

Previsão de Níveis Fluviais com Redes LSTM (Long Short-Term Memory) Integrada ao Mapeamento de Áreas de Risco de Inundação

Suelen Vitoria da Silva
Instituto Tecnológico de Aeronáutica
São José dos Campos, SP, Brasil
suelen.silva.102130@ga.ita.br

Elcio Hideiti Shiguemori
Instituto de Estudos Avançados
São José dos Campos, SP, Brasil
elcio.shiguemori@gp.ita.br

Ana Paula Abrantes de Castro
Shiguemori
Instituto Federal de São Paulo
Jacareí, SP, Brasil
anapaula.acs@ifsp.edu.br

Elton Vicente Escobar Silva
Centro Nacional de Monitoramento e
Alertas de Desastres Naturais
São José dos Campos, SP, Brasil
elton.escobar@cemaden.gov.br

Leonardo Bacelar Lima Santos
Centro Nacional de Monitoramento e
Alertas de Desastres Naturais
São José dos Campos, SP, Brasil
leonardo.santos@cemaden.gov.br

Abstract

This study introduces an integrated framework for short-term hydrological forecasting and spatial flood risk mapping by coupling Long Short-Term Memory (LSTM) neural networks with the Height Above the Nearest Drainage (HAND) topographic model. Focused on the Tamanduateí River basin in São Paulo, Brazil—a critical fast-response catchment—the methodology addresses the urgent need for high-precision, low-latency alerts in densely urbanized areas. By utilizing precipitation and stage height time series, the LSTM model predicts river levels up to 60 minutes ahead, using 10-minute intervals and a 6-hour antecedent window. Results indicate exceptional predictive performance, yielding coefficients of determination (R^2) of 0.9946, 0.9757, and 0.8956 for 10, 30, and 60-minute lead times, respectively. Complementarily, the HAND model generates stratified susceptibility maps to delineate inundation extents across various river stages. These outputs provide interpretable, actionable visualizations that enhance preventive decision-making and emergency response planning in vulnerable urban environments.

Keywords

Inundações, Previsão de inundações, Áreas de risco de inundação, Inteligência artificial na previsão de inundações

1 INTRODUÇÃO

Inundações ocorrem quando rios ou outros corpos d'água excedem a capacidade de escoamento de seus leitos e extravasam suas margens, geralmente em resposta ao aumento do volume transportado [1]. Em regiões urbanas, esses eventos tendem a produzir impactos amplos e recorrentes, incluindo transtornos na mobilidade, perdas econômicas e patrimoniais, danos à infraestrutura, aumento da exposição a doenças e riscos adicionais à população, como acidentes associados à presença de animais peçonhentos [2]. A intensificação e a recorrência de episódios de inundação decorrem, em grande medida, da combinação entre extremos hidrometeorológicos e mudanças antrópicas no uso e ocupação do solo. Processos como impermeabilização excessiva, ocupação de áreas naturalmente suscetíveis e canalização de cursos d'água alteram a

drenagem natural, reduzem a infiltração e retenção, e amplificam o escoamento superficial, elevando a severidade das cheias durante precipitações intensas [3].

Neste contexto, a previsão de níveis fluviométricos constitui um elemento central de sistemas de alerta precoce e estratégias de redução de risco. Estimativas confiáveis com antecedência adequada viabilizam a adoção de medidas preventivas e a coordenação de respostas por parte de gestores públicos e equipes de emergência, contribuindo para reduzir impactos e apoiar a proteção civil em áreas vulneráveis [4]. Entretanto, a previsão operacional em bacias urbanas permanece desafiadora devido à não linearidade dos processos hidrológicos, à variabilidade espaço-temporal da precipitação e a limitações de instrumentação e disponibilidade de dados [5–7].

Modelos orientados a dados têm ganhado relevância por sua capacidade de aprender relações complexas diretamente de séries temporais observadas [6–8]. Entre eles, redes recorrentes do tipo *Long Short-Term Memory* (LSTM) destacam-se pela habilidade de representar dependências temporais de curto e longo prazo, apresentando desempenho consistente em tarefas de previsão em diferentes domínios [9]. Assim, ao explorar séries históricas provenientes de pluviômetros (precipitação) e fluviômetros (nível do rio), as LSTM configuram uma alternativa promissora para estimativas de curto prazo compatíveis com as necessidades de monitoramento e emissão de alertas.

De forma complementar, mapas de suscetibilidade e risco são fundamentais para incorporar a dimensão espacial do problema, permitindo identificar vulnerabilidades e apoiar ações de planejamento urbano e gestão de emergências [10]. Nesse âmbito, o modelo *Height Above the Nearest Drainage* (HAND), desenvolvido no Instituto Nacional de Pesquisas Espaciais (INPE), utiliza a normalização do Modelo Digital de Elevação (MDE) em relação à rede de drenagem para caracterizar quantitativamente a topo-hidrologia da paisagem. Ao representar a altura relativa de cada ponto do terreno em relação ao canal de drenagem mais próximo, o HAND possibilita delimitar áreas potencialmente alagáveis e subsidiar classificações de suscetibilidade com base em informação geomorfológica [11].

