



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO TECNOLÓGICO  
CURSO DE GRADUAÇÃO EM CIÊNCIAS DA COMPUTAÇÃO

Gabriel Dutra

**Previsão de eventos emergenciais utilizando séries temporais e  
aprendizado de máquina**

Florianópolis  
2024

Gabriel Dutra

**Previsão de eventos emergenciais utilizando séries temporais e  
aprendizado de máquina**

Trabalho de Conclusão do Curso de Graduação do Curso de Graduação em Ciências da Computação do Centro Tecnológico da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Ciências da Computação.

Orientador: Prof. Renato Fileto, Dr.

Coorientador: Prof. Mateus Grellert, Dr.

Florianópolis

2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.  
Dados inseridos pelo próprio autor.

Dutra, Gabriel

Previsão de eventos emergenciais utilizando séries temporais e aprendizado de máquina / Gabriel Dutra ; orientador, Renato Fileto, coorientador, Mateus Grellert, 2024.

92 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro Tecnológico, Graduação em Ciências da Computação, Florianópolis, 2024.

Inclui referências.

1. Ciências da Computação. 2. Inteligência Artificial. 3. Ciência de Dados. I. Fileto, Renato. II. Grellert, Mateus. III. Universidade Federal de Santa Catarina. Graduação em Ciências da Computação. IV. Título.

Gabriel Dutra

**Previsão de eventos emergenciais utilizando séries temporais e  
aprendizado de máquina**

Trabalho de Conclusão de Curso submetida ao Curso de Graduação em Ciências da Computação da Universidade Federal de Santa Catarina para a obtenção do título de Bacharel em Ciências da Computação.

Florianópolis, 06 de Dezembro de 2024

**Banca Examinadora:**

---

Prof. Renato Fileto, Dr.  
Orientador  
Universidade Federal de Santa Catarina

---

Prof. Mateus Grellert, Dr.  
Coorientador  
Universidade Federal do Rio Grande do Sul

---

Prof. Jônata Tyska Carvalho, Dr.  
Avaliador  
Universidade Federal de Santa Catarina

## ABSTRACT

Emergency situations can occur due to natural causes (e.g. meteorological conditions) and other ones (e.g. accidents). In order for occurrences to be handled efficiently, service facilities must be strategically installed and configured, based on geographic issues and the demand occasionated by incidents that happen in each region. However, emergency events vary over time, as several factors such as meteorological and social events can change the dynamics of occurrences. Thus, the efficiency of fire department facilities positioned according to incident averages is hindered by these dynamics, especially when these facilities are not prepared for peaks in the number of occurrences. Emergency event forecasting techniques with good results can enable better decision making. However, accurate forecasting of emergency events is still a challenge, despite the recent developments in machine learning. This work aims to exploit temporal series of emergency events to build ARIMA, RNN and LSTM models to predict emergency events along time and space. Other data, such as historic meteorological data and geographic data related to risky areas will also be considered for building distinct models. The performance of these models and state-of-the-art solutions will be evaluated to compare prediction quality.

**Key Words:** ARIMA. RNN. LSTM. Time Series. Emergency Events. Prediction.

## RESUMO

Situações emergenciais podem ocorrer devido a causas naturais (e.g. condições meteorológicas) além de outras (e.g. acidentes). Para que as ocorrências sejam tratadas de forma eficaz, unidades de atendimento são instaladas e configuradas estrategicamente, baseadas em questões geográficas e demanda causada por incidentes que ocorrem em cada região. Entretanto, eventos emergenciais variam com o tempo, devido a diversos fatores tais quais meteorológicos e eventos sociais podem modificar a dinâmica das ocorrências. Então, a eficiência das instalações do departamento de bombeiros é posicionada de acordo com a média de incidentes por essas dinâmicas, especialmente quando elas não estão preparadas para picos nos números de ocorrências. Técnicas para previsões de eventos emergenciais com bons resultados podem possibilitar melhor tomada de decisão. Contudo, previsões de eventos emergenciais precisas ainda são um desafio, apesar de recentes desenvolvimentos em aprendizagem de máquina. Esse trabalho visa explorar séries temporais de eventos emergenciais para construir modelos ARIMA, RNN e LSTM para prever eventos emergenciais atrelado ao tempo e espaço. Outros dados, como dados históricos meteorológicos e geográficos relacionados a áreas de risco também serão considerados para a construção de diferentes modelos. A performance desses modelos e soluções referentes ao estado da arte serão avaliadas para comparar a qualidade das previsões.

**Palavras-chave:** ARIMA. RNN. LSTM. Séries temporais. Eventos de emergência. Previsão.

## LISTA DE FIGURAS

Figura 1 – Exemplo de série temporal: Número de ocorrências variando no tempo	14
Figura 2 – Estrutura de uma rede LSTM	16
Figura 3 – Processo de pesquisa bibliográfica realizado	21
Figura 4 – Fluxo geral de informação.	27
Figura 5 – A metodologia CRISP-DM	28
Figura 7 – Tabela de Classes de Suscetibilidade a Inundações	35
Figura 6 – Riscos de movimentos gravitacionais e suscetibilidade a inundações	36
Figura 8 – Tabela de Classes de Suscetibilidade a Movimentos de Massa	37
Figura 9 – Quantidade de Ocorrências por Tipo	39
Figura 10 – Subtipos de Atendimento Pré-Hospitalar	40
Figura 11 – Subtipos de Salvamento/ Busca / Resgate	41
Figura 12 – Autocorrelação de Pearson com diferentes lags temporais	42
Figura 13 – Série Temporal: Número de ocorrências de eventos do TIPO Salvamento/Busca/Resgate em Florianópolis variando no tempo	47
Figura 14 – Autocorrelation Function (ACF)	48
Figura 15 – Partial Autocorrelation (PACF)	48
Figura 16 – Análise Residual de Quantidade de Ocorrências	49
Figura 17 – Ocorrências Florianópolis - ARIMA	50
Figura 18 – Ocorrências Florianópolis - RNN	51
Figura 19 – Ocorrências Florianópolis - LSTM	52
Figura 20 – Ocorrências Florianópolis com dados meteorológicos - RNN	54
Figura 21 – Ocorrências Florianópolis com dados meteorológicos - LSTM	56
Figura 22 – Ocorrências Florianópolis com dados de áreas de risco - RNN	59
Figura 23 – Ocorrências Florianópolis com dados de áreas de risco - LSTM	61
Figura 24 – Ocorrências Florianópolis com dados meteorológicos e de áreas de risco - RNN	63
Figura 25 – Ocorrências Florianópolis com dados meteorológicos e de áreas de risco - LSTM	64
Figura 26 – Série Temporal: Número de ocorrências de eventos do TIPO Salvamento/Busca/Resgate em Santa Catarina ao longo do tempo	66
Figura 27 – Autocorrelação (ACF) com dados de SC	67
Figura 28 – Autocorrelação Parcial (PACF) com dados de SC	67
Figura 29 – Residual dos Dados de Santa Catarina	68
Figura 30 – Ocorrências Santa Catarina com dados de áreas de risco - ARIMA	69
Figura 31 – Ocorrências Santa Catarina com dados de áreas de risco - RNN	70
Figura 32 – Ocorrências Santa Catarina com dados de áreas de risco - LSTM	71

## LISTA DE TABELAS

Tabela 1 – Tabela Comparativa dos Artigos . . . . .	25
Tabela 3 – Tipos e Subtipos de Ocorrências . . . . .	31
Tabela 2 – Dicionário de dados do dataset . . . . .	33
Tabela 4 – Dicionário de dados do INMET . . . . .	34
Tabela 5 – Resumo do desempenho dos modelos no experimento Ocorrências em Florianópolis . . . . .	53
Tabela 6 – Resumo do desempenho dos modelos no experimento Ocorrências em Florianópolis com dados meteorológicos . . . . .	57
Tabela 7 – Resumo do desempenho dos modelos no experimento Ocorrências em Florianópolis com dados de áreas de risco . . . . .	62
Tabela 8 – Resumo do desempenho dos modelos no experimento Ocorrências em Florianópolis com dados meteorológicos e de áreas de risco . . . . .	65
Tabela 9 – Resumo do desempenho dos modelos no experimento Todas as ocorrências Santa Catarina com dados de áreas de risco . . . . .	72
Tabela 10 – Resumo do desempenho dos modelos nos experimentos . . . . .	73

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>10</b>
1.1	OBJETIVOS	11
1.2	JUSTIFICATIVA	11
1.3	METODOLOGIA	12
1.4	ESTRUTURA DO TRABALHO	12
<b>2</b>	<b>FUNDAMENTOS</b>	<b>13</b>
2.1	SÉRIES TEMPORAIS	13
2.2	ARIMA	14
2.3	REDES NEURAIS RECORRENTES	15
<b>2.3.1</b>	<b>Redes LSTM</b>	<b>15</b>
2.4	MEDIDAS DE DESEMPENHO DE PREDITORES	16
<b>2.4.1</b>	<b>Mean Squared Error</b>	<b>16</b>
<b>2.4.2</b>	<b>Root Mean Squared Error</b>	<b>17</b>
<b>2.4.3</b>	<b>Mean Absolute Error</b>	<b>18</b>
<b>2.4.4</b>	<b>Mean Absolute Percentage Error</b>	<b>19</b>
2.5	ESTADO DA ARTE	19
<b>2.5.1</b>	<b>Pesquisa Bibliográfica</b>	<b>19</b>
<b>2.5.2</b>	<b>Trabalhos Selecionados</b>	<b>21</b>
<b>2.5.3</b>	<b>Análise comparativa</b>	<b>24</b>
<b>3</b>	<b>DESENVOLVIMENTO DO TRABALHO</b>	<b>26</b>
3.1	PROPOSTA	26
3.2	METODOLOGIA	27
3.3	ENTENDIMENTO DO NEGÓCIO	27
<b>3.3.1</b>	<b>Seleção de modelos de predição</b>	<b>28</b>
<b>3.3.2</b>	<b>Seleção das Fontes de Dados</b>	<b>31</b>
3.4	ENTENDIMENTO E PREPARAÇÃO DOS DADOS	37
3.5	TREINAMENTO DOS MODELOS	40
3.6	AValiação DOS MODELOS	44
<b>4</b>	<b>EXPERIMENTOS</b>	<b>46</b>
4.1	OCORRÊNCIAS EM FLORIANÓPOLIS	46
4.2	FLORIANÓPOLIS COM DADOS METEOROLÓGICOS	53
4.3	FLORIANÓPOLIS COM DADOS DE ÁREAS DE RISCO	57
4.4	FLORIANÓPOLIS COM DADOS METEOROLÓGICOS E DE ÁREAS DE RISCO	62
4.5	TODAS AS OCORRÊNCIAS SANTA CATARINA COM DADOS DE ÁREAS DE RISCO	65
4.6	DISCUSSÃO	72

<b>5</b>	<b>CONCLUSÕES . . . . .</b>	<b>75</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>77</b>
	<b>APÊNDICE A – CÓDIGO DO TRABALHO . . . . .</b>	<b>80</b>
	<b>APÊNDICE B – ARTIGO . . . . .</b>	<b>81</b>

## 1 INTRODUÇÃO

Eventos de emergência tais como acidentes de trânsito, incêndios, alagamentos e deslizamentos, entre outros, podem ser extremamente prejudiciais às vítimas e aos envolvidos, causando lesões, prejuízos financeiros e até mortes. Por exemplo, 3.200 acidentes rodoviários ocorrem em média diariamente no mundo, causando mais de 1,35 milhões de mortes anuais (MUKHOPADHYAY *et al.*, 2020). Além disso, em 2020 o Brasil sofreu com 3.369 incêndios (SANTOS; SANTOS, 2021). Para prevenir, mitigar e responder situações emergenciais, existem forças serviço como as polícias, o corpo de bombeiros e a defesa civil, com capacidades inclusive de segurança e salvamento, que precisam responder imediatamente a eventos emergenciais.

As forças de salvamento são distribuídas de forma estratégica, a fim de minimizar o impacto de eventos emergenciais. Elas são usualmente distribuídas hoje em dia conforme a demanda média de incidentes em uma região e questões geográficas. Entretanto, eventos externos acarretam em variações de demandas das ocorrências, diminuindo a eficiência das instalações.

Como múltiplos eventos emergenciais podem ocorrer simultaneamente, as equipes de salvamento e segurança colocam as chamadas de ocorrências em uma fila. Caso não consigam se realocar para resolver todas as situações, as com menor prioridade são atendidas posteriormente. Logo, minimizar os danos causados por situações emergenciais se torna um grande desafio, devido ao número limitado de agentes e ao tempo necessário para responder às ocorrências e realizar as operações (MUKHOPADHYAY *et al.*, 2020).

Com base em aglomerados de dados relacionados, é possível descobrir diversos padrões e com eles simular situações futuras. Tanto os padrões obtidos quanto a simulação são obtidos utilizando aprendizado de máquina, por meio de algoritmos e técnicas criadas previamente. Tendo em vista a dificuldade que as forças de segurança e salvamento possuem, os impactos podem ser minimizados utilizando técnicas de aprendizado de máquina para prever eventos futuros e assim melhor se preparar para lidar com eles.

Diversas técnicas podem ser aplicadas para auxiliar na predição de eventos de emergência. Dentre elas, soluções baseadas em aprendizado de máquina estão ficando cada vez mais populares, solucionando problemas em diversas áreas, desde educacional a financeiro (RAMASWAMI; BHASKARAN, 2010). Algumas destas técnicas, como *Auto Regressive Integrated Moving Average* (ARIMA) e *Long Short Term Memory* (LSTM) (CORTEZ *et al.*, 2018), são baseadas em dados históricos para antecipar situações futuras, outras utilizam dados tabulares e não modelam diretamente a relação temporal nos dados, como Árvore de Decisão e Redes Neurais (HYNDMAN; ATHANASOPOULOS, 2018).

Este trabalho propõe treinar e avaliar métodos de predição de eventos com dados históricos sobre emergências das forças de salvamento do estado de Santa Catarina, visando prever a quantidade de ocorrências futuras de maneira próxima à realidade.

Serão utilizadas as técnicas de previsão de séries temporais *ARIMA*, *RNN* e *LSTM*. Além disso, os modelos também terão seus resultados comparados. Outros dados também serão considerados na construção dos modelos preditivos, tais como séries históricas de dados meteorológicos e dados geográficos relacionados com áreas de risco. Portanto, o problema tratado é prever quantidade de eventos emergenciais futuros a partir de dados históricos e outros dados adicionais, onde o trabalho possa ser incluso no estado da arte, demonstrando o benefício de utilizar técnicas de aprendizado de máquina para predição de eventos, podendo exibir informações que possuem o potencial de auxiliar em uma tomada de decisão futura.

## 1.1 OBJETIVOS

O objetivo geral deste trabalho é determinar se modelos de predição de séries temporais baseados em *LSTM*, *RNN* e *ARIMA* podem ser eficazes na predição de eventos de emergência e competitivos com outras abordagens do estado da arte. Os seguintes objetivos específicos devem contribuir para alcançar tal objetivo geral:

1. Revisar literatura sobre modelos de aprendizado de máquina para previsão de eventos emergenciais.
2. Coletar dados de diferentes fontes para enriquecer análises e modelos e modelos preditivos.
3. Aplicar métodos estatísticos para analisar conteúdos das bases de dados a serem usadas no treinamento e avaliação dos modelos.
4. Treinar modelos para preditivos *ARIMA*, *RNN* e *LSTM*.
5. Comparar desempenho dos modelos, verificando suas eficácias para os recortes de dados utilizados.

