: Humid Tropics*. Urban Water series - UNESCO-IHP. Chapter 6: 109-127.

MENDIONDO, E. M.; SOUZA, V. C.; REIS, L. F. R.; BRANDÃO, J. L. B.; DOMINGOS, S. (2013). *Ações Colaborativas na Redução da Vulnerabilidade aos Desastres Hidrológicos Usando Tecnologias Resilientes para a Drenagem Urbana*, Eixo Temático, In: Yoshizaki, H.

(coord.) NAP/CEPED-USP: Núcleo de Apoio à Pesquisa "Centro de Ensino e Pesquisa em Desastres", Pró-Reitoria de Pesquisa/USP.

MONTANARI, A.; SHOEMAKER, C.A.; VAN DE GIESEN, N. (2009). Introduction to special section on uncertainty assessment in surface and subsurface hydrology: an overview of issues and challenges. *Water Resour. Res.* 45, W00B00.

MURPHY, A. H. (1993). What is a good forecast? An essay on the nature of goodness in weather forecasting. *Weather and forecasting*, v. 8, n. 2, p. 281-293.

NAPOLITANO, G.; SEE, L.; CALVO, B.; SAVI, F.; HEPPENSTALL, A. (2010). A conceptual and neural network model for real-time flood forecasting of the Tiber River in Rome. *Physics and Chemistry of the Earth, Parts A/B/C*, 35(3), 187-194.

NASA Land Processes Distributed Active Archive Center (LP DAAC). (2001). ASTER L1B. USGS/Earth Resources Observation and Science (EROS) Center, Sioux Falls, South Dakota.

NAYAK, P.C.; SUDHEER, K.P.; RANGAN, D.M.; RAMASASTRI, K.S. (2005). Short-term flood forecasting with a neurofuzzy model. *Water Resources Research*, 41(4).

NGUYEN, P. K.; CHUA, L. H.; SON, L. H.. (2014). Flood forecasting in large rivers with data-driven models. *Natural hazards*, v. 71, n. 1, p. 767-784.

PAZ, A.R.; BUENO, E.O.; TUCCI, C.E.M. (2002). Análise de metodologias de previsão de vazões em tempo real estudos de casos: bacias do rio Doce (MG) e do rio Uruguai (RS). In *Anais do II Simpósio de Recursos Hídricos do Centro-Oeste*, Campo Grande.

PETERSON, E. W.; WICKS, C. M. (2006). Assessing the importance of conduit geometry and physical parameters in karst systems using the storm water management model (SWMM). *Journal of hydrology*, v. 329, n. 1, p. 294-305.

POSER, K., DRANSCH, D. (2010). Volunteered geographic information for disaster management with application to rapid flood damage estimation. - *Geomatica*, 64, 1, 89-98.

REN, M.; WANG, B.; LIANG, Q.; FU, G. (2010). Classified real-time flood forecasting by coupling fuzzy clustering and neural network. *International Journal of Sediment Research*, 25(2), 134-148.

RENARD, B.; KAVETSKI, D.; KUCZERA, G.; THYER, M.; FRANKS, S. (2010). Understanding input and structural errors. *Water Resour. Res.* 46, W05521. predictive uncertainty in hydrologic modeling: the challenge of identifying input and structural errors. *Water Resour. Res.* 46, W05521.

ROSSMAN, L. A. (2009). *Storm Water Management User's Manual Version 5.0*. EPA/600/R-05/040, National Risk Management Research Laboratory. United States Environmental Protection Agency, Cincinnati, Ohio.

ROTAVA, J.; MENDIONDO, E. M.; SOUZA, V. C. (2013). Simulação de instabilidade humana em inundações: primeiras considerações. *XX Simpósio Brasileiro de Recursos Hídricos*. Bento Gonçalves, RS.

SCHADE, Sven. *et al.* (2013). Citizen-based sensing of crisis events: sensor web enablement for volunteered geographic information. *Applied Geomatics*, v. 5, n. 1, p. 3-18.

SEHGAL, V.; SAHAY, R. R.; CHATTERJEE, C. (2014). Effect of utilization of discrete wavelet components on flood forecasting performance of wavelet based ANFIS models. *Water resources management*, v. 28, n. 6, p. 1733-1749.

SHAMIR, E.; LEE, B.J.; BAE, D.H.; GEORGAKAKOS, K.P. (2010). Flood forecasting in regulated basins using the ensemble extended Kalman filter with the storage function method. *Journal of Hydrologic Engineering*, 15(12), 1030-1044.

SHAMSELDIN, A.Y.; O'CONNOR, K.M.; NASR, A.E. (2007). A comparative study of three neural network forecast combination methods for simulated river flows of different rainfall runoff models. *Hydrol. Sci. J.* 52 (5), 896–916.

SHINMA, T. A. (2011). *Calibração multiobjetivo do SWMM aplicada à transformação chuva-vazão*. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP. 132p.