Diante desse cenário, este trabalho propõe uma metodologia integrada que combina a previsão de níveis fluviais por redes LSTM

com o mapeamento espacial do risco de inundação a partir de um produto HAND previamente classificado. As previsões de curto prazo são traduzidas em cenários de elevação do nível d'água e acopladas às informações topográficas do HAND para gerar classes espaciais de risco, visando produzir uma saída interpretável e acionável para monitoramento, alerta e tomada de decisão preventiva. A abordagem é aplicada à bacia do Rio Tamanduateí, na Região Metropolitana de São Paulo, utilizando dados observados de precipitação e nível do rio para avaliação do desempenho e demonstração do potencial de uso em contextos urbanos vulneráveis.

2 REVISÃO DA LITERATURA

A previsão de inundações tem sido historicamente conduzida por meio de modelos estatísticos e, sobretudo, por modelos hidrológicos e hidrodinâmicos de base física, que descrevem explicitamente processos de geração de escoamento, propagação de vazões e interação com características fisiográficas da bacia [5, 6]. Ferramentas consolidadas, como o *Soil and Water Assessment Tool* (SWAT) [12] e o *Hydrologic Modeling System* (HEC-HMS) [13], são empregadas para simular o comportamento hidrológico e estimar vazão e níveis d'água a partir de variáveis como precipitação, solo, uso e ocupação do solo e topografia [5]. Embora representem processos hidrológicos e sejam adequadas para a simulação de cenários, essas abordagens frequentemente requerem calibração e validação extensas, dependem de múltiplas fontes de dados hidrogeomorfológicos e podem impor elevado custo computacional em aplicações operacionais, sobretudo quando empregadas em alta resolução espacial e temporal [6].

Nos últimos anos, abordagens orientadas a dados têm ganhado protagonismo na literatura como alternativa ou complemento aos modelos físicos, particularmente em contextos em que a complexidade dos processos, a não linearidade e a disponibilidade heterogênea de dados tornam desafiadora a modelagem baseada em processos [6, 7]. Revisões recentes apontam para um crescimento do uso de modelos de aprendizado de máquina e aprendizado profundo na previsão de cheias, destacando seu potencial para capturar padrões complexos em séries temporais hidrológicas e produzir previsões com baixo custo computacional no estágio de inferência [6, 7]. Nesse cenário, redes recorrentes e variantes com mecanismos de memória têm sido exploradas por sua aptidão em modelar dependências temporais e efeitos de defasagem entre precipitação e resposta hidrológica [6, 7, 9].

Em particular, redes *Long Short-Term Memory* (LSTM) têm se mostrado eficazes em tarefas de previsão hidrológica por mitigar limitações de RNNs tradicionais e representar dependências de curto e longo prazo em séries temporais [9, 14, 15]. Estudos aplicados reportam bons resultados ao empregar arquiteturas recorrentes (incluindo LSTM e GRU) para previsão de nível d'água em cenários de alerta de inundação [9, 15].

Adicionalmente, trabalhos recentes têm incorporado estratégias de otimização e reaproveitamento de conhecimento, como *transfer learning*, com o objetivo de melhorar desempenho e generalização em modelos de previsão de inundações [6, 7]. Nesse contexto, Zhou et al. [8] propuseram um modelo *data-driven* que integra LSTM, otimização bayesiana e aprendizado por transferência, com ganhos

reportados em acurácia e eficiência preditiva em dimensões temporal e espacial [8]. Evidências na literatura indicam essa tendência de arquiteturas híbridas e de pipelines mais robustos, capazes de combinar desempenho preditivo e adaptabilidade a diferentes condições hidrológicas [4, 7, 8].

Assim, a literatura evidencia uma transição de abordagens estritamente físicas para soluções complementares orientadas a dados, com destaque para modelos recorrentes e métodos de aprendizado profundo aplicados a séries temporais hidrológicas [6, 7]. Contudo, permanece relevante investigar estratégias que conectem previsões hidrológicas de curto prazo a produtos espacialmente interpretáveis para suporte à decisão, especialmente em ambientes urbanos sujeitos a elevada exposição e vulnerabilidade.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Long Short-Term Memory (LSTM)

Nos anos recentes, as redes LSTM consolidaram-se como um recurso importante no campo da inteligência artificial e do aprendizado de máquina, sendo eficazes na modelagem de dados temporais ou sequenciais [15]. As redes neurais do tipo LSTM representam uma evolução das redes neurais recorrentes (RNN), concebidas para modelar dados sequenciais e capturar dependências temporais de longo prazo de maneira eficiente. Propostas por Hochreiter e Schmidhuber (1997)[14], as LSTM foram desenvolvidas para superar as limitações das RNN tradicionais, como o problema do gradiente desvanecente durante o treinamento. A arquitetura da LSTM inclui mecanismos de controle chamados "portas" (de entrada, esquecimento e saída), que permitem à rede manter, atualizar ou descartar informações ao longo do tempo, facilitando o aprendizado de padrões complexos em séries temporais. Por essa razão, as LSTM são utilizadas em tarefas que envolvem previsão de séries temporais, como hidrologia, meteorologia, finanças e processamento de linguagem natural.