## 1.2 JUSTIFICATIVA

Em diversos momentos diariamente, ocorrem eventos emergenciais, e velocidade de resposta pode ser o parâmetro que afeta a gravidade dos mesmos. Então o preparo para esses eventos é uma tarefa fundamental, e a utilização de técnicas de aprendizado de máquina e séries temporais pode ser útil neste campo. Apesar de pesquisas realizadas sobre métodos de predição, muitos desafios ainda persistem, principalmente quando parâmetros espaço-temporais são utilizados. Vários métodos têm sido utilizados para melhorar as predições, variando de técnicas estatísticas à aprendizagem de máquina.

Como há diferentes métodos usados para contornar os problemas acima, existe uma quantidade de técnicas distintas dependendo da aplicação. Isso gera diferentes resultados

conforme os tipos dados utilizados. Com essa variação, é necessária uma análise adequada para descobrir a técnica com maior compatibilidade perante aos dados.

Este trabalho parte da literatura referente a predição de eventos e análise dos resultados, com o intuito de agregar aos estudos literários, tendo foco em obtenção de bons resultados perante a taxa de incidentes em uma região analisada, diante de um período. A partir da análise de resultados, o trabalho visa apontar um método mais adequado referente aos dados utilizados.

### 1.3 METODOLOGIA

Este trabalho foi dividido e realizado, baseado fracamente na metodologia *Crisp-DM*, na qual usualmente é utilizada com a finalidade de realizar processos de *Data Mining*, logo foi adaptado para o contexto do trabalho. Foi escolhida, devido a divisão de fases iterativas que possui, logo facilita as análises referentes aos objetivos deste presente trabalho. O *dataset* utilizado para os experimentos, foi obtido a partir do banco de dados das Forças de Salvamento e Segurança de Santa Catarina. O ambiente de programação para realização da pesquisa foi o *Google Colaboratory*, na qual a ferramenta disponibiliza o acesso a um *Jupyter Notebook*, para programação em *Python*. Para o tratamento e visualização dos dados, foram utilizadas as bibliotecas *Pandas*, *Shapefile*, *Matplot*, *Shapely*, *Contextily*, *Sklearn*, *Keras* e *Numpy*.

### 1.4 ESTRUTURA DO TRABALHO

O restante deste trabalho está organizado da seguinte maneira. O capítulo 2 apresenta os fundamentos teóricos necessários, incluindo conceitos relevantes e uma análise de trabalhos relacionados, com o objetivo de situar a proposta no contexto do estado da arte. O capítulo 3 discute aspectos relacionados ao desenvolvimento do trabalho, detalhando o material utilizado, os métodos aplicados e a forma como os dados foram obtidos e estruturados. O capítulo 4 descreve a realização dos experimentos, destacando a implementação da solução proposta e os resultados obtidos, analisando sua eficácia em relação aos objetivos traçados. O capítulo 5 apresenta as conclusões finais, sintetizando as descobertas obtidas ao longo do trabalho, além de sugerir direções futuras.

## 2 FUNDAMENTOS

Este capítulo apresenta fundamentos sobre séries temporais, *ARIMA*, redes neurais recorrentes (RNN) e *LSTM*, respectivamente nas seções 2.1 a 2.3.1. Finalmente, na seção 2.5.1 relata a revisão bibliográfica realizada, apresenta seus resultados e compara a proposta deste TCC com trabalhos relacionados.

### 2.1 SÉRIES TEMPORAIS

Séries temporais, são coleções de observações feitas de maneira sequencial em determinado período. Sua ordem é importante, devido a dependência de observações vizinhas para análise e modelagem. Ela pode ser observada em diversos contextos, tais como lucro anual de empresas, resultados de vendas, ou variações de ações na bolsa de valores (HYNDMAN; ATHANASOPOULOS, 2018). O principal objetivo da utilização de series temporais é a previsão de eventos, estimando o comportamento futuro, baseado em seus dados e dependências seriais. Logo, com dados seriais, é possível inferir observações futuras independente da área de atuação, auxiliando na tomada de decisão.

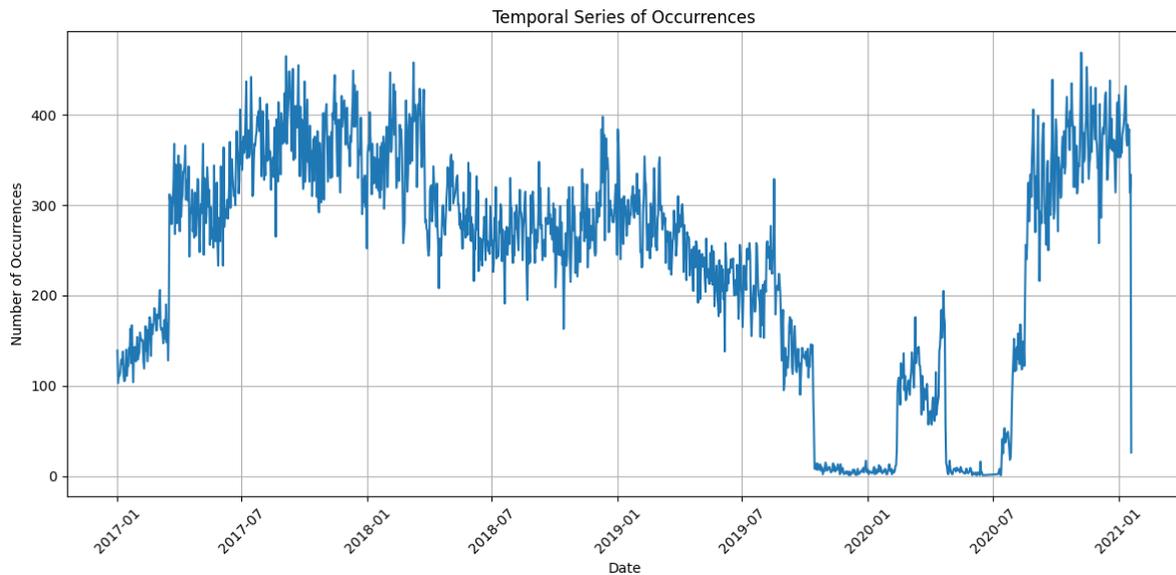
No campo matemático, ela é explicada como um conjunto serial de medidas em unidades de observação indexadas em uma ordem de tempo. Usualmente, é uma sequência obtida a partir de espaços de mesmo tamanho, sendo eles sucessivos. A análise de séries é composta por métodos para análise de dados, a fim de extrair características estatísticas e outros tipos de dados. A equação 1 representa uma série temporal  $Y$  com  $n$  medidas  $\langle y_t, ts_t \rangle$ , onde  $y_i$  é uma amostra ou valor da variável  $y$  em um instante de tempo (timestamp)  $ts_t$  ( $1 \leq t \leq n$ ).

$$Y = \{\langle y_1, ts_1 \rangle, \langle y_2, ts_2 \rangle \dots \langle y_n, ts_n \rangle\} \quad (1)$$

Dentro do campo científico, séries temporais são exploradas em processamento de sinais, astronomia, predição de terremotos, e adotada em diversos domínios de ciências aplicadas e engenharias. Observações de séries temporais podem ser realizadas por meio de gráficos com pontos de dados em intervalos sucessivos no tempo, a figura 1 ilustra um gráfico de uma série temporal referente a quantidade de ocorrências cadastradas nas Forças de Segurança e Salvamento de Santa Catarina variando diariamente.

Analisando a figura 1, é perceptível a variância de ocorrências ao longo do tempo, em alguns períodos ocorrem variações de grande escala, sendo difícil a percepção de sazonalidade presente nos dados sem auxílio de algoritmos externos.

Figura 1 – Exemplo de série temporal: Número de ocorrências variando no tempo



Fonte: Produzida pelo Autor

## 2.2 ARIMA

*ARIMA*, também conhecido como *Autoregressive integrated moving average*, é um dos modelos de predição mais utilizados quanto a séries temporais, sendo utilizado com a finalidade de descrever dados auto-relacionados. Modelos *ARIMA* muitas vezes são referidos como *ARIMA*  $(p, d, q)$ , onde  $p$  é a ordem do modelo auto-regressivo,  $d$  é o grau de diferenciação e  $q$  é a ordem da média móvel.

O modelo é baseado no modelo *ARMA*  $(p, q)$ , que é essencialmente um filtro para respostas de infinitos impulsos, na qual é aplicado um ruído branco além de uma interpretação para obter informações. Logo, o modelo *ARIMA* utiliza um grau de diferenciação, de tal forma que a última diferenciação é estacionária.

Em um modelo auto regressivo, a variável de interesse é prevista usando uma combinação linear de antigos valores da variável. O modelo *ARIMA* pode ser representado pela equação 2

$$y_t = c + \Phi_1 y_{t-1} + \Phi_2 y_{t-2} + \dots + \Phi_p y_{t-p} + \epsilon_t \quad (2)$$

Onde  $\epsilon_t$  é o ruído branco. Então o modelo funciona com diferentes valores temporais de  $(y_t)$ .

O grau de diferenciação se refere a diferentes observação consecutivas no mesmo modelo, ou seja, essa diferença na observação é realizado  $d-1$  vezes até que seja estacionaria. A Diferenciação pode ajudar com estabilidade da média de séries temporais diminuindo tendencias temporais e sazonalidade em um modelo *ARIMA* não sazonal.

Um modelo que usa média móvel, ao invés de utilizar valores do passado de uma variável de regressão, usa erros de previsões passados em um modelo similar a regressão. Assim ilustrado na figura a seguir:

$$y_t = c + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} \quad (3)$$

Onde  $\epsilon_t$  é o ruído branco, e os valores de  $\epsilon_t$  não são observados, logo não é um modelo de regressão comum.

O modelo *ARIMA* pode ser separado em sazonal e não sazonal, onde sazonal é o modelo explicado até o momento *ARIMA*  $(p, d, q)$ , e o modelo sazonal tem observações por ano sendo escrito como *ARIMA*  $(P, D, Q) m$ , onde  $m$  são as observações anuais. O modelo sazonal funciona de forma similar ao não sazonal, porém envolve observações pontuais, totalizando  $m$ . (HYNDMAN; ATHANASOPOULOS, 2018)

## 2.3 REDES NEURAIAS RECORRENTES

As redes neurais recorrentes (RNNs), são redes que trabalham com relações para permitir a persistência dos dados (GHOJOGH; GHODSI, 2023). Elas reconhecem padrões em variados tipos de dados, como em textos ou séries numéricas, provenientes das mais diversas fontes e considerando tempo e sequência. As redes neurais recorrentes, consideram como entrada, além do valor atual, valores anteriores, ou seja, a decisão na etapa de tempo  $t-1$ , afetará a decisão futura na etapa de tempo  $t$ . Dessa forma, as redes recorrentes trabalham com dois momentos, utilizando o momento atual e o passado como fontes, nos quais são combinados para determinar como responder a novos dados, ela possui *loop feedback*, no qual insere as saídas como entrada a cada instante. As redes neurais são métodos baseados em modelos matemáticos do cérebro, e por ser recorrente, ela pode ser comparada com a memória do mesmo, por utilizar os dados do passado. As RNNs, possuem matrizes de peso, que determinam a importância de cada nova entrada, e dos valores do passado (HYNDMAN; ATHANASOPOULOS, 2018).

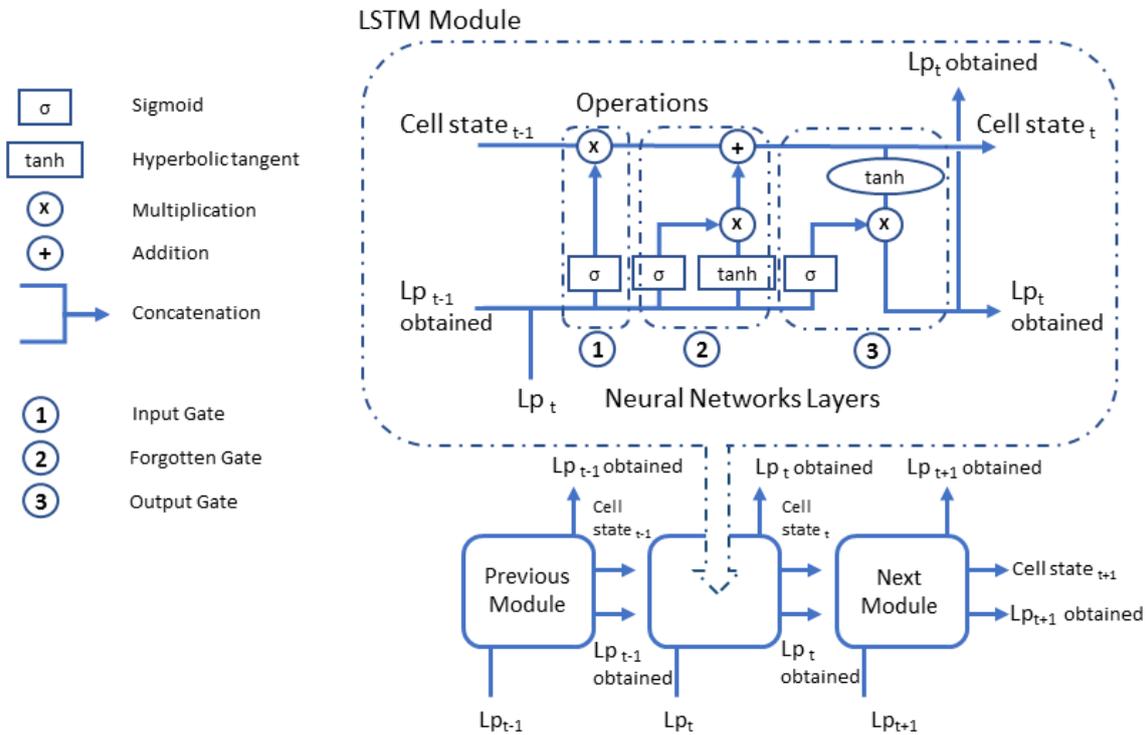
### 2.3.1 Redes LSTM

*LSTM* (do inglês *Long Short Term Memory*) é uma arquitetura de redes neurais recorrentes (*RNN*), na qual possui uma simulação de memória, "lembrando" valores em intervalos arbitrários. *LSTM* se adequa a séries temporais com durações desconhecidas, tendo a vantagem de possuir uma insensibilidade ao tamanho do gap, ou seja, ela possui uma memória muito mais longa.

Sua estrutura é separada em cadeias, contendo quatro redes neurais e múltiplos blocos de memória chamados células, as informações são retidas pelas células e as manipulações de memória são realizadas por *gates*. Dentro do módulo *LSTM* existem diversos blocos de operações atreladas em um *gate*. O bloco da função sigmoide, na qual sua saída varia entre

0 e 1, descreve o quanto um componente será liberado ou esquecido. O bloco da função tangente hiperbólica, tem sua saída variando de -1 a 1, definindo se a saída será negativa ou positiva, com a finalidade de filtra informações. A figura 2 ilustra sua estrutura.

Figura 2 – Estrutura de uma rede LSTM



Fonte: (NAVARRO *et al.*, 2020)

Os *gates* podem ser separados em três tipos, o *Forgot Gate*, o qual remove as informações em que não são consideradas úteis na célula, o *Input Gate*, que adiciona informações úteis ao estado da célula, e o *Output Gate*, no qual extrai informações úteis do estado da célula atual para ser utilizado como saída.