SIVAPALAN, M. *et al.* (2003). IAHS Decade on Predictions in Ungauged Basins (PUB), 2003-2012: Shaping an Exciting Future for the Hydrological Sciences. In: *Hydrological Sciences Journal*.

SUNKPHO, J.; OOTAMAKORN, C. (2011). Real-time flood monitoring and warning system. *Sonklanakarin Journal of Science and Technology*, v. 33, n. 2, p. 227.

TIWARI, M.K.; CHATTERJEE, C. (2010a). Uncertainty assessment and ensemble flood forecasting using bootstrap based artificial neural networks (BANNs). *Journal of Hydrology*, 382(1), 20-33.

TIWARI, M.K.; CHATTERJEE, C. (2010b). Development of an accurate and reliable hourly flood forecasting model using wavelet–bootstrap–ANN (WBANN) hybrid approach. *Journal of Hydrology*, 394(3), 458-470.

TOTH, E.; BRATH, A.; MONTANARI, A. (2000). Comparison of short-term rainfall prediction models for real-time flood forecasting. *Journal of Hydrology*, 239(1), 132-147.

TUCCI, C. E. M. *et al.* (1998). *Modelos hidrológicos*. UFRGS.

VENDRUSCOLO, S. (2007). *Interfaces entre a Política Nacional de Recursos Hídricos e a Política Nacional de Defesa Civil, com relação aos Desastres Hidrológicos*. Dissertação (Mestrado), Santa Catarina – SC.

VIS, M. ; KLIJN, F.; DE BRUIJN, K.M.; BUUREN, M. (2010). Resilience strategies for flood risk management in the Netherlands. In: *International Journal of River Basin Management*. 1:1, 33-40.

WALL, M. (1996). GALib: A C++ library of genetic algorithm components. *Mechanical Engineering Department, Massachusetts Institute of Technology*, v. 87, p. 54.

WANG, K. H., & ALTUNKAYNAK, A. (2011). Comparative case study of rainfall-runoff modeling between SWMM and fuzzy logic approach. *Journal of Hydrologic Engineering*, 17(2), 283-291.

WU, S.; LIEN, H.; CHANG, C.; SHEN, J. (2012). Real-time correction of water stage forecast during rainstorm events using combination of forecast errors. *Stoch. Environ. Res Risk Assess.* 26, 519–531.

XIONG, L.; O’CONNOR, K. (2002). Comparison of four updating models for real-time river flow forecasting. *Hydrol. Sci. J.* 47 (4), 21–640.

ZAFFANI, A. G. (2012). *Poluição Difusa da Drenagem Urbana com Base Ecohidrológica: Diagnóstico Atual e Cenários de Longo Prazo em Bacias Urbanas de São Carlos, SP*. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP. 170p.