3.2 Height Above the Nearest Drainage (HAND)

O modelo *HAND* (*Height Above the Nearest Drainage*), desenvolvido por Nobre et al. [16], é uma técnica de transformação do Modelo Digital de Elevação (MDE) que calcula a altura relativa de cada ponto do terreno em relação ao ponto mais próximo da rede de drenagem. Essa normalização fornece uma estimativa do potencial gravitacional local, permitindo identificar zonas de escoamento, acúmulo e saturação da água no solo. O HAND apresenta correlação com a profundidade do lençol freático e permite classificar o terreno em faixas hidrologicamente homogêneas. Essa característica o torna útil para o mapeamento de áreas potencialmente alagáveis e para a parametrização de modelos hidrológicos. Além disso, sua aplicação é robusta mesmo em bacias não instrumentadas, utilizando apenas dados topográficos.

4 METODOLOGIA

4.1 Área de Estudo

Na Figura 1 apresenta-se a área de estudo do projeto, onde foram selecionados dados das estações pluviométricas e fluviométricas da bacia do Rio Tamanduateí, localizada na região metropolitana de São Paulo.

O conjunto de treinamento, compreendido entre janeiro de 2022 e outubro de 2024 (representado em azul), forneceu a base histórica necessária para que as arquiteturas LSTM e GRU identificassem os padrões sazonais e as correlações não-lineares da bacia. Subsequentemente, o conjunto de validação, abrangendo de outubro de 2024 a fevereiro de 2025 (em laranja), foi utilizado para o ajuste fino dos hiperparâmetros e para a mitigação do *overfitting* por meio do monitoramento das curvas de aprendizado. Por fim, o conjunto de teste, estendendo-se de fevereiro a maio de 2025 (em verde), serviu como a avaliação definitiva do desempenho em dados inéditos.

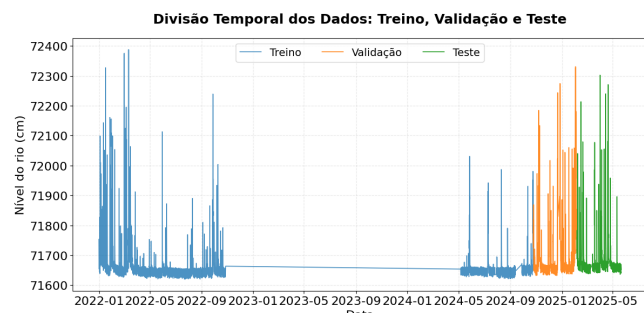


Figure 3: O Gráfico apresenta a divisão temporal dos dados.

5.2 Análise de Convergência e Curvas de Aprendizado

Para validar a integridade do processo de treinamento e assegurar a capacidade de generalização das arquiteturas propostas, foram analisadas as curvas de aprendizado (*loss curves*) baseadas no Erro Quadrático Médio (MSE). A Figura 4 ilustra a evolução do erro para as redes LSTM e GRU ao longo de 70 épocas.

Observa-se que ambas as arquiteturas apresentaram uma convergência rápida e estável, com uma redução acentuada do erro nas primeiras 10 épocas, seguida de uma estabilização assintótica em torno de 0,0004. O comportamento síncrono entre as curvas de treinamento (linhas sólidas) e validação (linhas tracejadas) é um indicativo robusto da ausência de *overfitting*.

Embora a rede GRU tenha apresentado uma descida de erro ligeiramente mais suave nas épocas iniciais, a arquitetura LSTM demonstrou uma menor amplitude de oscilação na curva de validação durante a fase de estabilização. Essa estabilidade é crucial para garantir que o modelo mantenha sua precisão frente a variabilidades inesperadas no nível do rio, fundamentando a confiabilidade das métricas de desempenho estatístico discutidas na seção subsequente.

5.3 Métricas de Avaliação

No que tange ao desempenho preditivo, a Tabela 1 consolida os resultados obtidos para os diferentes horizontes temporais, comparando as arquiteturas propostas com o modelo de persistência.

A análise dos resultados revela que a LSTM é a arquitetura mais adequada para a bacia do Tamanduateí, dada a sua natureza de resposta rápida. No horizonte crítico de 10 minutos, a LSTM obteve um RMSE de 5,16, sendo 12% mais precisa que a GRU (5,92). Esta precisão inicial é vital para o acionamento de sistemas de alerta precoce em áreas urbanas densamente impermeabilizadas.

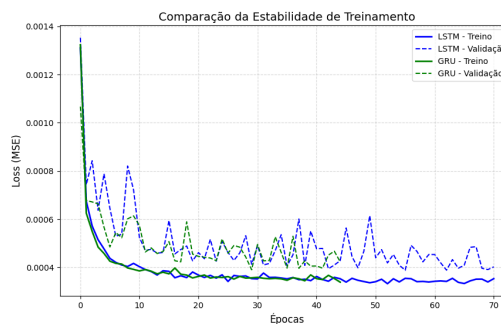


Figure 4: Curva de aprendizado do modelo proposto.