A célula recebe duas entradas, a saída do ultimo estado e a observação no tempo  $t$ . As informações para memória de longo prazo ficam na saída do ultimo estado. (HYNDMAN; ATHANASOPOULOS, 2018)

## 2.4 MEDIDAS DE DESEMPENHO DE PREDITORES

### 2.4.1 Mean Squared Error

O *Mean Squared Error (MSE)*, ou Erro Quadrático Médio, é uma das métricas mais utilizadas para avaliar a precisão de modelos preditivos, especialmente em problemas de regressão. Ele é amplamente aplicado em aprendizado de máquina e estatística para

medir o desempenho de modelos ao prever valores numéricos contínuos.(GADU *et al.*, 2023)

O *MSE* calcula a média dos quadrados das diferenças entre os valores observados e os valores preditos, penalizando de forma significativa erros maiores. Ele é definido matematicamente pela equação:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

Na equação acima,  $n$  é o número total de observações,  $y_i$  representa os valores reais (observados),  $\hat{y}_i$  são os valores previstos pelo modelo, e  $(y_i - \hat{y}_i)^2$  é o quadrado do erro de previsão para cada observação  $i$ .

O *MSE* fornece um valor positivo, pois os erros são elevados ao quadrado, eliminando os sinais negativos e amplificando os desvios mais significativos.

### Interpretação do MSE

O valor do *MSE* reflete o nível de erro do modelo:

Quanto menor o *MSE*, melhor é o desempenho do modelo, indicando que as previsões estão mais próximas dos valores reais. Valores elevados de *MSE* sugerem que o modelo possui erros substanciais, podendo indicar necessidade de ajuste ou melhorias no modelo.

Por ser baseado no quadrado dos erros, o *MSE* é especialmente sensível a *outliers* (valores atípicos). Um único erro muito grande pode aumentar significativamente o valor do *MSE*, tornando-o menos robusto em casos de dados com grande variabilidade.

#### 2.4.2 Root Mean Squared Error

O *Root Mean Squared Error (RMSE)*, ou Erro Quadrático Médio da Raiz, é uma métrica derivada do *Mean Squared Error (MSE)* e amplamente utilizada para avaliar a precisão de modelos preditivos em problemas de regressão. Assim como o *MSE*, o *RMSE* mede a diferença entre os valores observados e os valores previstos, mas possui uma vantagem significativa: ele retorna os erros na mesma unidade da variável de interesse, facilitando a interpretação.(GADU *et al.*, 2023)

O *RMSE* é calculado como a raiz quadrada do *MSE* e pode ser expresso pela equação:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

Na equação acima,  $n$  representa o número total de observações,  $y_i$  são os valores reais (observados),  $\hat{y}_i$  são os valores previstos pelo modelo, e  $(y_i - \hat{y}_i)^2$  é o quadrado do

erro de previsão para cada observação  $i$ . A raiz quadrada do valor médio obtido fornece uma medida mais próxima da escala original dos dados, facilitando a interpretação do erro de previsão.

### Interpretação do RMSE

O *RMSE* reflete o nível médio de erro do modelo. Quanto menor o RMSE, melhor o desempenho do modelo, indicando que as previsões estão mais próximas dos valores observados. Valores elevados de RMSE sugerem que o modelo não está capturando bem os padrões dos dados, podendo indicar necessidade de ajustes no pré-processamento ou no próprio modelo.

Por ser expresso na mesma unidade da variável de interesse, o RMSE facilita a análise prática dos erros. Isso

#### 2.4.3 Mean Absolute Error

O *Mean Absolute Error (MAE)*, ou Erro Absoluto Médio, é uma métrica amplamente utilizada para avaliar o desempenho de modelos preditivos em problemas de regressão. Ele mede a média das diferenças absolutas entre os valores reais e os valores previstos pelo modelo, fornecendo uma indicação clara do nível médio de erro de previsão, sem penalizar erros maiores de forma mais intensa, como ocorre no *MSE* e no *RMSE*. (GADU *et al.*, 2023)

Matematicamente, o *MAE* é definido pela seguinte equação:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

Na equação acima,  $n$  é o número total de observações,  $y_i$  representa os valores reais (observados),  $\hat{y}_i$  são os valores previstos pelo modelo, e  $|y_i - \hat{y}_i|$  é o valor absoluto do erro de previsão para cada observação  $i$ . O MAE fornece uma medida direta da média dos erros entre os valores previstos e os valores reais, sendo sempre positivo.

### Interpretação do MAE

Ele é intuitivo e fácil de interpretar, representando diretamente o erro médio em unidades da variável analisada. Por não elevar os erros ao quadrado, o *MAE* não amplifica *outliers*, tornando-o menos sensível a valores atípicos em comparação ao *MSE* e *RMSE*.

Um valor menor de *MAE* indica que o modelo está fazendo previsões mais precisas, enquanto um valor maior sugere a necessidade de ajustes no modelo ou na preparação dos dados.

#### 2.4.4 Mean Absolute Percentage Error

O *Mean Absolute Percentage Error (MAPE)*, ou Erro Percentual Absoluto Médio, é uma métrica comum para avaliar a precisão de modelos de previsão, particularmente em problemas de regressão. Ele mede a média dos erros absolutos como uma porcentagem dos valores reais, fornecendo uma avaliação relativa do desempenho do modelo, independentemente da escala dos dados. (GADU *et al.*, 2023)

Matematicamente, o *MAPE* é definido pela seguinte equação:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (7)$$

Na equação acima,  $n$  é o número total de observações,  $y_i$  representa os valores reais (observados),  $\hat{y}_i$  são os valores previstos pelo modelo, e  $\left| \frac{y_i - \hat{y}_i}{y_i} \right|$  é o erro percentual absoluto para cada observação  $i$ . O *MAPE* expressa os erros médios em termos percentuais, sendo ideal para dados onde valores de zero não estão presentes.

#### Interpretação do MAPE

Ele é facilmente interpretável, pois representa o erro médio em termos percentuais em relação aos valores reais. Por ser expresso em porcentagem, o *MAPE* é escalável e permite comparações entre diferentes conjuntos de dados ou modelos.

Um *MAPE* menor indica previsões mais precisas, enquanto valores elevados sugerem maior discrepância entre os valores previstos e os reais. No entanto, o *MAPE* pode ser sensível a valores de  $y_i$  próximos de zero, o que pode gerar resultados desproporcionais e distorcer a avaliação do modelo.

## 2.5 ESTADO DA ARTE

### 2.5.1 Pesquisa Bibliográfica

A pesquisa bibliográfica foi realizada com o objetivo de entender o estado da arte em predição de eventos emergenciais, além de situar e justificar a proposta deste TCC frente a trabalhos relacionados. Ela visa responder às seguintes perguntas.

1. Qual o estado da arte referente a predição de eventos emergências?
2. Quais métodos de predição são efetivos para previsão de eventos relacionados a dados geográficos?
3. Como dados adicionais afetam a predição de eventos?

Duas bases de dados foram selecionadas para realizar tal pesquisa bibliográfica: *Google Scholar* e *ResearchGate*. Essas bases de dados foram escolhidas por apresentar

ótimos resultados preliminares para busca de pesquisas referente a artigos e livros. Após escolhidas as bases, a busca dos artigos deu início com a combinação de todos os termos escolhidos utilizando conectores *AND* e *OR*. Causando um resultado de 17.600 artigos. *String* de busca inicial (*Prediction OR Forecasting*) *AND* (*Emerngecy Event*) *AND* *Data Mining* *AND* (*Neural Network*) *AND* (*Artificial Inteligence*).

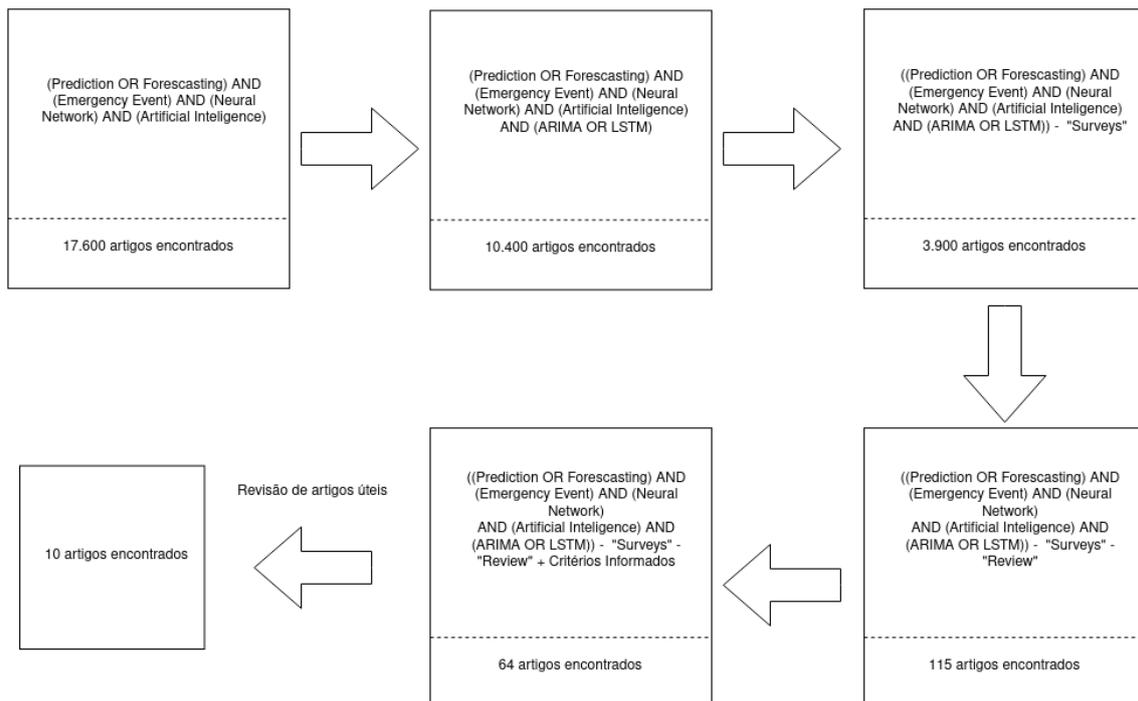
Além disso a busca dos artigos foi delimitada para os seguintes critérios, (i)publicações em inglês ou português, (ii)publicações de 2015 até 2023, (iii)publicações de fontes confiáveis e bem estabelecidas na comunidade de pesquisa, (iv) publicações com conteúdo referente a métodos de aprendizagem de máquina baseados em dados históricos, (v)Publicações com conteúdo referente ao funcionamento do sistema das forças de Segurança e Salvamento Brasileiro, (vi) publicações com conteúdo referente a *Data Mining*.

### Triagem dos Trabalhos

Para reduzir a quantidade de artigos, foi adicionado os termos *ARIMA* e *LSTM* adicionados na busca com o conector *AND*, e o conector *OR* entre eles, com a finalidade de redução da busca, procurando métodos nos quais serão trabalhados no trabalho, acarretando em 10.400 artigos. Retirando da busca os artigos que eram *surveys* da pesquisa, utilizando esse termo como palavra de exclusão, foi reduzido para 3.970 artigos resultantes. Retirando os artigos de *review* foram encontrados 115 artigos resultantes. Então a *string* final ficou como: (*Prediction OR Forecasting*) *AND* (*Emerngecy Event*) *AND* *Data Mining* *AND* (*Neural Network*) *AND* (*Artificial Inteligence*) *AND* (*ARIMA OR LSTM*) - '*SURVEYS*' - '*REVIEW*'.

A partir dos resultados obtidos, foram realizadas análises referente aos títulos das obras, verificando as que se enquadram no tema apresentado neste presente trabalho. Após essa filtragem, os *abstracts* foram analisados para que ocorra a redução de artigos, e os que se tornaram adequados foram utilizados como referência. A figura 3 sintetiza o processo completo de revisão bibliográfica realizado.

Figura 3 – Processo de pesquisa bibliográfica realizado



Fonte: Produzida pelo Autou

Após a triagem, foram selecionados 10 artigos relacionados relevantes. Entretanto outros artigos foram obtidos por meio de indicações. Dentre todos os artigos selecionados, 5 são discutidos a seguir, por serem considerado mais próximos aos objetivos deste TCC.

## 2.5.2 Trabalhos Selecionados

Esta seção apresenta resumos de principais trabalhos pesquisados, destacando seus objetivos, métodos utilizados e resultados obtidos. Logo, tem como objetivo, fazer um quadro comparativo referente aos trabalhos relacionados, com a proposta deste presente estudo. Foram escolhidos 4 trabalhos relacionados para serem apresentados nessa seção, eles foram escolhidos por apresentarem diversas similaridades com o presente trabalho.

### A Deep Learning based Emergency Resolution Time Prediction System

Previsões precisas do tempo de eventos emergenciais, são cruciais para segurança pública e funcionamento corriqueiro das cidades, pois ajuda a lidar com incidentes em tempo hábil, devido ao acesso de recursos preparados previamente. Este trabalho apresenta o *DeepER*, um modelo de previsão, no qual utiliza *deep learning*, para prever o futuro

baseado em acontecimentos passados (BEJARANO *et al.*, 2020). O *DeepER* é baseado em uma arquitetura *RNN*, e utiliza células básicas presente no modelo *LSTM*.

O desempenho do *DeepER* foi comparado com outros métodos de predição, como *ARIMA* e regressão linear, no qual apresentou resultados melhores de desempenho pelas métricas de avaliação *Mean Square Error* e *Mean Absolute Error*. Entretanto não obteve bons resultados em relação a picos de eventos, sendo inferior a regressão linear para os dados avaliados.

### **Real-time forecasts and risk assessment of novel coronavirus (COVID-19) cases: A data-driven analysis**

O COVID-19 se tornou uma emergência internacional referente a saúde pública, afetando centenas de países. Como séries temporais de COVID-19 apresentam tanto padrões não lineares, quanto não estacionários, utilizar métodos de predição seria útil. Com essas ocorrências, um dos objetivos deste artigo é gerar previsões de curto período para futuros casos de COVID-19 em múltiplos países (CHAKRABORTY; GHOSH, 2020). O método escolhido para realizar predições foi um modelo de séries temporais híbrido, no qual combina o modelo *ARIMA* com um modelo baseado em onduleta, com o intuito de superar as desvantagens específicas de cada modelo. O modelo *ARIMA* é usado predominantemente para predições de séries temporais lineares, mas em estudos recentes, o uso de modelos baseados em onduleta mostraram ótimos resultados. Para obtenção de resultados, foram analisados principalmente os países Canadá, França, Índia, Coreia do Sul, e Reino Unido. Os resultados obtidos utilizando esse modelo híbrido, obteve resultados melhores que os modelos utilizados de forma separada.

Assim como o objetivo de gerar predição em curto período, o artigo propõe uma avaliação de risco referente a diversos países, observando suas taxas de fatalidade. Para avaliação de riscos outro método foi utilizado, árvore de regressão. No qual, apresenta bons resultados e é fácil de analisar. E por meio dela foi concluído que o número total de casos, assim como a distribuição etária, e o período de quarentena tem grandes impactos no índice de risco referente aos seus países.

### **A COVID-19 Pandemic Artificial Intelligence–Based System With Deep Learning Forecasting and Automatic Statistical Data Acquisition: Development and Implementation Study**

Devido a doença COVID-19, foram causadas mais de 1.7 milhões de mortes, logo o controle desta pandemia tornou-se crucial ao redor do mundo. Entretanto, estudos que investigam seus padrões em conjunto com as políticas públicas de cada país são limitadas. Então, este trabalho visa desenvolver um sistema de inteligência artificial para analisar

os padrões dinâmicos do COVID-19, facilitando previsões e produzir de forma gráfica, a visualização das medidas adotadas em 171 países distintos (C. *et al.*, 2021).