ANEXOS

Anexo A

Códigos fontes dos softwares desenvolvidos

Software para previsão conceitual, baseado no trabalho de Georgakakos & Bras, e otimização dos parâmetros através de algoritmos genéticos. O código refere-se ao módulo de previsão de precipitação do MAHP.

```
#include <vcl.h>
#include <list>
#include <stdlib.h>
#include <string.h>
#include <math.h>
#include <time.h>
#pragma hdrstop
#include "main.h"
#include "datamods.h"

#define PTRANSF 133.32231202221 // Utilizado para transformar pressao mmHg em
Pa
#define A1 0.0008 //A1 = 8.10^-4 Kg/(m.s2.k3,5)
#define PN 100000 //Pressao nominal 10^5 Kg/(m.s2)
#define A 2500000 //Constante da eq. (14) do calor latente A=2,5.10^6 J/Kg
#define B 2380 //Constante da eq. (14) do calor latente B=2,38.10^3 J/(Kg.K)
#define CP 1004 //Calor especifico à pressao constante cp=1004 J/(kg.K)
#define DA 1 //Diferencial de área dA
#define ALFA 3500 //3500 s-1
#define TAST 273.15 //T* [°K] eq 42
#define PAST 101325 //p* [kg/(m*s2) eq 42
#define C1 700000 //C1 [kg/(m3.s2)] pag 1593
#define RV 461 //Constante dos gases para vapor de água [J/(kg.K)] pag 1592
#define R 287 //J/(K.Kg)
#define G 9.81 //Aceleração da gravidade m/s2
#define K 0 //Considerado pag 1602
#define GAMA 1

#include "GA1DArrayGenome.h"
#include "GA1DArrayGenome.CPP"
#include "GAAllele.Cpp"
#include "GA1DArrayGenome.cpp"
#include "GARealGenome.h"
#include "GARealGenome.cpp"
#include "GASStateGA.h"
#include "GASimpleGA.h"

int firstTime =1;
float lastP =0;

int coco =0;
TForm1 *Form1;
GARealAlleleSetArray Alleles;
int InitialPopulation, Generations;
float CrossoverProb, MutationProb;

void SetAlleleValue()
{
Alleles.add(StrToFloat (Form1->elmin->Text), StrToFloat (Form1->elmax->Text));
```

```
Alleles.add(StrToFloat (Form1->e2min->Text), StrToFloat(Form1->e2max->Text));
Alleles.add(StrToFloat (Form1->e3min->Text), StrToFloat(Form1->e3max->Text));
Alleles.add(StrToFloat (Form1->e4min->Text), StrToFloat(Form1->e4max->Text));
Alleles.add(0,30000);
}

void Optimize()
{
double minfit;
double globalFitness, previousFitness;
float threshold =0.00001;
int repeat =0;
GARandomSeed();
SetAlleleValue();
    GAREalGenome genome (Alleles, objective);
genome.initializer (:: Initializer);
    GASTeadyStateGA ga(genome);
ga.maximize();
ga.populationSize(InitialPopulation);
    ga.nGenerations (Generations);
    ga.pCrossover (CrossoverProb);
    ga.pMutation (MutationProb);
    GASigmaTruncationScaling trunc;
    ga.scaling(trunc);
ga.scoreFilename("results.dat");
ga.scoreFrequency(10);
ga.flushFrequency(50);
    ga.pReplacement (0.25);
ga.selectScores(GAStatistics::AllScores);
ga.initialize();
while(!ga.done()){
minfit=999999999;
ga.step();
genome= ga.statistics().bestIndividual();
previousFitness= globalFitness;
globalFitness= minfit;
if(fabs(previousFitness - globalFitness)< threshold)
repeat++;
else
repeat=0;
if(repeat ==(int) InitialPopulation/3)
break;
if(Form1->stop ==1)
break;
genome= ga.statistics().bestIndividual();
}
}

float objective(GAGenome& g)
{
int j =0, k =0;
    GAREalGenome & genome =(GAREalGenome &)g;
double fitness =0;
    Form1->SetE1Value(genome.gene(0));
    Form1->SetE2Value(genome.gene(1));
    Form1->SetE3Value(genome.gene(2));
    Form1->SetE4Value(genome.gene(3));
    Form1->SetV1Value(genome.gene(4));
    Form1->Forecasting();
if(Form1->lf->Checked)
```

```
fitness= Form1->CalcNSE2();
else
fitness= Form1->CalcNSE();
if(fitness <-30)
fitness=-30;
    Form1->Series1->Add(fitness);
    Form1->Mem01->Lines->Add(FloatToStr(fitness));
    Application->ProcessMessages();
    Form1->Refresh();
    Form1->Repaint();
return(fitness);
}

// low flow nash-sutcliffe
double TForm1::CalcNSE2()
{
int i;
double division=0;
double numerador=0;
double media=0;
double nse =0;
double logobs;

media= Average();
for(i =0; i < countvalues; i++)
{
if(vobs[i]<=0)
vobs[i]=0.0000001;
if(vsim[i]<=0)
vsim[i]=0.0000001;
numerador+= pow((log(vobs[i])- log(vsim[i])),2);
division+= pow(log(vobs[i])-log(media),2);
if(division ==0)
division=0.0000001;
nse= numerador/division;
}
return(1- nse);
}

// high flow nash-sutcliffe
double TForm1::CalcNSE ()
{
int i;
double numerador =0;
double division =0;
double media;
double nse =0;
media= Average();
for(i =0; i < countvalues; i++)
{
numerador+= pow(vobs[i]-vsim[i],2);
division+= pow((vobs[i]-media),2);
if(division ==0)
division=0.0000001;
nse= numerador/division;
}
return(1- nse);
}
```

```
void TForm1::Forecasting()
{
    FILE *DBConn;// é um arquivo, mas no futuro vai ser uma conexao com BD
    int iteracao=1;
    double pobs;
    stationData stat;
    int hours, minutes;
    DBConn =DBConnect();
    if(DBConn ==NULL)// Erro
    {
        ShowMessage("Arquivo de dados nao encontrado");
        exit;
    }
    DM->DeleteObserved->ExecSQL();
    DM->DeleteSimulated->ExecSQL();
    countvalues=0;
    Series3->Clear();
    Series4->Clear();
    while(( LoadDBData(DBConn,&stat,&pobs))==0)
    {
        PrecForecast(&stat,&pobs,&iteracao);
    }
    fclose(DBConn);
}

void __fastcall TForm1::Button1Click(TObject *Sender)
{
    showgraph=1;
    if(DM->TSetup->State != dsBrowse)
        DM->TSetup->Post();
    SetE1Value(StrToFloat(Edit3->Text));
    SetE2Value(StrToFloat(Edit4->Text));
    SetE3Value(StrToFloat(Edit5->Text));
    SetE4Value(StrToFloat(Edit6->Text));
    SetV1Value(StrToFloat(Edit1->Text));
    Forecasting();
    nse->Caption = FloatToStr(CalcNSE());
}
//-----

FILE * TForm1::DBConnect()
{
    FILE *estFile =NULL;// ponteiro para arquivo da estacao
    char estFname[100];
    strcpy(estFname, Edit8->Text.c_str());
    // strcpy(estFname, open->FileName.c_str());
    if( FileExists(estFname))// Checa existencia do arquivo da estacao
    {
        if((estFile = fopen(estFname,"r"))==NULL)
        {
            printf("Nao foi possivel abrir o arquivo de entrada da estacao.\n");
            return estFile;// Erro repassado a main
        }
        else{// Se for possivel abrir o arquivo, retorna ponteiro a main
            printf("%d", estFile);
            printf("\n%p", estFile);
            return estFile;
        }
    }
}
```

```
else
{
printf("Arquivo de entrada nao encontrado.\n");
return estFile;// Erro repassado a main
}
}

int TForm1::LoadDBData(FILE *inFile, stationData *stat_F,double*pobs_F)
{
int dadoSendoLido =1;//identifica o dado a ser lido do arquivo. 1 = no. da
estacao, 2 = year, ...
char c =NULL;//caractere sendo lido
int linhaInvalida =0;
char year[10]="";//variaveis locais, receberao os dados do arquivo
char date[10]="";
char time[10]="";
char temperatura[10]="";
char umidade[10]="";
char pressao[10]="";
char pobs[10]="";
int horas, minutos, resto;
while( c !='\n' && c != EOF ){          c = fgetc(inFile);
if( feof(inFile))
return 1;if(c !=', '){
switch(dadoSendoLido){
case1:
if(c =='2')
linhaInvalida=1;
break;
case2:
year[strlen(year)]= c;
break;
case3:
date[strlen(date)]= c;
break;
case4:
time[strlen(time)]= c;
break;
case5:
temperatura[strlen(temperatura)]= c;
break;
case6:
umidade[strlen(umidade)]= c;
break;
case7:
//radioacao
break;
case8:
//radioacaoref
break;
case9:
//radioacaoliq
break;
case10:
pressao[strlen(pressao)]= c;
break;
case11:
pobs[strlen(pobs)]= c;
break;
default:
break;
```

```
}
}
else{
dadoSendoLido++;
}
}
if(linhaInvalida ==1){
LoadDBData(inFile, stat_F, pobs_F);
return0;
}
else
{
    stat_F->year =atoi(year);
    stat_F->date =atoi(date);
    stat_F->time =atoi(time);
stat_F->temperatura = atof(temperatura);
stat_F->umidade = atof(umidade);
stat_F->pressao =atof(pressao);
*pobs_F =(double)atof(pobs);
// essas duas variaveis serao usadas no futuro (dados de radar)
stat_F->topoDosEcos ==-1;
    stat_F->VIL ==-1;
}
return0;
}

double TForm1::f(double T,double p)
{
double pt, p1, p2, p3, res;
float diff;
float diff2;
diff= T -223.15;
if(T <223.15)// narumi
diff=0;// narumi

    diff2 = T -273.15;
if(T <273.15)// narumi
    diff2 =0;// narumi

    p1 =pow((PN / p),0.286);
    p2 =0.622* A1 *(pow((diff),3.5))/ p;
    p3 =(A - B *(diff2))* p2 /(CP * T);
res= T * p1 * exp(p3);
return res;
}

double TForm1::NewtonRaphson(double*ts,double*plinha,double*tetaE1)
{
double x, x0, Epsilon, E, p, p1, p2, erro[2];
int i =1;
x0 =*ts;
p=*plinha;
    Epsilon =0.001**tetaE1;
    E =*tetaE1;
do{
p1 = f(x0, p);
    E =fabs(p1 -*tetaE1);
erro[0]= E;
x0 = x0 -0.1;
p1 = f(x0, p);
```



```

erro[1]= fabs(p1 -*tetaE1);
i++;
}while((E>Epsilon)&& erro[0]> erro[1]);
return x0;
}

void TForm1::SaveToDB(TDate dia, TTime hora,double pobs,double psim)
{
    DM->TObserved->Insert();
    DM->TObservedDia->Value = dia;
    DM->TObservedHora->Value = hora;
    DM->TObservedObserved->AsFloat = pobs;
    DM->TSimulated->Insert();
    DM->TSimulatedDia->Value = dia;
    DM->TSimulatedHora->Value = hora;
    DM->TSimulatedSimulated->AsFloat = psim;
    DM->TSimulated->Post();
    DM->TObserved->Post();
}

double TForm1::Average()
{
    double sumobs =0;
    int i;
    for(i =0; i < countvalues; i++)
    {
        sumobs+= vobs[i];
    }
    return sumobs/countvalues;
}

int TForm1::SaveResults(stationData stat,double P,double pobs)
{
    struct tm tml ={0};
    int hours, minutes;
    int isEmpty;
    char fileName[100];
    TDate dia;
    TTime hora;
    FILE *outFile;
    tml.tm_year =2000-1900+ stat.year %4;
    tml.tm_mday = stat.date;
    tml.tm_hour =12;
    mktime(&tml);
    tml.tm_year = stat.year;
    tml.tm_mon++;
    minutes= stat.time%100;
    hours= stat.time/100;
    if(hours ==24)
    hours=0;
    if((outFile = fopen(savefilename->Text.c_str(),"a"))==NULL)
    {
        printf("Erro ao abrir o arquivo de saida.\n");
        return0;
    }
    fseek(outFile,0, SEEK_END);
    isEmpty= ftell(outFile);
    if( isEmpty ==0)
        fprintf(outFile,";StaID,Year,Month,Day,Hour,Min,P.obs,P.sim\n");
    dia= EncodeDate(tml.tm_year,tml.tm_mon,tml.tm_mday);
    hora= EncodeTime(hours%24,minutes,0,0);