Horizonte	Modelo	RMSE	MAE	R^2	NSE	KGE
10 min	LSTM	5,16	1,88	0,994	0,994	0,986
	GRU	5,92	1,95	0,993	0,993	0,995
	Persistência	6,44	1,65	0,991	0,991	0,995
20 min	LSTM	7,55	2,04	0,988	0,988	0,981
	GRU	7,58	2,11	0,988	0,988	0,992
	Persistência	12,12	3,11	0,970	0,970	0,985
30 min	LSTM	11,31	2,74	0,974	0,974	0,980
	GRU	11,08	2,78	0,975	0,975	0,987
	Persistência	17,23	4,55	0,940	0,940	0,970
40 min	LSTM	15,43	3,75	0,952	0,952	0,975
	GRU	15,20	3,64	0,954	0,954	0,975
	Persistência	21,85	5,96	0,904	0,904	0,952
50 min	LSTM	19,48	4,73	0,924	0,924	0,961
	GRU	19,32	4,60	0,925	0,925	0,956
	Persistência	26,06	7,34	0,864	0,864	0,932
60 min	LSTM	23,34	5,75	0,891	0,891	0,942
	GRU	23,24	5,59	0,892	0,892	0,932
	Persistência	29,91	8,68	0,821	0,821	0,910

Table 1: Comparação de métricas de avaliação entre os modelos (10-60 min).

Embora a GRU demonstre uma vantagem numérica discreta aos 60 minutos (RMSE de 23,24 vs. 23,34), a avaliação qualitativa indica que a LSTM possui maior estabilidade preditiva. Essa consistência nos hidrogramas torna a LSTM mais adequada para a previsão de curto prazo em bacias de resposta rápida, onde a precisão na tendência de subida do nível é crítica.

O decaimento do R^2 de 0,994 para 0,891 ao longo de uma hora reflete a propagação natural da incerteza, validando a integridade estatística do modelo e afastando hipóteses de *overfitting*. Ademais, o elevado valor de KGE (0,942) mantido pela LSTM aos 60 minutos reforça sua capacidade de preservar a variabilidade e a média dos eventos de cheia, consolidando-a como uma ferramenta eficaz para o suporte à decisão da Defesa Civil.

5.4 Gráficos de Resíduos

Nas Figuras 5 e 6 apresenta-se a distribuição dos resíduos para as arquiteturas LSTM e GRU, respectivamente. A análise da dispersão desses erros é fundamental para verificar a imparcialidade dos modelos e a ausência de tendências sistemáticas nas estimativas de nível.

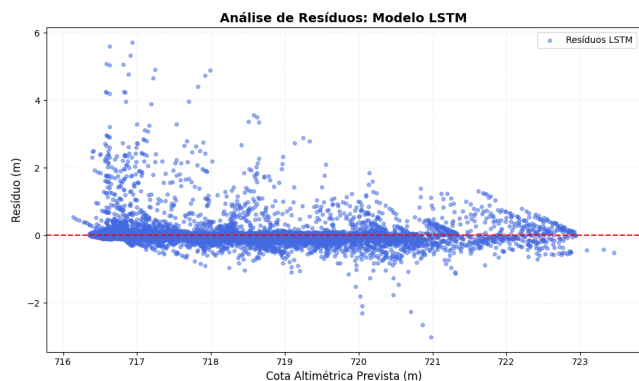


Figure 5: Gráfico de resíduos LSTM.

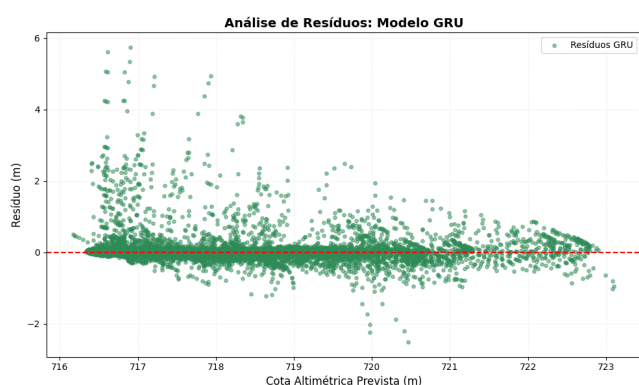


Figure 6: Gráfico de resíduos GRU.

Conforme ilustrado, os valores referem-se à cota em relação ao nível médio do mar, expressos em metros (m), onde a massa de erros se concentra simetricamente em torno do eixo zero.

A maioria das ocorrências situa-se em uma faixa de erro reduzida, geralmente inferior a 0,10 m, o que é compatível com o alto coeficiente de determinação obtido. Entretanto, nota-se a presença de picos residuais positivos que atingem o patamar de 6,00 m em cotas superiores a 717,00 m, evidenciando episódios isolados de subestimação. Tais discrepâncias são intrínsecas à complexidade física da bacia do Tamanduateí, onde eventos de cheias repentinas (*flash floods*) impõem variações abruptas de cota que desafiam a precisão absoluta.

A estabilidade do modelo foi confirmada pela variância controlada do erro mesmo em cotas elevadas, demonstrando que a precisão das previsões não sofre oscilações significativas em função da amplitude da cota altimétrica. Quanto à incerteza preditiva, o RMSE de 0,05 m (10 min) e 0,23 m (60 min) estabelece a margem de erro esperada para aplicações em tempo real. Embora o modelo forneça previsões pontuais, essa métrica serve como indicador de confiança para a Defesa Civil, visto que o erro médio observado representa uma fração mínima da cota total do rio.

5.5 Gráficos de Valores Observados vs. Previstos

Na Figura 7 apresenta-se o gráfico de dispersão que correlaciona as cotas altimétricas medidas pelo sensor com as previsões geradas pela rede LSTM.