Foram empregados diversos métodos de previsões, fazendo um comparativo entre eles, analisando seus resultados, com o intuito de apresentar os melhores. Os métodos utilizados foram *ARIMA*, Rede Neural Feedforward, percepção multilayer, e *LSTM*. Os resultados obtidos para os métodos *ARIMA*, FNF e percepção multilayer não foram estáveis, pois tiveram bons resultados em poucos países. O método *LSTM*, demonstrou ótimos resultados, tendo uma performance acima dos outros métodos apresentados.

### **Predicting the Unpredictable: Comparing Statistical Forecasting and Deep Learning Models for Forecasting Emergency Department Arrivals**

Hospitais cheios são um problema enfrentado atualmente, onde diversos hospitais não conseguem atender seus pacientes, devido a picos de demanda. Logo, se essas demandas forem previstas, o preparo para tais momentos acarretaria em demandas sendo compridas mais facilmente. Nessa tese, diversos modelos de previsão foram avaliados, com o intuito de prever chegadas em quadros emergenciais (ZELENETZ; JACOB, 2020). Os métodos utilizados foram Redes Neurais Recorrentes e *LSTM*, então foi realizado um comparativo com *ARIMA*, pois cada um tem suas vantagens e desvantagens em relação a complexidade e flexibilidade.

Observando os resultados, é observado que ao utilizar o *dataset* hospitalar, os modelos não apresentam bons resultados referentes a picos de demanda. Em relação a médias de incidentes diários, todos apresentaram bons resultados, porém foram avaliados a cada hora, acarretando em dificuldades para seu desempenho. O autor retrata que os métodos teriam um maior desempenho, caso fossem utilizadas métricas de tempo mais distantes.

O desempenho obtido por *ARIMA*, *LSTM* e *RNN*, foram similares, entretanto o melhor desempenho foi o método *LSTM*, quando o escopo observado tinha um período maior, o desempenho do método *RNN* foi maior em períodos pequenos de tempo. Entretanto, quando observado a complexidade do método, e menor esforço computacional, o método *ARIMA* foi listado como o melhor.

### **Antecipação de Emergências Utilizando Técnicas Baseadas em Séries Temporais e Aprendizado de Máquina**

Com o decorrer dos anos ocorre um aumento significativo da população nas grandes cidades e regiões metropolitanas, o que tem levado a um aumento proporcional de eventos de emergência. Esse cenário representa um desafio para as equipes de socorro, que precisam lidar com essas emergências de forma eficiente e rápida. O trabalho propõe um método

para antecipar eventos de emergência usando dados das forças de segurança e salvamento, através de técnicas de aprendizado de máquina.

Modelos de regressão como Regressão Linear, *K-Nearest Neighbors* e *Random Forests* foram treinados e avaliados usando métricas de desempenho como R<sup>2</sup> e Mean Squared Error. Os resultados indicam que os modelos de Regressão Linear e *Random Forests* tiveram melhor desempenho, tendo cerca de 37% da variância dos dados (BOHM, 2022).

### 2.5.3 Análise comparativa

Os artigos descritos apresentam uma amostra de pesquisas e estudos realizados na área de predição de eventos, com diversas técnicas e algoritmos de aprendizado de máquina e séries temporais. O estudo desses artigos trouxe um embasamento teórico e entendimento mais apropriado das soluções propostas e oportunidades de melhora para o presente trabalho. Pelos métodos utilizados, e seus resultados, pode ser notado um grande potencial nos métodos explorados neste trabalho. A tabela 1 apresenta um resumo comparativo de alguns artigos.

Assim como esses trabalhos a variável predita será baseada em quantidade de incidentes, porém utilizando os dados das Forças de Segurança e Salvamento. Uma das diferenças entre os trabalhos analisados e o presente trabalho, é o enriquecimento dos dados utilizando *datasets* complementares, como por exemplo os dados do *INMET*, no qual apresenta dados climáticos. Além disso, este trabalho apresenta predição de quantidades de incidentes observando o espaço-tempo, pois ambas métricas tem importância para esse tipo de predição.

Artigo	Predição	Entradas	Técnicas	Desempenho
(BEJARANO <i>et al.</i> , 2020)	Quantidade de Incidentes de emergência	Incidentes de casos emergenciais referente a "NYC Open Data" providos pelo escritório gerencial de emergência	DeepER, ARIMA e Regressão Linear	Por suas métricas de desempenho, DeepER foi o melhor resultado, porém para picos de ocorrência, Regressão Linear foi vantajosa
(CHAKRABORTY; GHOSH, 2020)	Quantidade de Casos de COVID-19 em diversos países	Ocorrências de COVID-19 presentes em séries temporais de diversos países atualizando os dados em tempo real	ARIMA, WBF e ARIMA-WBF	Em todos os testes realizados, ARIMA-WBF teve um melhor desempenho
(C. <i>et al.</i> , 2021)	Quantidade de Incidentes de COVID-19	Quantidade de incidentes de COVID-19 obtidos a partir do "Oxford COVID-19 Government Response Tracker" e do "COVID-19 Data Repository" da universidade "Johns Hopkins".	ARIMA, FNN, MLP e LSTM	LSTM apresentou melhor desempenho na maioria dos países, porém ARIMA e FNN tiveram resultados melhores na Coreia do Sul
(ZELENETZ; JACOB, 2020)	Quantidade de incidentes hospitalares	Séries temporais de casos de emergência hospitalares em um período de 48 meses	ARIMA, LSTM e RNN	RNN apresentou o melhor desempenho em períodos curtos de tempo, entretanto conforme o período aumentava, LSTM apresentava melhores resultados
(BOHM, 2022)	Quantidade de Ocorrências emergenciais	Séries temporais de ocorrências dos corpos de bombeiros em um período de 48 meses	Regressão linear, KNN e Random Forest	Random Forest teve o melhor desempenho, entretanto não tiveram bons resultados

Tabela 1 – Tabela Comparativa dos Artigos

### 3 DESENVOLVIMENTO DO TRABALHO

Este capítulo apresenta os aspectos relacionados ao desenvolvimento do trabalho. Na Seção 3.1, é detalhada a proposta do trabalho, com a descrição dos objetivos e a abordagem adotada. Em seguida, a Seção 3.2 descreve a metodologia utilizada, apresentando o fluxo de trabalho seguido. As próximas seções seguem a estrutura definida pela metodologia escolhida: a Seção 3.3 trata do entendimento do negócio, abordando a seleção de modelos de predição e das fontes de dados; a Seção 3.4 discute o entendimento e preparação dos dados; a Seção 3.5 apresenta o treinamento dos modelos; e, por fim, a Seção 3.6 detalha a avaliação dos modelos, com as métricas e critérios utilizados.

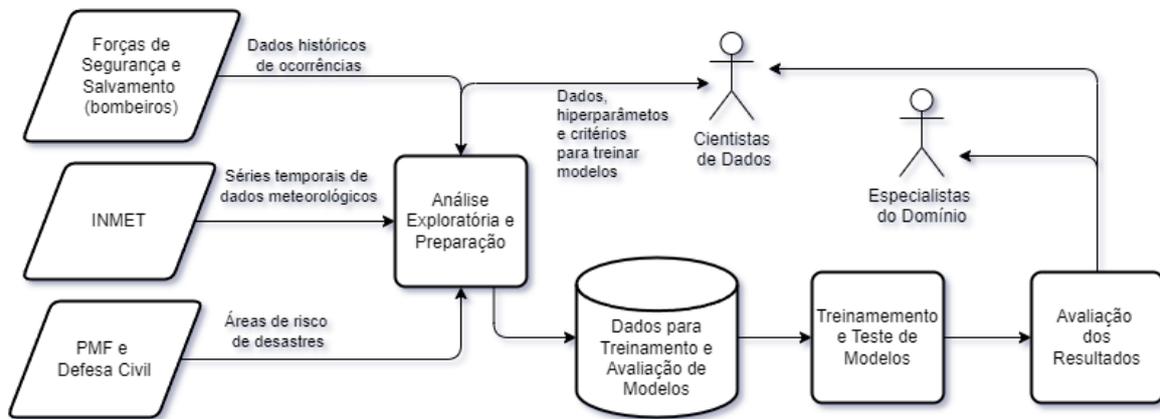
#### 3.1 PROPOSTA

Este trabalho tem como proposta, extrair informações de diferentes fontes, inicialmente criando um *dataframe* a partir de dados históricos de ocorrências das Forças de Segurança e Salvamento. Inicialmente serão utilizados apenas os dados das Forças de Salvamento, e a partir do *dataframe*, serão realizadas diversas análises exploratórias para filtrar os dados desejados. Após a filtração, os dados serão preparados, a fim de os enquadrarem em diferentes métodos de predição. Então serão realizados experimentos aplicando tanto o método *ARIMA* quanto *RNN* e *LSTM*, e após os experimentos, serão realizadas avaliações de resultados. Os resultados de cada modelo serão comparados com o intuito de verificar o modelo que se melhor se adequou ao recorte de dados.

Após avaliação inicial, o *dataframe* criado receberá dados adicionais, compostos por séries temporais de dados meteorológicos obtidos pelo *INMET*. O processo anterior será realizado novamente, com a esperança de melhorar os resultados encontrados, por ter uma quantidade maior de dados pertinentes. E por fim o *dataframe* receberá dados referentes a áreas de risco de desastres, obtidos por meio da *PMF* e Defesa Civil, além de encontrados em domínio público por coletas do Serviço Geológico Brasileiro, onde após aplicação dos métodos, serão comparados entre si.

A finalidade deste trabalho busca estudar e apresentar métodos alternativos para predição de eventos, onde sejam demonstrados os benefícios de utilizar-los, além de descrever de forma sucinta, como o processo de predição ocorre, podendo ser reutilizado em diversos contextos. A figura 4 representa o fluxo geral desenvolvido para esse estudo.

Figura 4 – Fluxo geral de informação.



Fonte: Produzido pelo autor

### 3.2 METODOLOGIA

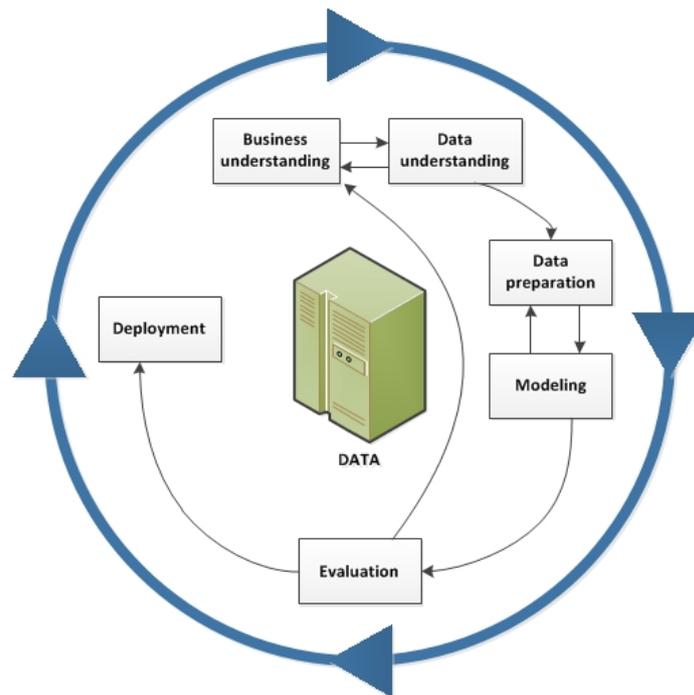
A metodologia empregada para obtenção de dados e tratamento dos mesmos será baseada em *Cross-Industry Standard Process for Data Mining* (CRISP-DM) (SCHRÖER; KRUSE; GÓMEZ, 2021), na qual é uma modelagem de processos para *Data Mining*, porém será adaptada com a finalidade de estruturar a pesquisa e será utilizada em um contexto diferente, logo o trabalho seguirá fracamente o modelo *CRISP-DM*. A Figura 5 apresenta os passos definidos na metodologia *CRISP-DM*.

A metodologia *CRISP-DM* é dividida em seis fases iterativas, sendo elas: *Business Understanding*, *Data understanding*, *Data preparation*, *Modeling*, *Evaluation* e *Deployment*. O ciclo das mesmas não é estrito, ou seja, é possível retornar para uma fase anterior após avançar para a próxima, assim como ilustra a Figura 5. As etapas a seguir foram formadas para desenvolvimento do trabalho sendo adaptadas do modelo *CRISP-DM* original.

### 3.3 ENTENDIMENTO DO NEGÓCIO

A etapa de *Business Understanding* é fundamental para fundamentar o projeto em uma base sólida de conhecimento. Nesta fase, foram realizadas investigações abrangentes em fontes de literatura relevantes, incluindo livros, artigos acadêmicos e materiais online disponíveis em repositórios como *Google Scholar* e *Researchgate*, bem como orientações fornecidas pelo Orientador. A triagem dos artigos foi uma parte crucial desse processo, visando selecionar aqueles que mais contribuiriam para o entendimento dos métodos empregados na pesquisa, além de explorar trabalhos anteriores na literatura para identificar semelhanças e diferenças com o projeto atual. Utilizando termos específicos de pesquisa, como *ARIMA* e *LSTM*, e refinando os critérios de seleção para excluir pesquisas tipo

Figura 5 – A metodologia CRISP-DM



Fonte: (IBM, 2021)

*surveys* e *review*, foi possível reduzir a quantidade de artigos para uma amostra mais relevante e significativa. A análise dos títulos e resumos das obras permitiu uma seleção criteriosa dos artigos mais pertinentes ao tema da pesquisa, garantindo que apenas os mais relevantes fossem utilizados como referência. O processo de pesquisa ilustrado na Figura 3 destaca a importância da metodologia adotada para garantir a qualidade e relevância do material obtido, fornecendo uma base sólida para o desenvolvimento do projeto.

### 3.3.1 Seleção de modelos de predição

Neste estudo, foram selecionados dois modelos de predição distintos para abordar a previsão de ocorrências nas Forças de Segurança e Salvamento: ARIMA (AutoRegressive Integrated Moving Average), LSTM (Long Short-Term Memory) e Simple RNN (Simple Recurring Neural Network). Cada modelo possui características que o tornam adequado para diferentes aspectos dos dados e da tarefa em questão, que envolve a previsão de eventos com base em séries temporais.

#### ARIMA - Modelo Auto-Regressivo Integrado de Médias Móveis

O modelo *ARIMA* foi escolhido por sua simplicidade e eficácia em dados estacionários ou com pequenas transformações para alcançarem a estacionariedade. As principais

vantagens que justificam sua escolha são:

**Simple e Interpretável:** *ARIMA* é um modelo linear, de fácil interpretação, onde a relação entre as variáveis pode ser descrita de maneira clara. Isso é vantajoso, especialmente quando o objetivo é entender como as variáveis passadas influenciam as previsões futuras.

**Efetivo em Séries Estacionárias:** O *ARIMA* se destaca em séries temporais que não apresentam tendências ou sazonalidade, ou que podem ser convertidas para um formato estacionário por meio de diferenciação. Esse tipo de comportamento é comum em muitos conjuntos de dados, especialmente aqueles que refletem padrões de ocorrências passadas.

**Pouca Parametrização:** O modelo *ARIMA* é relativamente simples de ajustar, pois exige apenas a definição de três parâmetros principais —  $p$  (ordem autorregressiva),  $d$  (número de diferenciações para estacionarização) e  $q$  (ordem da média móvel). Isso facilita a busca por uma boa configuração sem a necessidade de muitos ajustes complexos.