```

```

vsim=(double*) realloc (vsim,sizeof(double)*(countvalues+1));
vobs=(double*) realloc (vobs,sizeof(double)*(countvalues+1));
diahora=(double*) realloc (diahora,sizeof(double)*(countvalues+1));
vsim[countvalues]= P - lastP;
//    lastP = P;
vobs[countvalues]= pobs;
diahora[countvalues]= dia+hora;
countvalues++;
if(showgraph ==1){
    Series3->XValues->DateTime =true;
    Series4->XValues->DateTime =true;
    Series3->AddXY(dia+hora, P,"",0xFF972F);
    Series4->AddXY(dia+hora, pobs,"",0x0009500);
}
fprintf(outFile,"1,%d,%d,%d,%d,%d,%f,%f\n",          tm1.tm_year,          tm1.tm_mon,
tm1.tm_mday, hours, minutes, P, pobs);
fclose(outFile);
return1;
}

void TForm1::SetE1Value(double value)
{
    e1 = value;
}

void TForm1::SetE2Value(double value)
{
    e2 = value;
}

void TForm1::SetE3Value(double value)
{
    e3 = value;
}

void TForm1::SetE4Value(double value)
{
    e4 = value;
}

void TForm1::SetV1Value(double value)
{
    v1 = value;
}

double TForm1::Georgakakos(stationData stat,double pobs,int*iteracao)
{
    double td;//temperatura no ponto de orvalho (em K)
    double ps;//pressao na base da nuvem
    double ts;//pressao na base da nuvem (de novo?)
    double es;//pressao de saturacao umida
    double wo;//razao de mistura inicial
    double wss;//razao de mistura na base
    double tt;
    double pt;
    double wst;
    double teta;//temperatura potencial teta
    double L;//Calor latente de condensação
    double tetaE1;//temperatura potencial teta e