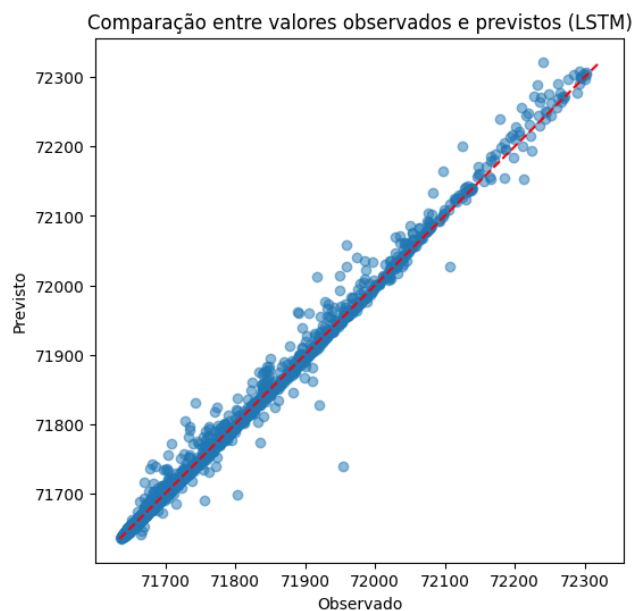


Figure 7: O Gráfico de previsão LSTM vs. observado.

A análise visual revela uma forte aderência dos dados à linha de referência.

Observa-se que a maioria das observações concentra-se na cota de base de 717,00 m, correspondente ao nível médio do mar na região da bacia do Tamanduateí. No entanto, a manutenção da linearidade em cotas superiores a 723,00 m indica que o modelo preserva sua acurácia mesmo durante eventos de extravasamento, sem apresentar dispersões significativas ou subestimações sistemáticas em níveis críticos.

Diferente de modelos lineares simples que podem ter métricas infladas pela predominância de valores baixos, a distribuição apresentada na Figura 7 indica que a rede neural aprendeu a dinâmica de ascensão do rio. A ausência de "nuvens" de pontos distantes da diagonal principal sugere que o erro é estável e que o desempenho estatístico reflete uma capacidade real de previsão operacional, minimizando o risco de falsos negativos em situações de emergência hidrológica.

5.6 Análise de Estabilidade e Incerteza Preditiva por Regime Sazonal

A avaliação da eficácia do modelo LSTM foi realizada por meio da análise de resíduos e da consistência das previsões em diferentes estados hidrológicos da bacia do Tamanduateí.

O conjunto de teste, compreendido entre fevereiro e maio de 2025, permitiu validar o sistema tanto no auge do período chuvoso quanto na transição para o regime de estiagem. No período de cheia (Fevereiro-Março), apresentado na Figura 8, caracterizado por eventos de *flash floods*, o modelo demonstrou alta aderência à linha de referência 1:1, sendo capaz de prever picos superiores a 723,00 m. Essa performance em eventos extremos é importante para o suporte à decisão da Defesa Civil, garantindo que os alertas de inundação sejam baseados em tendências físicas reais e não em ruídos estatísticos.

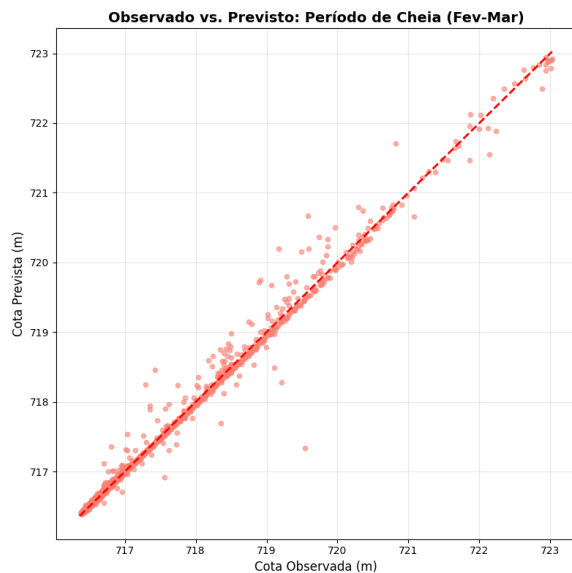


Figure 8: Gráfico em períodos chuvosos.

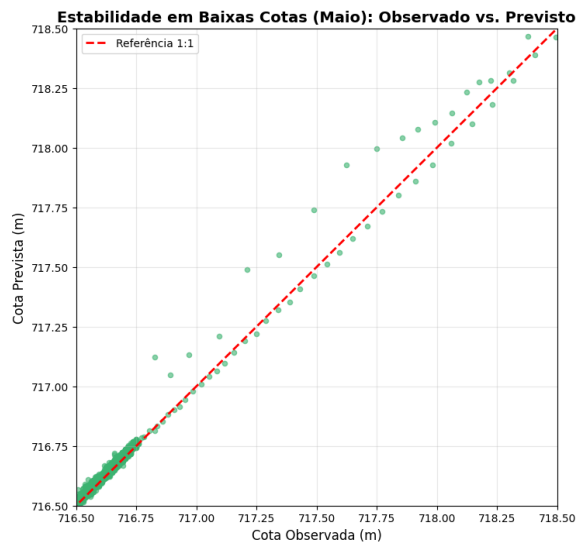


Figure 9: Gráfico de maio.