Em suma, o *ARIMA* é ideal para séries temporais com comportamentos lineares ou autocorrelacionados, como pode ser o caso de dados históricos das Forças de Salvamento, onde padrões passados podem refletir diretamente em futuros eventos. (HYNDMAN; ATHANASOPOULOS, 2018)

### **LSTM - Redes Neurais Recorrentes para Padrões Não-Lineares**

Por outro lado, o modelo *LSTM* é uma rede neural recorrente que foi projetada para lidar com dependências de longo prazo em dados sequenciais, como é o caso das séries temporais. Diferente dos modelos tradicionais lineares, as redes *LSTM* podem modelar relações complexas e não-lineares. A escolha do *LSTM* para este estudo se deve à sua capacidade de capturar padrões de longa dependência e de aprender estruturas complexas em séries temporais dinâmicas, oferecendo as seguintes vantagens:

**Captura de Padrões Não-Lineares:** O *LSTM* é particularmente eficaz para identificar e aprender padrões não-lineares que modelos tradicionais, como o *ARIMA*, podem não ser capazes de detectar. Isso é útil em contextos onde os dados podem exibir comportamento não-linear, como em eventos imprevisíveis ou variáveis de natureza complexa.

**Versatilidade:** Uma das principais vantagens das redes *LSTM* é sua capacidade de lidar com diferentes tipos de dados. Elas podem ser aplicadas tanto em séries temporais univariadas (como ocorrências de eventos de segurança) quanto multivariadas (como a combinação de dados de ocorrências com dados meteorológicos e informações de áreas de risco). Isso proporciona uma flexibilidade significativa ao modelar conjuntos de dados mais ricos e complexos.

**Dependências de Longo Prazo:** O *LSTM* foi projetado para superar as limitações das redes neurais tradicionais e de outros modelos de séries temporais, que têm dificuldade em capturar dependências de longo prazo. Em situações em que eventos passados distantes têm impacto significativo sobre o comportamento futuro, o *LSTM* se destaca por sua

capacidade de "lembrar" informações a longo prazo.

Essas características tornam o *LSTM* particularmente útil quando se lida com grandes volumes de dados, com relações temporais complexas e não lineares, o que é comum em muitos problemas de previsão de eventos em áreas como segurança e gestão de desastres. (HYNDMAN; ATHANASOPOULOS, 2018)

### RNN Simples - Rede Neural Recorrente Simples

A *RNN Simples* é outro modelo de redes neurais recorrentes que foi considerado para a tarefa de previsão de eventos baseados em séries temporais. Diferente do modelo *ARIMA*, que é puramente linear, e do *LSTM*, que é uma arquitetura avançada para captura de dependências de longo prazo, a *RNN simples* oferece uma abordagem intermediária, com uma estrutura mais básica e comumente usada em problemas de séries temporais. A escolha da *RNN Simples* para este estudo se baseia em várias vantagens, que se destacam principalmente no contexto de dados temporais e sequenciais:

**Captura de Dependências Temporais:** A principal característica das redes neurais recorrentes é a capacidade de lidar com dados sequenciais, ou seja, dados onde a ordem e o tempo são cruciais. As *RNNs* simples conseguem "lembrar" de informações passadas na série temporal para prever o futuro, o que as torna apropriadas para séries temporais com dependências de curto e médio prazo.

**Arquitetura Simples e Leve:** A *RNN* simples é mais fácil de treinar e possui uma estrutura relativamente simples quando comparada ao *LSTM*, que é uma versão mais complexa da rede neural recorrente. Embora a *RNN* simples não seja tão eficaz em capturar dependências de longo prazo como o *LSTM*, ela pode ser eficiente em dados com menos complexidade e onde as dependências temporais podem ser mais curtas. Sua simplicidade também resulta em um menor custo computacional, o que pode ser vantajoso em cenários onde os recursos são limitados.

**Adequada para Dados Temporais de Curto Prazo:** Quando as séries temporais possuem dependências mais imediatas (ou seja, o comportamento presente depende fortemente de poucos períodos passados), a *RNN simples* pode ser eficaz, especialmente em contextos como o de ocorrências de eventos em que a sequência imediata de eventos passados pode ser um bom preditor do futuro próximo. Isso pode ser particularmente útil para dados de segurança e salvamento, onde padrões imediatos de ocorrência de eventos são relevantes para prever eventos em um curto espaço de tempo.

**Flexibilidade para Dados Univariados e Multivariados:** Embora as *RNNs* simples sejam frequentemente usadas com dados univariados, elas também podem ser estendidas para trabalhar com dados multivariados (ou seja, com múltiplas variáveis de entrada), o que as torna adequadas para situações em que diferentes fontes de dados, como variáveis meteorológicas ou informações sobre áreas de risco, precisam ser combinadas para melhorar

as previsões.(HYNDMAN; ATHANASOPOULOS, 2018)

### 3.3.2 Seleção das Fontes de Dados

A fase de *Data Understanding* na arquitetura *CRISP-DM* é crucial, pois estabelece a base sobre a qual o projeto se desenvolve. Nesta fase, os dados brutos são coletados e explorados para obter uma visão clara de sua qualidade, estrutura e relevância para os objetivos do negócio. Através de análises descritivas, visualizações e verificação de qualidade, são identificados padrões, tendências e possíveis problemas, como valores faltantes e inconsistências.(GALLAGHER; BRUTON; O’SULLIVAN, 2016)

Essa etapa propõe a coleta de dados, os explorando e descrevendo, considerando sua qualidade. Os dados foram obtidos de diferentes fontes, e sua informação foi cruzada por meio da data e hora presente em *datasets* distintos. O *dataset* utilizado para retratar os eventos emergenciais foi obtido pelo aluno Felipe Siqueira, que realizou um trabalho de doutorado com um tema similar e na época trabalhava no Corpo de Bombeiros de Santa Catarina, tendo acesso aos dados com facilidade. O *dataset* contém diversos dados referentes as ocorrências cadastradas em Santa Catarina, desde 2017 à 2021, seus dados brutos estão distribuídos em 22 colunas, desde horário a coordenada de ocorrência. O *dataset* está armazenado em um arquivo .CSV(Formato Excel), além disso o foi copiado para o drive, onde sua manipulação foi facilitada. A extração foi realizada utilizando a biblioteca *Pandas*, na qual é uma biblioteca *open source*, que permite a manipulação rápida e eficiente de *Dataframes*.

A tabela 2 representa as informações presentes no *dataset* das Forças de Segurança e Salvamento seguindo o formato de um dicionário de dados do *dataset*.

Cada ocorrência no *dataset* das Forças de Segurança e Salvamento é classificada de acordo com um tipo e um subtipo, proporcionando um detalhamento granular das situações atendidas pelos bombeiros durante esse período. A análise desses dados pode oferecer uma compreensão abrangente sobre a natureza das emergências atendidas, permitindo uma visão holística sobre a atuação dos bombeiros e a dinâmica das emergências no estado de Santa Catarina.

No *dataset* principal, as ocorrências são classificadas em diversos tipos, onde cada um deles possui subtipos distintos mapeados. Por conta disso, podem ter causas distintas, então foram realizadas análises, com o intuito de descobrir quais tipos e subtipos seriam adequados a este trabalho. A tabela de tipos e subtipos é representada pela tabela 3 abaixo:

Tabela 3 – Tipos e Subtipos de Ocorrências

Tipo	Subtipo
	EMERGÊNCIA PSIQUIÁTRICA
	DESMAIO/SÍNCOPE
	QUEDA

Tabela 3 – Tipos e Subtipos de Ocorrências (continuação)

<b>Tipo</b>	<b>Subtipo</b>
	CONVULSÃO EMERGÊNCIA CARDÍACA ATROPELAMENTO EMERGÊNCIA OBSTÉTRICA EMERGÊNCIA RESPIRATÓRIA VÍTIMA DE AGRESSÃO DE ARMA BRANCA VÍTIMA DE AGRESSÃO FÍSICA INTOXICAÇÃO EXÓGENA QUEIMADURA ELÉTRICA VÍTIMA DE AGRESSÃO DE ARMA DE FOGO ATAQUE DE ANIMAL COM PEÇONHA QUEIMADURA TÉRMICA ATAQUE DE ANIMAL SEM PEÇONHA ATAQUE DE INSETO QUEIMADURA QUÍMICA VÍTIMA DE AGRESSÃO SEXUAL ATAQUE DE ANIMAL AQUÁTICO
INCÊNDIO	EDIFICAÇÃO VEGETAÇÃO LIXO MEIO DE TRANSPORTE TRANSFORMADOR TERRENO BALDIO TURFA INSTALAÇÕES COM CALDEIRAS REJEITOS INDUSTRIAIS CASA DE MAQUINAS AERONAVE EMBARCAÇÃO LIXO HOSPITALAR
SALVAMENTO / BUSCA / RESGATE	COLISÃO/CHOQUE AFOGAMENTO EXPLOSÃO OBJETO EM LOCAL DE RISCO CAPOTAMENTO DESABAMENTO SUICÍDIO/TENTATIVA SOTERRAMENTO ENCHENTE/INUNDAÇÃO DESLIZAMENTO ALAGAMENTO
PRODUTOS PERIGOSOS	QUÍMICO EXPLOSIVO CORROSIVO BIOLÓGICO

Além do *dataset* das ocorrências emergenciais, dados meteorológicos de Santa Catarina foram incorporados em experimentos para enriquecer o *dataset*, com o intuito de aprimorar a predição de eventos. Esses dados, obtidos pelo site do *INMET*, estão no formato .CSV e cobrem o mesmo período de 2017 a 2021, capturados pela estação meteorológica de cada região.

Atributo	Descrição
id_ocorrencia	Identificador da ocorrência
cidade	A cidade onde aconteceu a ocorrência
populacao	População total da cidade
horario	Data e hora da ocorrência
vtr	Viatura empenhada na ocorrência
mtcl	Matricula do militar ou cpf do Bombeiro comunitário
mitilar_bc	Identificação se o individuo é Bombeiro Comunitário ou Bombeiro Militar
bcz_indezado	Identifica se o bombeiro comunitário estava no serviço indenizado ou não
obm	Organização bombeiro militar que estava na ocorrência
coodernada_obm	Coordenada da organização Bombeiro Militar
coordenada_ocorrencia	Coordenada da ocorrência
lat_ocorrencia	Latitude ocorrência
lon_ocorrencia	Longitude ocorrência
tipo	Tipo da ocorrência
subtipo	Subtipo da ocorrência
tempo_resposta	Tempo do acionamento até a chegada ao local da ocorrência
tempo_total_empenho	Tempo total da saída da obm até a chegada a obm novamente
firecast	Indica se uma viatura utilizou o sistema "firecast" para efetuar comandos J-9, J-10, J-11 e J-12
origem_samu	Indica se foi um repasse da ocorrência que foi atendida pelo samu.
vitima	Informa em código o que ocorreu com a vítima da ocorrência

Tabela 2 – Dicionário de dados do dataset

Essas informações climáticas auxiliam na previsão de eventos emergenciais, devido ao impacto direto e indireto que as condições meteorológicas exercem sobre diversos tipos de ocorrências. Assim, a escolha desses dados auxiliares baseou-se na relevância que essas informações têm para a tomada de decisões e nos padrões climáticos sazonais que influenciam a dinâmica das emergências.

A tabela 4 apresenta o dicionário de dados para os dados meteorológicos obtidos pelo *INMET*.

Atributo	Descrição
DATA (YYYY-MM-DD)	Data, separada em "Ano-Mês-dia"
HORA (UTC)	Hora da coleta dos dados
PRECIPITAÇÃO TOTAL, HORARIO (mm)	Mediação de precipitação total, medida em mm
PRESSAO ATMOSFERICA AO NIVEL DA ESTACAO, HORARIA (mB)	Valor de pressão atmosférica, medida em mB
PRESSÃO ATMOSFERICA MAX.NA HORA ANT. (AUT) (mB)	Valor máximo de pressão atmosférica entre a ultima hora e o momento da coleta
PRESSÃO ATMOSFERICA MIN. NA HORA ANT. (AUT) (mB)	Valor mínimo de pressão atmosférica entre a ultima hora e o momento da coleta
RADIACAO GLOBAL (KJ/m <sup>2</sup> )	Valor referente a radiação solar, medido das 10:00 as 22:00
TEMPERATURA DO AR - BULBO SECO, HORARIA (°C)	Temperatura do ar, medida com um termômetro comum
TEMPERATURA DO PONTO DE ORVALHO (°C)	Temperatura do ar na qual a água começa a condensar
TEMPERATURA MÁXIMA NA HORA ANT. (AUT) (°C)	Temperatura máxima da última coleta até a coleta atual
TEMPERATURA MÍNIMA NA HORA ANT. (AUT) (°C)	Temperatura mínima da última coleta até a coleta atual
TEMPERATURA ORVALHO MAX. NA HORA ANT. (AUT) (°C)	Temperatura de orvalho máxima da última coleta até a coleta atual
TEMPERATURA ORVALHO MIN. NA HORA ANT. (AUT) (°C)	Temperatura de orvalho mínima da última coleta até a coleta atual
UMIDADE REL. MAX. NA HORA ANT. (AUT) (%)	Porcentagem referente à umidade relativa máxima da última coleta até a coleta atual
UMIDADE REL. MIN. NA HORA ANT. (AUT) (%)	Porcentagem referente à umidade relativa mínima da última coleta até a coleta atual
UMIDADE RELATIVA DO AR, HORARIA (%)	Porcentagem referente à umidade relativa da coleta
VENTO, DIREÇÃO HORARIA (gr) (° (gr))	Direção do vento
VENTO, RAJADA MAXIMA (m/s)	Velocidade máxima coletada entre a última coleta e a atual
VENTO, VELOCIDADE HORARIA (m/s)	Velocidade do vento na coleta

Tabela 4 – Dicionário de dados do INMET

Por fim, para incluir informações sobre áreas de risco, foram utilizados cartas de áreas de risco, realizadas por estudos feitos pelo Serviço Geológico Brasileiro (SGB). Esses

dados permitiram mapear áreas em níveis de risco distintos — Baixo, Médio e Alto — associados às coordenadas dos eventos. A Figura 6 abaixo ilustra essas áreas de risco pertencentes ao município de Florianópolis:

As colorações da imagem correspondem a níveis de risco diferentes entre risco de inundações e risco de suscetibilidade de movimentos de massa. Cada cor correspondente aos riscos de inundações estão representados pela figura 7 e da mesma forma as áreas de suscetibilidade de movimentos de massa estão representados pela figura 8