```

```

double umI;//Entrada de umidade I
double nv;//Adimensional de velocidade
double vbeta;//Velocidade v beta
double c;//Inverso do diâmetro médio
double dast;//D* [equacao 42]
double P;//PWV (precipitacao acumulada?)
double obs;
double erro;
double zb;
double dc;
double nd;
double vp;
double pt1;

double plinha;
double tslinha;
double tm;
double v;
double deltaT;
double X[2000];

double ob1;
double ob2;
double ot;
double zt;
double zt2;
double zc;
double teta17;

double aux, aux_tm, aux_l, aux_w, tolerancia, tolerancia_v, v2, res, F1, F2,
F3;
double ur = stat.umidade;
double temperatura = stat.temperatura;
double pressao = stat.pressao;
double topoDosEcos = stat.topoDosEcos;
double VIL = stat.VIL;
double DELTA;
double pa, pb, pc, pd, pe;
AnsiString Line;

double pl =20000;//PL, parametro de entrada: pressao cte no limite da
troposfera 200mbar
double dt = StrToFloat(deltat->Text);//delta t dos dados (em segundos). 450 =
7.5 min de intervalo de calculos
int limitVIL =0;//se 1, desconsidera valores de VIL < 3 kg/m². [C99 nao
suporta tipo boolean, mas limitVIL receberia 0 ou 1]

v1 =1.5;//V inicial, parametro de entrada
X[0]=1;//x inicial
temperatura= temperatura +273.15;//temperatura passada para Kelvin
pressao= pressao * PTRANSF;//[pressao de saturacao umida [es umido] eq 4]
es=( ur /100)*(A1 *( pow ( temperatura -223.15,3.5)));// pow(x,3.15) == x^3.15
td= pow((es/A1), (1/3.5))+223.15;

/* [Avaliar o grau de saturação do ar na superfície. Se w0 < wss o ar não
* está saturado e a ascensão é adiabática, caso contrário, desde a
* superfície a taxa de decaimento da temperatura é pseudo adiabática.] */
wo=(0.622*( A1 * pow(td-223.15,3.5))/ pressao );//razao de mistura wo =
ws(Td,po), eq 5
wss=(0.622*( A1 * pow(temperatura-223.15,3.5))/ pressao );//razao de mistura
ws(To, po), eq 6