Adicionalmente, a estabilidade em baixas cotas foi verificada utilizando o mês de maio como *proxy* para o regime seco. A Figura 9 revela uma dispersão mínima em torno da cota de base (717,00 m). Esta evidência indica que a rede neural permanece calibrada na ausência de precipitação intensa, não apresentando deriva preditiva (*drift*) ou viés sistemático que pudesse comprometer a confiabilidade do sistema durante longos períodos de estiagem. Portanto, os resultados ratificam a prontidão operacional da metodologia proposta para o monitoramento contínuo e a mitigação de desastres na Região Metropolitana de São Paulo.

5.7 Mapeamento de Suscetibilidade via Modelo HAND

A espacialização das áreas vulneráveis a processos de inundação na bacia do Tamanduati foi realizada por meio do modelo topográfico HAND (*Height Above the Nearest Drainage*), conforme ilustrado na Figura 10. Esta abordagem permitiu a classificação do terreno em cinco classes de suscetibilidade, baseando-se estritamente na distância vertical de cada pixel em relação ao curso d'água mais próximo. A estratificação adotada compreende as classes: Muito Alta (0 a 1 m), Alta (1 a 5 m), Média (5 a 10 m), Baixa (10 a 25 m) e Muito Baixa (25 a 100 m), fornecendo um gradiente detalhado da vulnerabilidade física do relevo local.

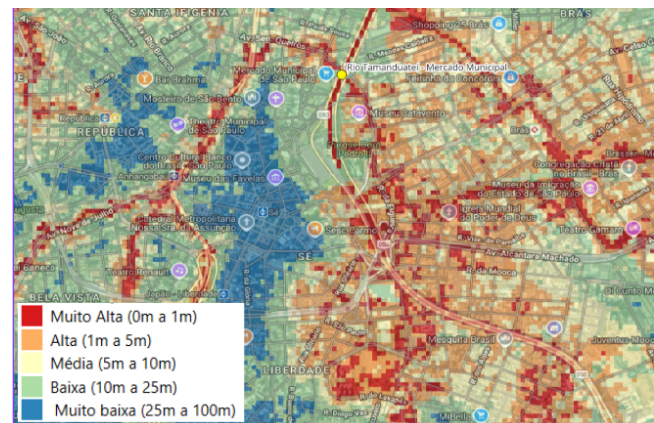


Figure 10: Mapa de suscetibilidade a inundações gerado a partir do modelo HAND classificado em cinco categorias de risco.

É importante ressaltar que a metodologia empregada baseia-se em critérios topográficos derivados do Modelo Digital de Elevação (MDE). Devido à complexidade e à dificuldade de acesso a dados técnicos detalhados sobre a infraestrutura de drenagem urbana, impermeabilização do solo e rugosidade hidráulica na Região Metropolitana de São Paulo, o modelo HAND foi selecionado por oferecer uma análise inicial e de baixo custo computacional. Embora outros fatores hidrodinâmicos influenciem a propagação real das águas, a topografia normalizada pelo HAND serve como um indicador primário eficaz da conectividade hídrica e do potencial de acumulação de água na superfície.

A integração deste mapa com as previsões temporais da rede LSTM potencializa a utilidade da ferramenta para a gestão de desastres. Ao prever incrementos na cota do rio (como as variações entre 717 m e 723 m observadas nos períodos de cheia), é possível correlacionar o nível previsto com as faixas métricas do HAND apresentadas na Figura 10. Assim, mesmo tratando-se de uma análise inicial centrada na topografia, o produto final oferece uma visualização espacial acionável que auxilia a Defesa Civil na identificação antecipada de logradouros em risco durante eventos de *flash floods*.

5.8 Integração LSTM-HAND e Análise de Cenários Operacionais

A metodologia proposta acopla a precisão temporal das redes neurais LSTM à espacialização topográfica do modelo HAND para

traduzir previsões hidrológicas em cenários de risco acionáveis. Esta abordagem permite identificar não apenas "quando" o nível do rio atingirá uma cota crítica, mas "onde" os impactos espaciais serão mais severos na mancha urbana.

5.9 Definição de Cenários e Limiares de Referência

Para fundamentar a análise, adotaram-se os limiares operacionais da estação Mercado Municipal, monitorada pelo SAISP Figura 11. Os estágios de criticidade oficial são definidos em: 722,779 m (Atenção), 723,779 m (Alerta), 724,779 m (Emergência) e 725,775 m (Extravasamento). Com base nestes parâmetros, foram simulados quatro cenários incrementais (718 m e 722 m) para avaliar a sensibilidade do modelo HAND.




Figure 11: Limiares Saisp.

5.10 Análise da Progressão da Suscetibilidade



Figure 12: Áreas de risco para a cota de 718,000.

A Figura 12 detalha o cenário de 718,000 m, que se destaca como um estágio crítico para o sistema de alerta precoce. Mesmo estando significativamente abaixo do limiar de Atenção oficial do SAISP (722,779 m), o modelo sinaliza regiões em estado de Atenção e Alerta, com ênfase na Avenida do Estado. Este resultado comprova a sensibilidade da metodologia em detectar vulnerabilidades topográficas e potenciais pontos de acúmulo de água de forma antecipada ao acionamento dos sensores físicos de calha.