Figura 7 – Tabela de Classes de Suscetibilidade a Inundações

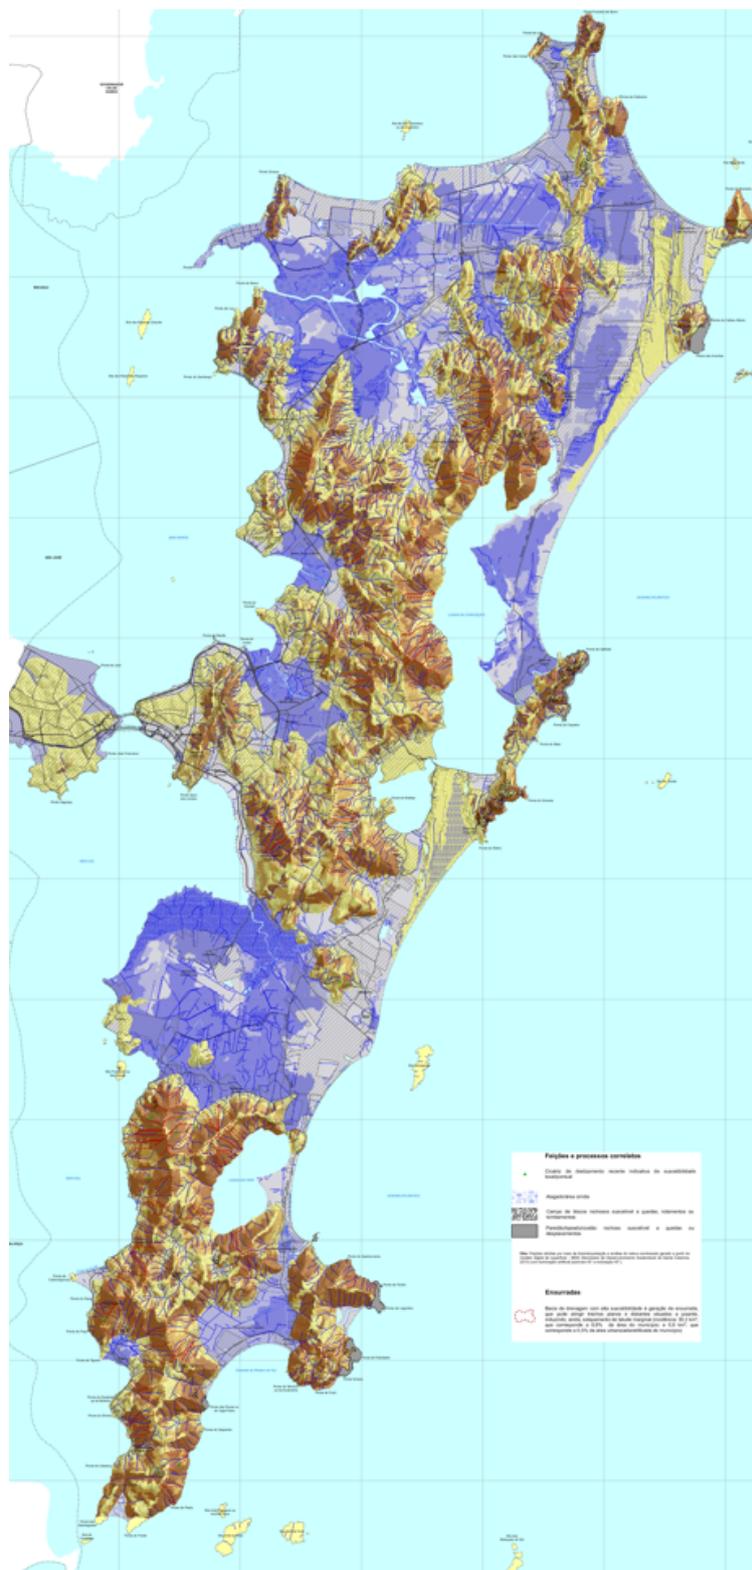
**Quadro-legenda B - Suscetibilidade a inundações**

Classe de suscetibilidade	Foto ilustrativa	Características predominantes		Área		Área urbanizada/edificada	
		Locais	Bacias de drenagem contribuintes	km <sup>2</sup>	% (*)	km <sup>2</sup>	% (**)
<b>Alta</b>		<ul style="list-style-type: none"> <li>• Relevo: planícies aluviais/costeiras, com amplitudes e declividades muito baixas (&lt; 2<sup>o</sup>);</li> <li>• Solos: hidromórficos, em terrenos situados ao longo de curso d'água, mal drenados e com nível d'água subterrâneo aflorante a raso;</li> <li>• Altura de inundação: até 2,5 m em relação à borda da calha do leito regular do curso d'água; e</li> <li>• Processos: inundação, alagamento e assoreamento.</li> </ul>	<ul style="list-style-type: none"> <li>• Área de contribuição: grande;</li> <li>• Formato: tendendo a circular;</li> <li>• Densidade de drenagem: alta;</li> <li>• Padrão dos canais fluviais: tendendo a sinuoso; e</li> <li>• Relação de relevo: amplitude baixa e canal principal longo.</li> </ul>	82,1	18,7	22,2	19,8
<b>Média</b>		<ul style="list-style-type: none"> <li>• Relevo: terraços fluviais/marinhos baixos e/ou flancos de encostas, com amplitudes e declividades baixas (&lt; 5<sup>o</sup>);</li> <li>• Solos: hidromórficos e não hidromórficos, em terrenos argilo-arenosos e com nível d'água subterrâneo raso a pouco profundo;</li> <li>• Altura de inundação: entre 2,5 e 5 m em relação à borda da calha do leito regular do curso d'água; e</li> <li>• Processos: inundação, alagamento e assoreamento.</li> </ul>	<ul style="list-style-type: none"> <li>• Área de contribuição: intermediária;</li> <li>• Formato: circular a alongado;</li> <li>• Densidade de drenagem: média;</li> <li>• Padrão dos canais fluviais: sinuoso a retilíneo; e</li> <li>• Relação de relevo: amplitude média e canal principal intermediário.</li> </ul>	36,7	8,3	17,4	15,5
<b>Baixa</b>		<ul style="list-style-type: none"> <li>• Relevo: terraços fluviais/marinhos altos e/ou flancos de encostas, com amplitudes e declividades baixas (&lt; 5<sup>o</sup>);</li> <li>• Solos: não hidromórficos, em terrenos silto-arenosos e com nível d'água subterrâneo pouco profundo;</li> <li>• Altura de inundação: acima de 5 m em relação à borda da calha do leito regular do curso d'água; e</li> <li>• Processos: inundação, alagamento e assoreamento.</li> </ul>	<ul style="list-style-type: none"> <li>• Área de contribuição: pequena;</li> <li>• Formato: tendendo a alongado;</li> <li>• Densidade de drenagem: baixa;</li> <li>• Padrão dos canais fluviais: tendendo a retilíneo; e</li> <li>• Relação de relevo: amplitude alta e canal principal curto.</li> </ul>	51,4	11,7	27,5	24,5

(\*) Porcentagem em relação à área emersa do município. (\*\*) Porcentagem em relação à área urbanizada/edificada do município.

Fonte: Serviço Geológico Brasileiro

Figura 6 – Riscos de movimentos gravitacionais e suscetibilidade a inundações



Fonte: Serviço Geológico Brasileiro

Figura 8 – Tabela de Classes de Suscetibilidade a Movimentos de Massa

**Quadro-legenda A - Suscetibilidade a movimentos gravitacionais de massa**

Classe de suscetibilidade	Foto ilustrativa	Características predominantes	Área		Área urbanizada/edificada	
			km <sup>2</sup>	% (*)	km <sup>2</sup>	% (**)
Alta		<ul style="list-style-type: none"> <li>• Relevo: serras e morros altos;</li> <li>• Forma das encostas: retilíneas e côncavas, com anfiteatros de cabeceiras de drenagem abruptos;</li> <li>• Amplitudes: 80 a 360 m;</li> <li>• Declividades: &gt; 25°;</li> <li>• Litologia: séries graníticas alcalinas;</li> <li>• Densidade de lineamentos/estruturas: alta;</li> <li>• Solos: pouco evoluídos e rasos; e</li> <li>• Processos: deslizamento e queda de rocha.</li> </ul>	76,6	17,4	2,9	2,6
Média		<ul style="list-style-type: none"> <li>• Relevo: serras, morros altos e morros baixos;</li> <li>• Forma das encostas: convexas a retilíneas e côncavas, com anfiteatros de cabeceira de drenagem;</li> <li>• Amplitudes: 60 a 280 m;</li> <li>• Declividades: 10 a 30°;</li> <li>• Litologia: séries graníticas alcalinas;</li> <li>• Densidade de lineamentos/estruturas: média;</li> <li>• Solos: evoluídos e moderadamente profundos; e</li> <li>• Processos: deslizamento e queda de rocha.</li> </ul>	48,8	11,1	4,5	4,0
Baixa		<ul style="list-style-type: none"> <li>• Relevo: planícies e terraços fluviais/marinhos e colinas;</li> <li>• Forma das encostas: convexas suavizadas e topos amplos;</li> <li>• Amplitudes: &lt; 160 m;</li> <li>• Declividades: &lt; 15°;</li> <li>• Litologia: sedimentos argilosos;</li> <li>• Densidade de lineamentos/estruturas: baixa;</li> <li>• Solos: aluviais/marinhos; evoluídos e profundos nas colinas; e</li> <li>• Processos: deslizamento e queda de rocha.</li> </ul>	314,1	71,5	104,7	93,4

(\*) Porcentagem em relação à área emersa do município. (\*\*) Porcentagem em relação à área urbanizada/edificada do município.

Fonte: Serviço Geológico Brasileiro

### 3.4 ENTENDIMENTO E PREPARAÇÃO DOS DADOS

A fase de preparação de dados é crucial em projetos de *data mining*, pois garante que os dados estejam em um formato adequado para o processamento e modelagem. Este estágio envolve a limpeza de dados para remover ruídos e inconsistências, a transformação e normalização para assegurar que os dados sejam comparáveis, e a construção de novos atributos que possam melhorar a performance dos modelos. Uma preparação de dados bem-executada não só melhora a precisão dos modelos, mas também reduz o tempo de processamento e aumenta a confiança nos resultados finais. Sem essa etapa, a qualidade dos *insights* extraídos pode ser significativamente comprometida, impactando negativamente as decisões de negócio baseadas nesses dados. (GALLAGHER; BRUTON; O'SULLIVAN, 2016)

A qualidade dos dados e a forma como são preparados podem influenciar significativamente o sucesso do modelo de mineração de dados. Dados mal preparados podem levar a modelos imprecisos, *insights* incorretos e decisões erradas. Portanto, é essencial

dedicar tempo e recursos adequados para esta fase, garantindo que os dados estejam em uma forma utilizável e de alta qualidade.

A fim de entender melhor os dados para realizar inclusões e exclusões, foram realizadas análises exploratórias, facilitando a tomada de decisão. Para um melhor tratamento e manipulação dos dados, foi necessário cadastrar a tipagem dos campos e criar novos campos, separando o campo horário em datas e horários.

Para melhorar o sucesso dos modelos, foram realizadas análises que descobriram diversos registros com campos nulos, totalizando 186.509 de um total de 1.927.410 registros, os quais foram removidos do *dataset*, pois não forneciam informações necessárias para a pesquisa. Além disso, a análise identificou ocorrências duplicadas com o mesmo identificador, onde 1.358.603 estavam duplicados restando 568.807 registros originais. Os registros duplicados foram excluídos.

A fim de verificar a veracidade das coordenadas, foram realizados *plots*, comparando as coordenadas com o local no mapa disponibilizado pela prefeitura. Isso permitiu descobrir que algumas coordenadas não correspondiam ao local cadastrado, sendo necessárias remoções manuais do *dataset*, delimitando o range das coordenadas geográficas do *dataset*.

Após a remoção dos registros com erro de coordenadas, foram identificados erros de cadastro no *dataset*. Cada campo foi analisado em busca de inconsistências, resultando na descoberta de dados faltantes e registros com formatos de cadastro diferentes. Por exemplo, no atributo *obm*, o formato esperado era *2ªPEL/2ªCBM/1ªBBM - TRINDADE*, mas diversos registros estavam cadastrados de maneira inconsistente, como *1/8105*, dificultando a análise. Para evitar que esses erros afetassem os modelos de previsão, foi decidido retirar os atributos *obm*, *coordenada\_obm*, *lat\_obm*, *lon\_obm*, *origem\_samu*, *vitima* e *firecast* do *dataset*.

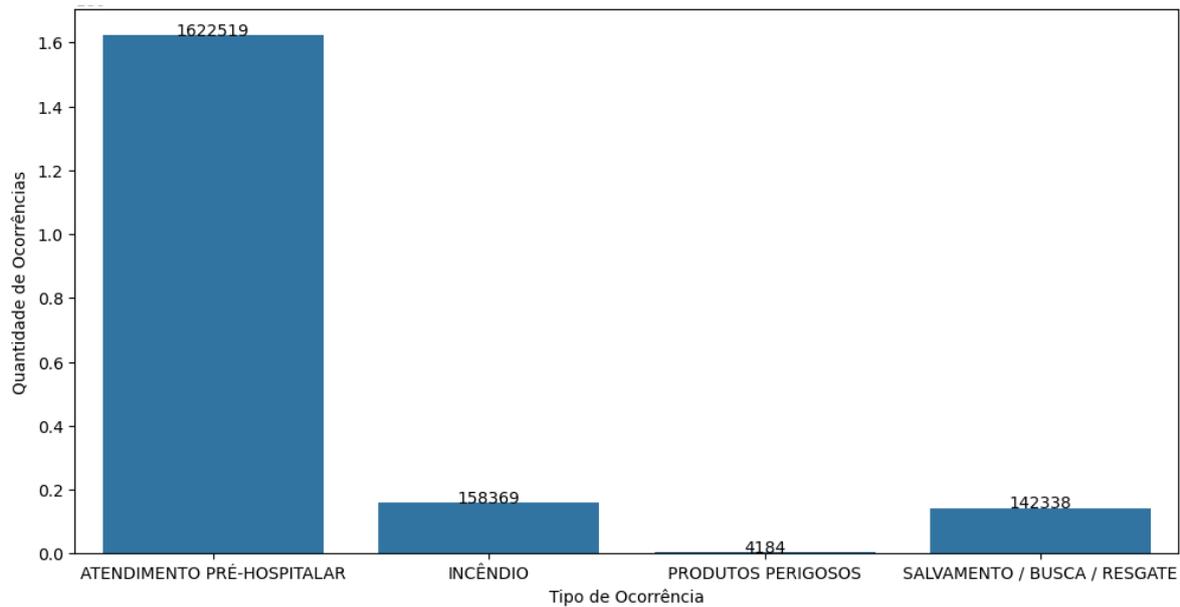
Algumas informações presentes no *dataset*, não continham informações pertinentes a predição dos eventos, além de conter dados faltantes, logo os campos *coordenada\_ocorrencia*, *militar\_bc*, *bc\_indenizado*, *tempo\_resposta*, *tempo\_total\_empenho* foram retirados.

Para entender melhor a distribuição dos dados e criar filtros adequados, foram realizadas diversas consultas exploratórias. Inicialmente, analisou-se a distribuição das ocorrências por tipo, como mostrado na Figura 9.

Observa-se uma distribuição desigual, com a maioria das ocorrências classificadas em uma categoria específica. No entanto, como um dos objetivos deste estudo é analisar as predições quando o *dataset* é enriquecido com dados meteorológicos, o tipo *ATENDIMENTO PRÉ-HOSPITALAR* foi considerado não relevante, pois aparenta não apresentar relação direta com variáveis climáticas. A Figura 10 ilustra a distribuição dos subtipos de "ATENDIMENTO PRÉ-HOSPITALAR".

Ao observar a Figura 10, nota-se que a quantidade de ocorrências sem um sub-

Figura 9 – Quantidade de Ocorrências por Tipo



Fonte: Produzido pelo autor

tipo classificado é muito superior a qualquer subtipo especificado, o que representa uma anomalia no *dataset* e justifica a disparidade entre as categorias de dados.

Como este estudo propõe o enriquecimento dos dados com informações climáticas e de áreas de risco, o tipo *SALVAMENTO / BUSCA / RESGATE* foi considerado relevante e será o foco da pesquisa. A Figura 11 ilustra a distribuição das ocorrências deste tipo.