```

```

//se wo > wss, ascencao pseudo-adiabatica. Senao, ascencao adiabatica
ps= pressao /( pow((((temperatura - td)/223.15)+1),3.5));
ts= temperatura /((((temperatura - td)/223.15)+1);
teta= pow(PN/ps,0.286)* ts;//teta eq 7
    L = A - B *(ts-273.15);//calor latente de condensacao eq 15
tetaE1 = teta * exp( L *(0.622*(A1*(pow((ts-223.15),3.5)))/ ps)/(CP *
ts));//tetae equacao 14 p1588

//Parametrizacao para encontrar v e pt. ++UTILIZACAO DOS PARAMETROS DE
ENTRADA++
do{
pt1=((e2 - p1)/(1+ e3 * v1))+ p1;//subst v1 na eq 18, encontra pt
plinha= ps -(0.25*(ps - pt1));//pt1 = 1.1*ps / subst pt1 na eq 15, encontra p'
tm= NewtonRaphson(&ts,&plinha,&tetaE1);//encontra Tm
aux=((0.75)* ps)+((0.25)* pt1);//subst valor de pt na eq 16 e encontra tslinha
tslinha=(temperatura/pow(pressao,0.286))* pow(aux,0.286);//encontra tslinha
deltaT= tm - tslinha;//subst tm e tslinha na eq 14 e encontra deltat
if(deltaT <0) deltaT =0;// narumi
    v1 = e1 *pow((CP * deltaT),0.5);//eq 13
if(v1 ==0)
v1 =0.000001;
pt=((e2 - p1)/(1+ e3 * v1))+ p1;//calcula p novamente
res= pt1 - pt;//compara os dois valores de p
tolerancia_v = pt1 *2/100;
pt1 = pt;
}while(fabs(res)> tolerancia_v);
v= v1;
pt= pt1;
c=1/(e4 * pow(v, K));//c eq 19 estudo de caso
tt= NewtonRaphson(&ts,&pt,&tetaE1);
teta17 = f(tt, pt);//funcao

if(topoDosEcos ==-1)// se o topo dos ecos nao foi informado
{
zc=(R *(ts + tt)/(2*G))* log( pressao / pt);
zb=(R *(ts + temperatura)/(2*G))* log( pressao / ps);
zt= zc + zb;
    zt2 =0.0;
}
else
{
zt2 = topoDosEcos *1000;
zt=(R *(tt + temperatura)/(2*G))* log (pressao / pt);
zb=(R *(ts + temperatura)/(2*G))* log (pressao / ps);

if(zt2 < zb)
zc=0;
else
zc= zt2 - zb;
}

float diff = tt -223.15;// narumi
if(tt <223.15)// narumi
diff=0;// narumi
wst=0.622*(A1 *(pow((diff),3.5)))/ pt;//Razao de mistura ws(Tt, pt)
umI=(wo - wst)*((ps /(R * ts)+(pt /(R * tt)))/2)* v * DA;//Umidade I eq 2;
I[i] = (wo[i]-wst[i])*ROM*v[i]*DA;
dast=2.11* pow(10,-5)* pow((temperatura / TAST),1.94)*(PAST / pressao);//D* eq
42
dc= pow((4*(dast /(C1 * RV))* zb *((A1 * pow((temperatura -223.15),3.5)/

```

```

temperatura)//Diametro critico Dc eq 56
-(A1 *pow((td -223.15),3.5)/ temperatura)), (0.3333));
//Adimensionais eq 58-60
nv= v * c / ALFA;
nd= c * dc;
vp=4* ALFA / c;

DELTA =(0.333)*((1/GAMA)+(1/(GAMA*GAMA)))+(1/(GAMA*GAMA*GAMA)); //DELTA eq
32

//Ob e Ot em funcao da massa, ou seja, nao esta multiplicado por X[i]
F1 =(1+(3/4)* nv +pow(nv,2)*0.25);
F2 =pow(nv,3)*0.0416667;
F3 =(F1+F2)/exp(nv);
if(zc ==0)
ob1 =0;
else
ob1 =(vp * X[*iteracao-1])/(DELTA * zc))* F3;
F1 =(1+((3/4)*(GAMA * nv))+pow((GAMA * nv),2)*0.25+(pow(GAMA *
nv,3)*0.0416667))/ exp(GAMA * nv);
F2 =(GAMA *nv*0.25);
if(zc ==0)
ot=0;
else
ot=((vp * X[*iteracao-1])/(DELTA * zc * pow(GAMA,5)))*(F1 + F2 -1);

/* X[iteração+1] = (umI - (Ob+Ot) * X[iteracao]) * dt;
* Se nao houver dados de radar, X[iteracao] usa os dados da estacao */

if(VIL ==-1)//Se nao houver dados de radar, X[iteracao] usa os dados da
estacao
X[*iteracao]=(umI -(ob1 + ot))* dt + X[*iteracao-1];
else{//Senao, usa os dados de VIL
X[*iteracao]= VIL;
if(X[*iteracao-1]==0)
ob2 =0;
else
ob2 = umI - ot -((X[*iteracao-1])/ dt);
}

//Precipitacao 63 - 64 resultado em unidade de massa
if( zc ==0||((VIL <3.0)&&(limitVIL ==1)))
P =0;
else
{
if(nd >= nv)
{
pa=(X[*iteracao]/(DELTA * zc))* vp;
pb=(1- nv *0.25)*(1+ nd +(pow(nd,2)*0.5));
pc=(pow(nd,3)*0.125);
pd= exp(nd);
pe=(pb + pc)/ pd;
P = pa * pe;
}
else
P =(X[*iteracao]/(DELTA * zc))* vp *(1+0.75* nv + pow(nv,2)*0.25+
pow(nv,3)*0.0416667- pow(nd,3)*0.0416667)/ exp(nv);
}

P = P * dt;//valor acumulado em 7,5 min
Line.sprintf("\n\nTemp. (K): %.2f || Umid.: %.2f || T. orv: %.2f || P.
Ac.: %.2f || P. Obs.: N/A || massa X: %.2f || Zc: %.2f || Zt: %.2f || Topo