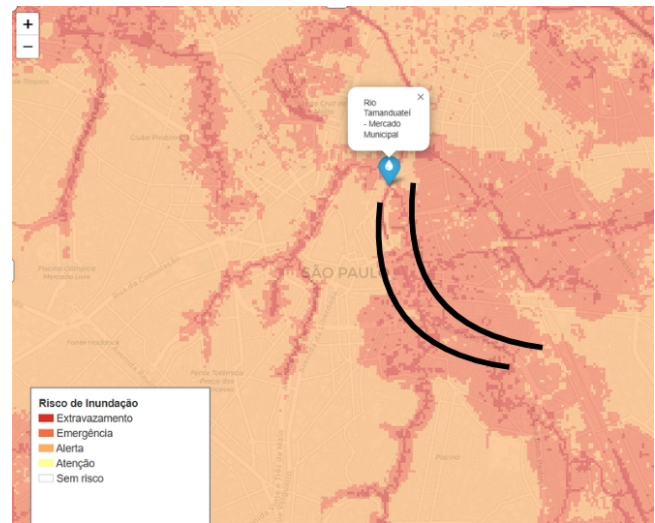


Figure 13: Áreas de risco para a cota de 722,000.

A Figura 13 detalha a simulação para a cota de 722,000 m, pata-mar que se aproxima do estágio de Atenção oficial definido pelo SAISP (722,779 m). Neste nível, o modelo indica uma transição crítica de risco, com a mancha de inundação expandindo-se para as classes de Extravasamento, Emergência e Alerta, sinalizando o comprometimento iminente da capacidade da calha principal.

5.11 Validação Qualitativa: O Caso da Avenida do Estado

A confiabilidade do mapeamento foi verificada confrontando os resultados com registros históricos do CGE-SP apresentados na Figura 14. Os dados indicam que a Avenida do Estado (região entre as marcações pretas nas Figuras 12 e 13) é recorrentemente classificada como área intransitável em eventos de cheia. A convergência espacial entre as manchas de risco geradas pelo HAND e os registros de interdição real verifica a metodologia para a identificação de logradouros criticamente vulneráveis.

	De 16:08 a 21:21 AV DO ESTADO	Sentido: SANTANA/IPIRANGA Referência: R S CAETANO (BOM RETIRO)
	De 16:38 a 18:01 R STA ISABEL	Sentido: BAIRRO/CENTRO Referência: R AMARAL GURGEL
	De 17:20 a 21:01 AV DO ESTADO	Sentido: IPIRANGA/SANTANA Referência: R JOAO TEODORO

Figure 14: Registro do CGE de áreas inundadas que ficaram intransitáveis dia 24/01/2025.

5.12 Discussão sobre Limitações e "Falsos Positivos"

É importante reconhecer que o modelo HAND oferece uma análise inicial, servindo como um indicador primário de conectividade hídrica. Contudo, por ser um modelo puramente topográfico, ele pode indicar áreas como inundadas que, na realidade, podem não sofrer alagamentos devido a outros fatores hidrodinâmicos ou à presença de infraestrutura de micro-drenagem urbana (galerias pluviais) não contabilizada nesta escala. Assim, o produto final deve ser interpretado como um mapa de suscetibilidade potencial, oferecendo uma visualização acionável para o auxílio antecipado da Defesa Civil.

6 CONCLUSÃO

Este estudo indicou que a integração de modelos de aprendizagem profunda com o mapeamento topográfico HAND constitui uma estrutura metodológica promissora para o monitoramento preventivo de inundações urbanas. A análise comparativa evidenciou que as arquiteturas *Long Short-Term Memory* e *Gated Recurrent Unit* superaram o modelo de Persistência, indicando uma capacidade superior em capturar as não-linearidades do Rio Tamandateí. A configuração baseada em uma janela de entrada de seis horas para previsões de até uma hora à frente permitiu que a LSTM alcançasse um coeficiente de determinação (R^2) superior a 0,99, evidenciando a base necessária para a espacialização precisa do risco.

O principal diferencial prático observado foi a capacidade de detecção proativa, uma vez que o sistema identificou vulnerabilidades na Avenida do Estado já no nível de 718, 000 m, representando uma antecipação estratégica. Embora o trabalho se caracterize como uma prova de conceito — com limitações inerentes à simplificação do modelo HAND e à ausência de uma validação hidrodinâmica completa da bacia — a convergência qualitativa com os registros de áreas intransitáveis do CGE-SP valida o potencial da ferramenta para o suporte à decisão da Defesa Civil.

Para desenvolvimentos futuros, vislumbra-se a incorporação de variáveis exógenas como pluviosidade em tempo real, umidade do solo e modelos digitais de elevação de alta resolução, além da realização de validações quantitativas sistemáticas com registros históricos de inundação. Pretende-se ainda explorar modelos híbridos que associem LSTMs a Redes Neurais Convolucionais e integrar dados de radar meteorológico para estender o horizonte de previsão, bem como incorporar dados da rede de galerias pluviais ao modelo HAND para mitigar falsos positivos e elevar a precisão das manchas urbanas. Em síntese, esta pesquisa estabelece um marco técnico ao demonstrar que a união entre inteligência artificial temporal e análise topográfica pode antecipar riscos reais, oferecendo subsídios para que a gestão pública atue na mitigação de desastres.