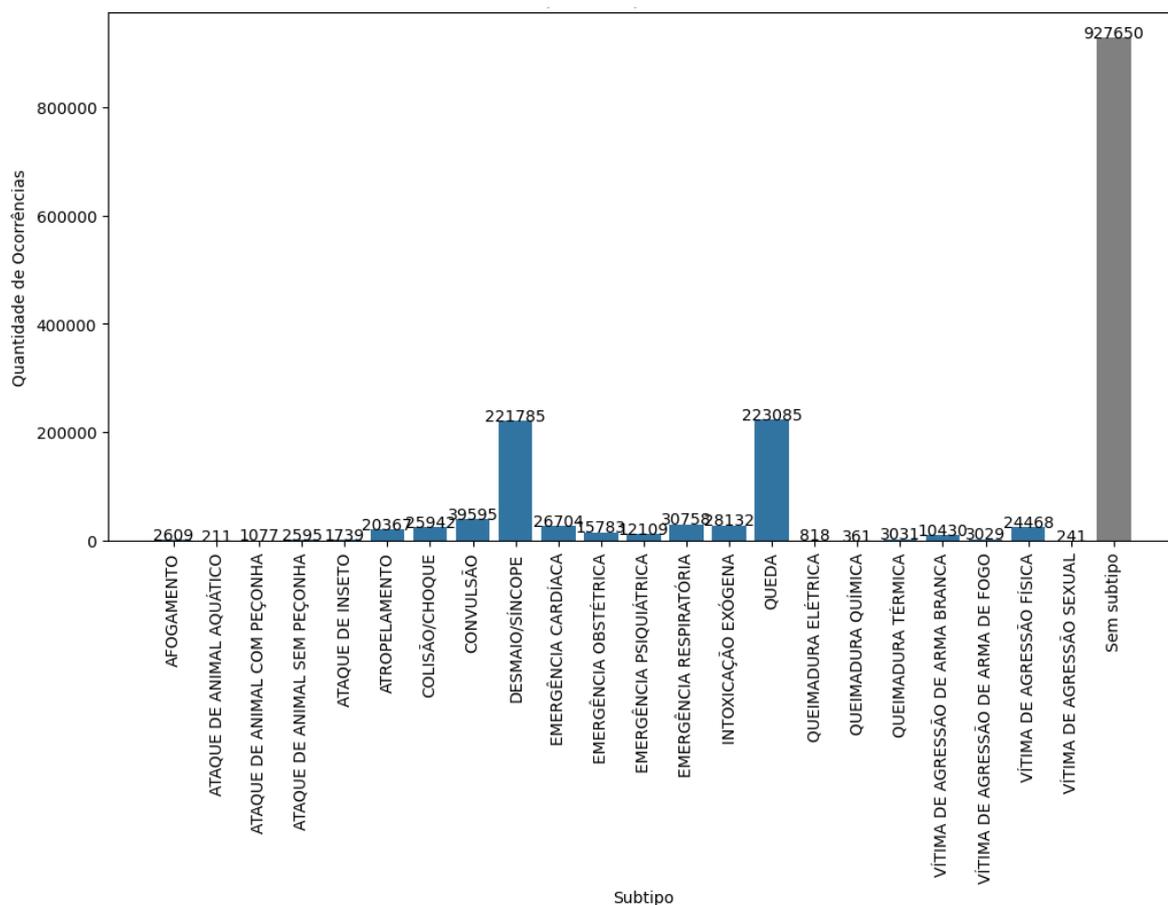
Ainda que a quantidade de registros sem classificação de subtipos seja alta, não é predominante como em *ATENDIMENTO PRÉ-HOSPITALAR*. Como subtipos influenciados diretamente por fatores meteorológicos são pouco frequentes, optou-se por utilizar o conjunto quase completo dos dados desse tipo, retirando apenas os subtipos *SUICÍDIO/TENTATIVA*, *EXPLOSÃO*, *AFOGAMENTO* e *SEM SUBTIPO*.

Para enriquecer os dados, foram utilizadas medições climáticas realizadas pelo *INMET*, com dados disponibilizados publicamente pelo Órgão Federal. As medições são realizadas a cada hora, e, a partir das datas e horários das ocorrências, foram feitas junções no *dataset*. Com esses dados, foi possível identificar padrões que afetam diretamente a quantidade de ocorrências em determinado período, melhorando as previsões para eventos emergenciais.

Para que o *dataset* formado referente a informações meteorológicas tenha consistentes, as informações presentes foram tratadas e juntadas. Cada *dataset* de dados meteorológicos continha um padrão específico, entretanto continha as mesmas informações, logo foi necessário um tratamento para fazer a junção de todos os *datasets* obtidos.

Para melhorar os resultados dos modelos, o *dataset* de dados meteorológicos foi

Figura 10 – Subtipos de Atendimento Pré-Hospitalar



Fonte: Produzido pelo autor

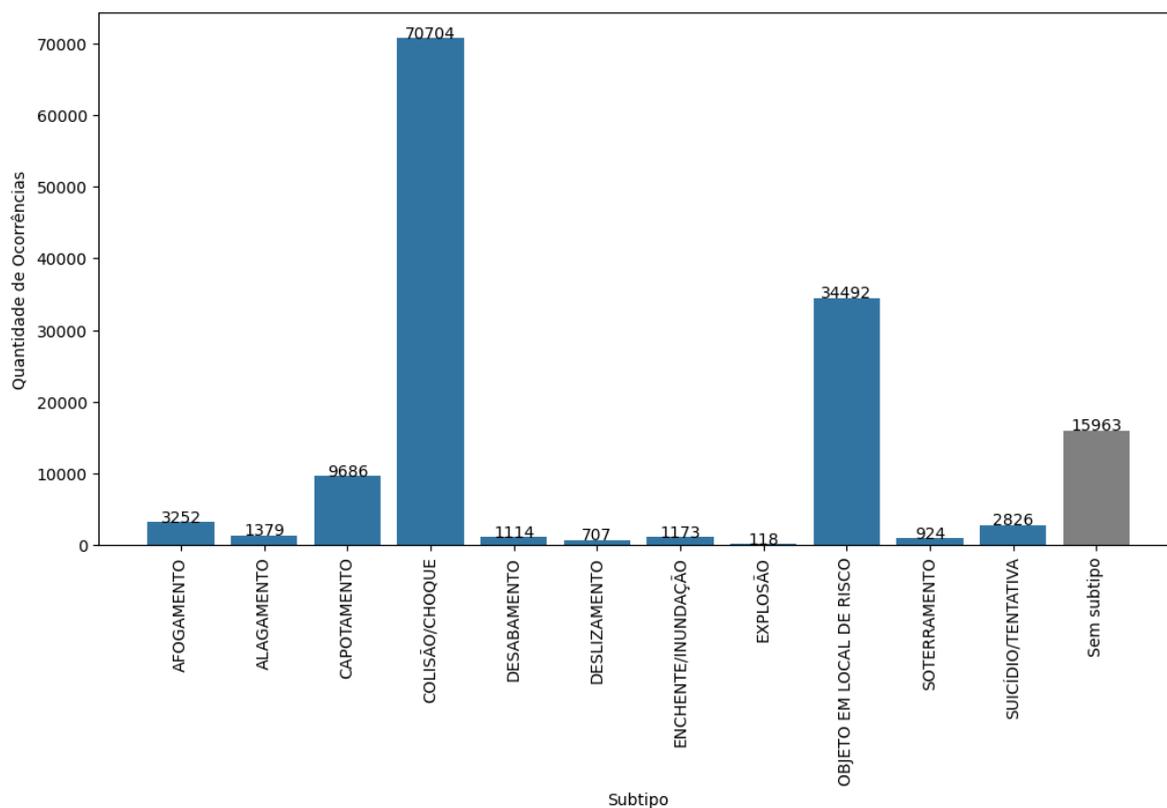
analisado, então os campos que não continham informações relevantes foram retirados, sendo eles "RADIACAO GLOBAL (KJ/m2)", "TEMPERATURA DO AR - BULBO SECO, HORARIA (°C)", "TEMPERATURA DO PONTO DE ORVALHO (°C)", "TEMPERATURA MÁXIMA NA HORA ANT. (AUT) (°C)", "TEMPERATURA MÍNIMA NA HORA ANT. (AUT) (°C)", "TEMPERATURA ORVALHO MAX. NA HORA ANT. (AUT) (°C)" e "TEMPERATURA ORVALHO MIN. NA HORA ANT. (AUT) (°C)".

As informações pertinentes a áreas de risco precisaram de pouco tratamento, foram usados os arquivos que continham os vetores com as informações áreas de risco em suas respectivas coordenadas. Então as áreas foram classificadas de acordo com seu risco.

### 3.5 TREINAMENTO DOS MODELOS

A fase de treinamento dos modelos na arquitetura *CRISP-DM* é onde a análise técnica se intensifica, transformando dados preparados em modelos preditivos ou descritivos que fornecem *insights* acionáveis. Durante esta etapa, as técnicas de modelagem

Figura 11 – Subtipos de Salvamento/ Busca / Resgate



Fonte: Produzido pelo autor

apropriadas são selecionadas e aplicadas, seguidas pela validação e avaliação rigorosa para garantir que os modelos não apenas se ajustem bem aos dados de treinamento, mas também generalizem efetivamente para novos dados. A fase de modelagem é crucial porque traduz a análise dos dados em previsões concretas e recomendações, desempenhando um papel central na capacidade da organização de tomar decisões baseadas em dados. (GALLAGHER; BRUTON; O’SULLIVAN, 2016)

Esta etapa de modelagem segue a abordagem *Modeling*, que envolve a classificação dos dados e a seleção da técnica de modelagem adequada, além da avaliação dos resultados por meio da comparação de diferentes modelos para escolher os mais eficazes. Os dados são divididos em duas partes: uma para treinamento e outra para teste, e as técnicas de aprendizado de máquina são aplicadas para obter os resultados desejados, que são então comparados para determinar as melhores abordagens.

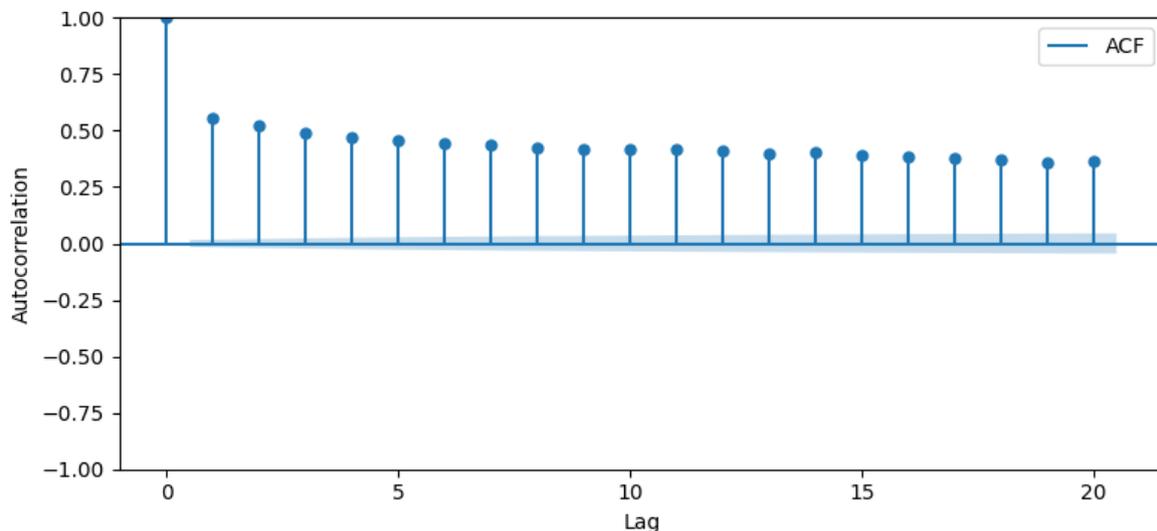
A separação dos dados foi realizada com a biblioteca *sklearn*, que oferece ferramentas eficientes para análise preditiva, reutilizáveis em diversas situações e com código aberto. O *dataset* foi dividido aleatoriamente, com 80% dos dados usados para o treinamento e o restante para avaliar a precisão das previsões.

## ARIMA

No modelo *ARIMA*, foi utilizada uma abordagem de *Rolling Forecast*, na qual é uma técnica de previsão em séries temporais usada para avaliar o desempenho de modelos preditivos em cenários que refletem condições do mundo real. Essa abordagem simula a previsão contínua, ajustando o modelo a cada nova observação.

Como apresentado anteriormente no capítulo 2, o método *ARIMA* possui três parâmetros:  $p$ ,  $d$  e  $q$ . Para determinar os valores adequados para cada um desses parâmetros, foram realizadas análises nos dados de entrada, utilizando *plots* de correlação e diferentes graus de diferenciação. Entretanto, em cada conjunto de diferente de dados, novos testes devem ser realizados. O gráfico representado pela figura 12 ilustra um exemplo de correlação.

Figura 12 – Autocorrelação de Pearson com diferentes lags temporais



Fonte: Produzido pelo Autor

O gráfico da Função de Autocorrelação (ACF) representado pela figura 12, é uma representação que mede a correlação linear entre os valores de uma série temporal em diferentes *lags* temporais. Cada *lag* representa um intervalo no tempo, e o eixo X do gráfico mostra os valores de *lag*, enquanto o eixo Y indica a força da correlação, que varia de -1 (correlação perfeita negativa) a 1 (correlação perfeita positiva). As barras verticais no gráfico indicam os coeficientes de autocorrelação, e as linhas pontilhadas horizontais representam o intervalo de confiança, permitindo identificar quais *lags* têm correlações estatisticamente significativas. Valores fora desse intervalo sugerem que os dados possuem uma relação temporal importante nesse *lag*, enquanto valores dentro do intervalo indicam uma correlação não significativa.

O *ACF* é essencial para entender padrões temporais nos dados e pode revelar a presença de sazonalidade ou persistência em séries temporais. A análise também é útil para guiar a construção de modelos, como a escolha do número de *lags* relevantes em modelos *ARIMA*.

Para o modelo *ARIMA*, foi decidido usar transformações *Box-Cox*, onde é uma técnica matemática usada para transformar dados de modo que eles se aproximem de uma distribuição normal (gaussiana) e para estabilizar a variância, especialmente em séries temporais ou regressões lineares. Para a configuração inicial o conjunto de treino transformado é armazenado em uma lista, que será usada para ajustar o modelo e fazer previsões de forma incremental.

Após fazer as previsões no domínio transformado, os valores foram convertidos de volta ao domínio original, para que sejam realizadas as avaliações.

## LSTM

No modelo *LSTM*, foi utilizada a abordagem de *Rolling Forecast*, que prevê o próximo passo no tempo com base em valores anteriores. Essa estratégia é adequada para séries temporais, pois permite a atualização constante das previsões conforme novos dados se tornam disponíveis.

Um dos primeiros passos foi aplicar a normalização nos dados para garantir que todas as variáveis de entrada estivessem na mesma escala, essencial para o bom desempenho de redes neurais. Para isso, utilizou-se a função *MinMaxScaler*, que escalona os dados para valores entre 0 e 1, evitando problemas de dominância de variáveis com maiores magnitudes e acelerando o processo de convergência durante o treinamento.