```

```

Ecos: N/A || Zb: %.2f || Pressao (atm): %.2f || Erro tetaE: %f || w0: %f ||
ws: %f || wt: %f || ps: %f || ts: %f || teta: %f || v: %f || Pt [pa]: %f ||
Tt[K]: %f || Teta E[K]: %f || Sai. Ob Geo.: %f \n\n", temperatura, ur, td, P,
X[*iteracao], zc/1000, zt/1000, zb/1000, pressao, teta17-tetaE1, wo, wss, wst,
ps, ts, teta, v, pt, tt, tetaE1, obl);
return P;
}

int TForm1::PrecForecast(stationData *stat,double*pobs,int*iteracao)
{
double P;
P =Georgakakos(*stat,*pobs, iteracao);
SaveResults(*stat, P,*pobs);
(*iteracao)++;
return 0;
}

void __fastcall TForm1::FormCreate(TObject *Sender)
{
DM->DeleteObserved->ExecSQL();
DM->DeleteSimulated->ExecSQL();
countvalues=0;
vobs=(double*) malloc (sizeof(double)*1);
vsim=(double*) malloc (sizeof(double)*1);
diahora=(double*) malloc (sizeof(double)*1);
stop=0;
}

void __fastcall TForm1::Button2Click(TObject *Sender)
{
showgraph=1;
if(DM->TSetup->State != dsBrowse)
DM->TSetup->Post();
stop=0;
InitialPopulation =StrToInt(Edit7->Text);
Generations =StrToInt(Edit9->Text);
CrossoverProb =StrToFloat(Edit10->Text);
MutationProb =StrToFloat(Edit11->Text);

SetE1Value(StrToFloat(Edit3->Text));
SetE2Value(StrToFloat(Edit4->Text));
SetE3Value(StrToFloat(Edit5->Text));
SetE4Value(StrToFloat(Edit6->Text));
SetV1Value(StrToFloat(Edit1->Text));
Optimize();
nse->Caption = FloatToStr(CalcNSE());
}

void Initializer (GAGenome& g)
{
GARealGenome & genome =(GARealGenome &)g;
float RandomValue;
RandomValue =GARandomFloat(StrToFloat(Form1->elmin->Text), StrToFloat(Form1->elmax->Text));
genome.gene(0, RandomValue);
RandomValue =GARandomFloat(StrToFloat(Form1->e2min->Text), StrToFloat(Form1->e2max->Text));
genome.gene(1, RandomValue);
}

```

```
    RandomValue =GARandomFloat(StrToFloat(Form1->e3min->Text), StrToFloat(Form1->e3max->Text));  
    genome.gene(2, RandomValue);  
    RandomValue =GARandomFloat(StrToFloat(Form1->e4min->Text), StrToFloat(Form1->e4max->Text));  
    genome.gene(3, RandomValue);  
    RandomValue =GARandomFloat(0,30000);  
    genome.gene(4, RandomValue);  
}
```