7 AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. Elcio Hideiti Shigumori é parcialmente financiado pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (316948/2023-3).

References

- [1] G.L. Urbani, M.C.P. Graciosa, and M.C. Valverde. Delimitação de manchas de inundação na Bacia do Córrego do Ipiranga, São Paulo - SP, Brasil, com modelagem hidrológico-hidráulica. *Revista de Gestão de Água da América Latina*, 20:e13, 2023. doi: 10.21168/rega.v20e13.
- [2] J.D.A. Nylander, A.J.A. Barros, K.F.C. Mesquita, G.C.M. Bezerra, and J.A.R. Pereira. Análise das causas e consequências de inundações e alagamentos na bacia hidrográfica da Tamandaré do município de Belém/PA. *Brazilian Journal of Development*, 7(5):49335–49348, 2021. doi: 10.34117/bjdv.v7i5.29920.
- [3] G.F. Ferreira, A.P. Veról, and R.R. de Mattos. Soluções baseadas na natureza para requalificação urbana e ambiental das margens do Rio Piraquara, Realengo (RJ). In *Anais do 5º Encontro Latino Americano e Europeu sobre Edificações e Comunidades Sustentáveis*, 2023.
- [4] P.Y. Kow, J.Y. Liou, M.T. Yang, M.H. Lee, L.C. Chang, and F.J. Chang. Advancing climate-resilient flood mitigation: Utilizing transformer-LSTM for water level forecasting at pumping stations. *Science of The Total Environment*, 927:172246, 2024. doi: 10.1016/j.scitotenv.2024.172246.
- [5] M. Aliye, A. Aga, T. Tadesse, and P. Yohannes. Evaluating the performance of HEC-HMS and SWAT hydrological models in simulating the rainfall-runoff process for data scarce region of Ethiopian Rift Valley Lake Basin. *Open Journal of Modern Hydrology*, 10(4):105–122, 2020. doi: 10.4236/ojmh.2020.104007.
- [6] A. Mosavi, P. Ozturk, and K. Chau. Flood prediction using machine learning models: Literature review. *Water*, 10(11):1536, 2018. doi: 10.3390/w10111536.
- [7] S. Refadah. Development in flood forecasting: A comprehensive review of complex and machine learning models. *Physics and Chemistry of the Earth, Parts A/B/C*, 139:103975, 2025. doi: 10.1016/j.pce.2025.103975.
- [8] L. Zhou, Z. Pan, J. Wang, Z. Wei, and Y. Meng. A deep-learning-technique-based data-driven model for accurate and rapid flood predictions in temporal and spatial dimensions. *Hydrology and Earth System Sciences*, 27(9):1791–1808, 2023. doi: 10.5194/hess-27-1791-2023.
- [9] M. Cho, C. Kim, K. Jung, and H. Jung. Water level forecasting model applying a gated recurrent unit (GRU) method with long short-term memory (LSTM) for flood forecasting. *Water*, 14(14):2221, 2022. doi: 10.3390/w14142221.
- [10] R.B. Mudashiru, N. Sabtu, I. Abustan, and W. Balogun. Flood hazard mapping methods: A review. *Journal of Hydrology*, 603:126846, 2021. doi: 10.1016/j.jhydrol.2021.126846.
- [11] A.A. Queiroga, R.G.L. Oliveira, H.J.A. Filgueira, and C. Cunico. Mapeamento de áreas suscetíveis à inundação aplicando diferentes modelos digitais de elevação no modelo Height Above the Nearest Drainage (HAND). *Revista do Departamento de Geografia*, 43:e191008, 2023. doi: 10.11606/eISSN.2236-2878.rdg.2023.191008.
- [12] Jeffrey G Arnold, Raghavan Srinivasan, Ranjan S Muttiah, and Jimmy R Williams. Large area hydrologic modeling and assessment part i: Model development. *JAWRA Journal of the American Water Resources Association*, 34(1):73–89, 1998. doi: 10.1111/j.1752-1688.1998.tb05961.x.
- [13] U.S. Army Corps of Engineers. *Hydrologic Modeling System HEC-HMS: Technical Reference Manual*. Hydrologic Engineering Center (HEC), Davis, CA, 2000. CPD-74B.
- [14] S. Hochreiter and J. Schmidhuber. Long short-term memory. *Neural Computation*, 9(8):1735–1780, 1997. doi: 10.1162/neco.1997.9.8.1735.
- [15] C. Sampaio Descovi, A.C. Zuffo, S. Mohammadzadeh, L.F. Murillo Bermúdez, and D. Alfonso Sierra. Redes de memória de longo e curto prazo (LSTM) para predição de fluxo de rio na bacia do Pantanal Brasileiro. *HOLOS*, 5:1–18, 2023. doi: 10.15628/holos.2023.16315.
- [16] A.D. Nobre, L.A. Cuartas, M.G. Hodnett, C.D. Rennó, H. Rodrigues, A. Silveira, M.J. Waterloo, and G. Sales. Height Above the Nearest Drainage – a hydrologically relevant new terrain model. *Journal of Hydrology*, 404(1-2):13–29, 2011. doi: 10.1016/j.jhydrol.2011.03.051.