Software para previsão conceitual, baseado no trabalho de Georgakakos & Bras, e otimização dos parâmetros através de algoritmos genéticos. O código refere-se ao módulo de previsão de precipitação do MAHP.

```
#include <stdio.h>
#include <math.h>
#include "calculation.h"

int main(int argc, char*argv[])
{
    int i;
    int qtde =19;
    int num =4;
    double prec[19]={0,      0,      0,      0,      0,      0,      0.5,  4.8,  0.25, 0,
                     0,      0,      1.52, 0,      0,      2.54, 0.5,  0.75};
    double aux[4]={0,0,0,0};

    for(i =0; i < qtde - num ; i++)
    {
        aux[0]= prec[i];
        aux[1]= prec[i +1];
        aux[2]= prec[i +2];
        aux[3]= prec[i +3];
        printf("%f\n", Regression(aux,4));
    }

    for(i =0; i < qtde - num; i++)
    {
        int j =0;

        printf("%f\n", AutocorrelationLag1(prec, qtde-num));

        while(prec[j +1])
        {
            prec[j]= prec[j +1];
        }
    }

    return 0;
}

double ArithmeticMean(double*vec, int length)
{
    int i;
    double sum =0;

    for(i =0; i < length; i++)
        sum+= vec[i];

    return sum / length;
}

double Variance(double*vec, int length)
{
    int i;
    double vec_mean =0, sum =0;

    vec_mean =ArithmeticMean(vec, length);
    for(i =0; i < length; i++)
        sum= sum +((vec[i]- vec_mean)*(vec[i]- vec_mean));
}
```



```
return sum / length;
}

double StandardDeviation(double*vec,int length)
{
return sqrt(Variance(vec, length));
}

double AutocorrelationLag1(double*vec,int length)
{
int i;
double vec_mean, denom =0, coeff =0;
double resp;

    vec_mean =ArithmeticMean(vec, length);
for(i =0; i < length -1; i++)
{
coeff+=(vec[i]- vec_mean)*(vec[i +1]- vec_mean);
denom+=(vec[i]- vec_mean)*(vec[i]- vec_mean);
}
denom+=(vec[i]- vec_mean)*(vec[i]- vec_mean);
if(denom ==0) denom =0.00001;
resp= coeff/=denom;
return resp;
}

double Regression(double*vec,int length)
{
double vec_mean, autocor_coeff, std_deviation, rand_num;

    vec_mean =ArithmeticMean(vec, length);
    autocor_coeff =AutocorrelationLag1(vec, length);
    std_deviation =StandardDeviation(vec, length);
rand_num =(rand()%10000);/* Gera numero aleatorio entre 0 e 9999. */
rand_num /=9999;/* Normaliza entre 0.0000 e 1.0000 o numero aleatorio. */

return vec_mean +((vec[length -1]- vec_mean)* autocor_coeff)+(rand_num *
std_deviation * sqrt(1-(autocor_coeff * autocor_coeff)));
}
```

Anexo B

Neste anexo estão as tabelas com os parâmetros de entrada inseridos no modelo SWMM com as características das sub-bacias e trechos.

Tabela 9: Características das sub-bacias inseridas no SWMM.

Sub-bacia	Área	%AI	%Slope	NI	NP	DI	DP	%AIZero	CN
1	725	70	7.5	0.01	0.034	0.05	0.05	70	85
2	2184	40	9	0.01	0.034	0.05	0.05	60	85
3	621	5	10.1	0.01	0.034	0.015	0.05	25	87
4	89	75	7.6	0.01	0.034	0.05	0.05	25	75
5	368	95	8.1	0.01	0.034	0.05	0.05	100	85
6	743	95	8.6	0.01	0.034	0.05	0.05	100	92
7	49	95	9.2	0.01	0.034	0.05	0.05	25	92
8	482	95	8.1	0.01	0.034	0.05	0.05	100	92
9	432	75	8.1	0.01	0.034	0.05	0.05	100	75
10	389	90	10	0.01	0.034	0.05	0.05	100	79.5
11	11	1	10.9	0.01	0.1	0.05	0.05	25	75
12	609	90	8	0.01	0.034	0.05	0.05	25	90.7
13	550	95	10.7	0.01	0.034	0.05	0.05	25	75
14	331	60	10.5	0.01	0.034	0.05	0.05	25	70
15	98	10	10.9	0.01	0.034	0.05	0.05	25	65.3

%AI – porcentagem de área superficial impermeável

%AIZero – Porcentagem da área impermeável sem armazenamento de depressão (%)

%Slope – Declividade média da sub-bacia em porcentagem

DI – Profundidade do armazenamento em depressão na parcela impermeável da sub-bacia (mm)

DP – Profundidade do armazenamento em depressão na parcela permeável da sub-bacia (mm)

NI – n de manning para escoamento superficial na parcela impermeável da sub-bacia

NP - n de manning para escoamento superficial na parcela permeável da sub-bacia

Tabela 10: Características dos trechos inseridas no SWMM.

Conduto	Comprimento	Rugosidade	Conduto	Comprimento	Rugosidade
L-1	2494.41	0.034	L-18	250.533	0.034
L-2	756.55	0.034	L-19	2073.807	0.034
L-3	6292.38	0.034	L-20	256.98	0.034
L-4	309.53	0.012	L-21	2022.39	0.012
L-5	2554.71	0.012	L-22	911.9	0.012
L-6	42.09	0.012	L-24	155.94	0.012
L-7	1456.1	0.034	L-25	472.87	0.012
L-8	239.96	0.034	L-26	1217.13	0.012
L-9	1787.47	0.012	L-27	43	0.012
L-10	197.6	0.012	L-28	517.66	0.02
L-11	41.54	0.012	L-29	274.43	0.02
L-12	1162.17	0.053	L-30	2295.88	0.02
L-13	444.62	0.012	L-31	580.59	0.012
L-14	928	0.012	L-32	94.7	0.012
L-15	1024	0.012	L-33	58	0.012
L-16	1370	0.012	L-34	125.96	0.012
L-17	678.42	0.034	1	400	0.01