O modelo *LSTM* foi configurado com duas camadas principais de redes recorrentes. Cada camada contém 50 células de memória (definido pelo parâmetro *units=50*), uma escolha comum para capturar padrões complexos em séries temporais de médio porte. A primeira camada *LSTM* foi configurada com o parâmetro *return\_sequences=True* para permitir que suas saídas sejam utilizadas como entradas para a camada subsequente. Isso é particularmente importante em arquiteturas profundas, como a utilizada neste caso, para preservar informações temporais ao longo das camadas.

Para mitigar o risco de *overfitting*, foi empregada a técnica de regularização *Dropout*, que desativa aleatoriamente uma fração dos neurônios de uma camada durante o treinamento. A taxa de *Dropout* foi definida como 20% (ou *rate=0.2*), o que força o modelo a aprender representações mais generalizadas e independentes dos dados de entrada.

A camada de saída do modelo é uma *Dense layer* com apenas uma unidade (*units=1*), apropriada para prever valores contínuos, como a quantidade diária de chamadas ou vendas. O modelo foi compilado utilizando o otimizador *Adam*, uma escolha padrão devido à sua eficiência em problemas com dados ruidosos, combinado com a função

de perda *mean\_squared\_error* (MSE), que mede a diferença média quadrada entre os valores previstos e os reais.

## RNN

O modelo *RNN* utilizou a abordagem de *Rolling Forecast*, apropriada para séries temporais, permitindo a previsão do próximo valor com base em uma janela deslizante de dados anteriores. A preparação do modelo envolveu a definição de componentes, funções e parâmetros específicos para ajustar a rede neural aos dados de previsão.

Inicialmente, aplicou-se a normalização dos dados para garantir que todas as variáveis estivessem em uma escala uniforme, essencial para o desempenho de redes neurais. A função *MinMaxScaler* foi utilizada para escalonar os valores entre 0 e 1, o que melhora a convergência do modelo e facilita o aprendizado durante o treinamento.

A arquitetura do modelo foi composta por uma camada de células *SimpleRNN*, configurada com 50 unidades (*units=50*) e função de ativação *ReLU* (*activation='relu'*). Este número de unidades foi escolhido para capturar padrões temporais complexos, fornecendo à rede capacidade suficiente para processar as dependências sequenciais presentes nos dados.

A camada de entrada foi configurada para receber sequências de 10 passos de tempo (*time\_step=10*), com uma única característica em cada passo (*input\_shape=(10, 1)*). Esse formato reflete a estrutura de janelas temporais utilizada para alimentar o modelo, o que é fundamental para a previsão baseada em séries temporais.

Uma camada de saída *Dense* com uma unidade (*units=1*) foi adicionada ao final do modelo, adequada para a predição de valores contínuos, como a quantidade diária de chamadas. Essa configuração simplificada é ideal para problemas de regressão em que se prevê um único valor numérico.

O modelo foi compilado utilizando o otimizador *Adam*, amplamente reconhecido por sua eficiência em problemas com dados ruidosos e sua capacidade de adaptação durante o treinamento. A função de perda escolhida foi o erro quadrático médio (*mean\_squared\_error*), que penaliza previsões distantes dos valores reais, sendo apropriada para problemas de regressão.

O treinamento foi realizado por 10 épocas (*epochs=10*) e com um tamanho de lote de 32 (*batch\_size=32*). Este número de épocas foi suficiente para garantir que o modelo aprendesse os padrões presentes nos dados sem overfitting, enquanto o tamanho do lote balanceou a precisão do gradiente e o custo computacional.

## 3.6 AVALIAÇÃO DOS MODELOS

Para avaliar a precisão das previsões geradas pelos três modelos (*ARIMA*, *LSTM* e *RNN Simples*), foram utilizadas quatro métricas de erro amplamente utilizadas em

publicações científicas e estudos de predição de séries temporais:

Mean Squared Error (MSE): O *MSE* mede a média dos quadrados dos erros, ou seja, a média das diferenças elevadas ao quadrado entre os valores reais e os valores previstos. Quanto menor o *MSE*, melhor o desempenho do modelo, pois indica que as previsões estão mais próximas dos valores reais.

Root Mean Squared Error (RMSE): O *RMSE* é a raiz quadrada do *MSE*, o que o torna mais intuitivo, pois é expresso na mesma unidade dos dados originais. O *RMSE* também ajuda a identificar o impacto dos grandes erros, uma vez que penaliza mais erros maiores.

Mean Absolute Error (MAE): O *MAE* calcula a média das diferenças absolutas entre os valores reais e os valores previstos. Ele fornece uma medida direta da magnitude média do erro, sendo fácil de interpretar. Quanto menor o *MAE*, melhor o modelo, pois indica que a magnitude média dos erros é pequena.

Mean Absolute Percentage Error (MAPE): O *MAPE* mede a média dos erros absolutos em termos percentuais. Ele é particularmente útil para avaliar a precisão do modelo em relação aos valores reais, pois expressa os erros em termos relativos. Um *MAPE* mais baixo indica que o modelo tem um bom desempenho na previsão, com menor variação em relação aos valores reais.

Essas métricas foram escolhidas porque são amplamente reconhecidas como indicadores eficazes da precisão de modelos de previsão em séries temporais, fornecendo uma medida objetiva da qualidade das previsões.

## 4 EXPERIMENTOS

Este capítulo apresenta os experimentos realizados para avaliar o desempenho das abordagens propostas neste trabalho. Na Seção 4.1, são descritos os experimentos utilizando apenas os dados de ocorrências registradas em Florianópolis. A Seção 4.2 incorpora dados meteorológicos aos dados de ocorrências, enquanto a Seção 4.3 avalia a inclusão de dados de áreas de risco. A Seção 4.4 combina ambas as fontes de enriquecimento, meteorológicos e de áreas de risco, para verificar sua influência conjunta. Na Seção 4.5, são apresentados os resultados ao expandir a análise para todo o estado de Santa Catarina, utilizando os dados de ocorrências e áreas de risco. Por fim, a Seção 4.6 traz uma discussão sobre os resultados obtidos, destacando os principais achados e desafios encontrados ao longo dos experimentos.

Foram realizados diversos experimentos para observar como os modelos se ajustam aos dados e quais são as diferenças nos resultados e experimentos com o enriquecimento dos dados. Cada experimento tem um conjunto de dados diferente, logo o treinamento dos mesmos pode variar dependendo do modelo preditivo. O treinamento dos modelos *RNN* e *LSTM* mantiveram os mesmos, ocorrendo apenas alterações no *ARIMA*. Por o modelo *ARIMA* receber apenas uma única *feature* (dado de entrada para o modelo), o enriquecimento do *dataframe* por meio de novos campos com informações adicionais não alterava o resultado significativamente, logo o *ARIMA* será analisado apenas nos experimentos que contém quantidades diferentes de registros no *dataset*.

Os experimentos foram analisados utilizando as métricas presentes na sessão 3.6, além disso foram realizados gráficos para visualizar as previsões comparadas com os dados reais ao longo do tempo. O *dataset* que foi usado como entrada variou com cada experimento, sendo os quatro primeiros utilizando o recorte geográfico de Florianópolis e o último com o recorte geográfico de Santa Catarina. Todos os *datasets* de entrada tinham uma estrutura parecida, e a variável de predição foi a quantidade de ocorrências em determinado dia, entretanto cada registro do *dataset* continha informações de uma ocorrência, e um campo com o número total de ocorrências no dia dessa ocorrência. Logo, os gráficos com as previsões não foram realizados com a finalidade de demonstrar resultados discretos, e sim variando em um tempo contínuo, devido a registros terem tempos diferentes entre si, podendo variar em horas ou até mesmo dias.

### 4.1 OCORRÊNCIAS EM FLORIANÓPOLIS

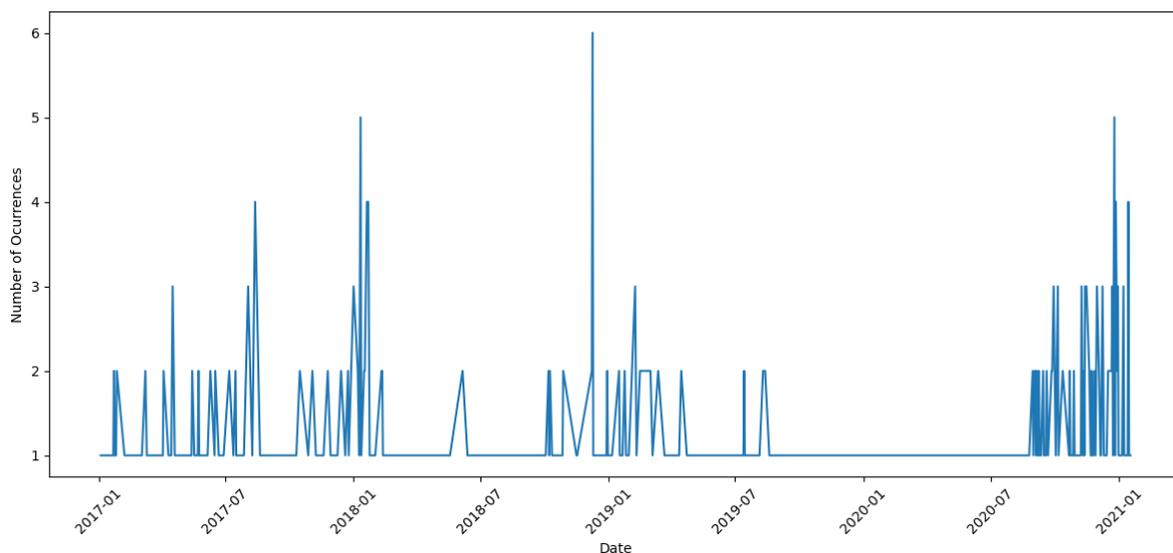
O primeiro experimento foi realizado com o objetivo de prever a quantidade de chamadas diárias para as Forças de Segurança e Salvamento em Florianópolis, utilizando os modelos de predição *ARIMA*, *LSTM* e *RNN Simples*. Para este experimento, foi

utilizado apenas o *dataset* das Forças de Segurança e Salvamento, com a quantidade de registros sendo 493, onde contém informações de tempo, quantidade de ocorrências diárias, id de ocorrências, tipo, subtipo e localidade.

O principal objetivo do experimento foi fazer previsões da quantidade de chamadas diárias para as Forças de Segurança e Salvamento, utilizando os diferentes modelos de previsão de séries temporais. Essa tarefa de previsão busca identificar e capturar padrões temporais nas ocorrências de chamadas, ajudando a prever a demanda futura dos serviços de segurança e salvamento, o que pode ser essencial para o planejamento de recursos e alocação eficiente de equipes.

Após a explicação sobre os objetivos e a metodologia do experimento, é importante incluir uma representação visual das séries temporais das ocorrências de Florianópolis. A Figura 13 ilustra a evolução das ocorrências, proporcionando uma visão clara e objetiva do comportamento das ocorrências ao longo do tempo.

Figura 13 – Série Temporal: Número de ocorrências de eventos do TIPO Salvamento/-Busca/Resgate em Florianópolis variando no tempo



Fonte: Produzido pelo autor

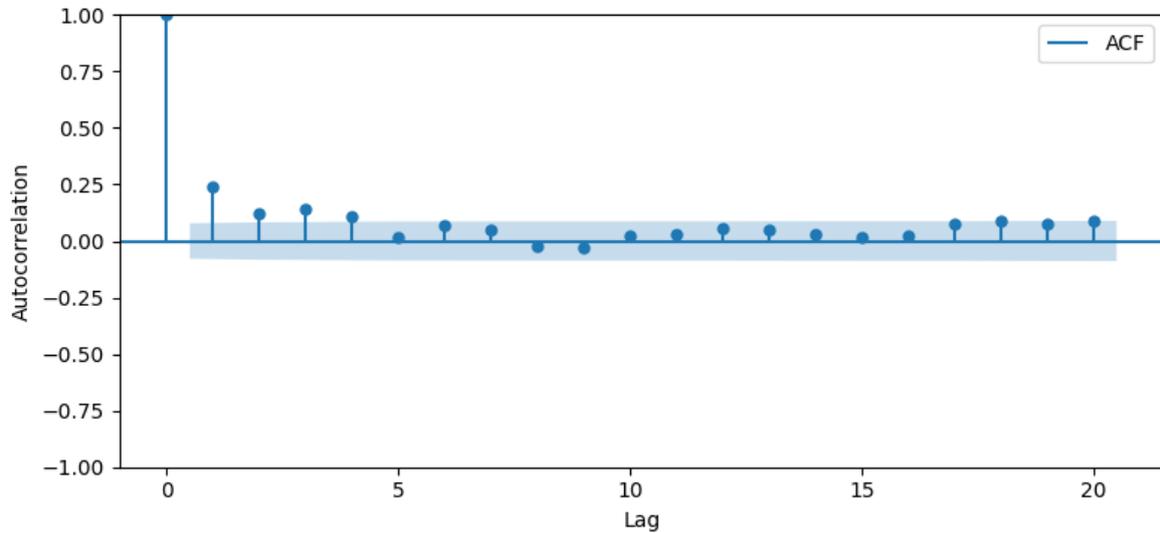
## ARIMA

Inicialmente, é necessário determinar a ordem de diferenciação para tornar os dados o mais estacionários possível. O método *adfuller* foi utilizado para verificar qual o menor valor de  $d$ , que indicaria a diferenciação, para entender se os dados estão estacionários ou devem ser realizadas diferenciações até que os dados estejam, descobrindo assim o valor de  $d$ . O valor de  $d$  foi 0, pois os dados estavam estacionários quando analisados.

O próximo passo é determinar o valor de  $p$ , que é delimitado pela maior *lag*

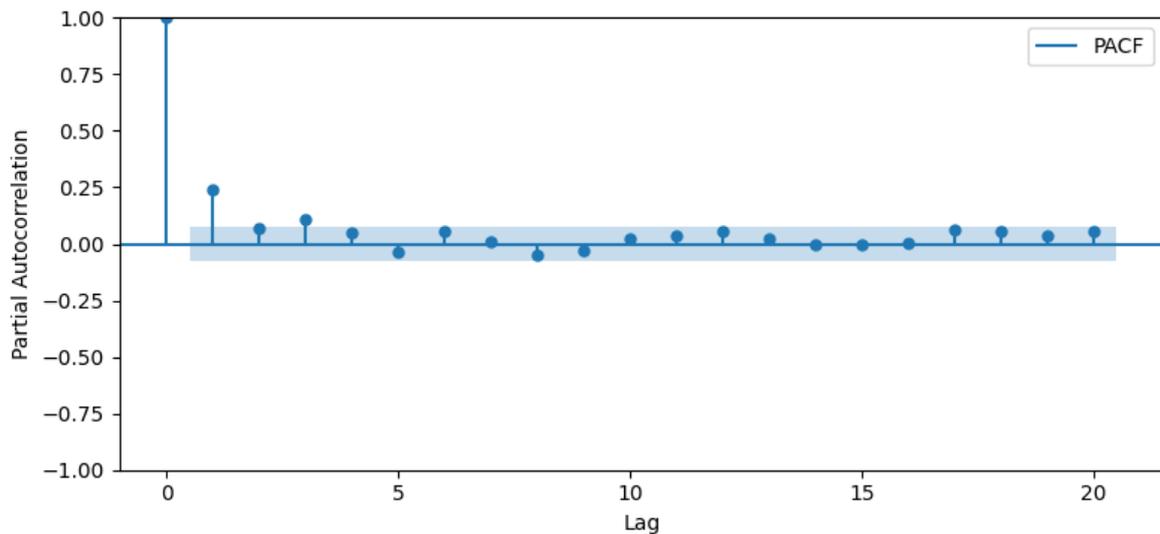
identificada nos *plots* de autocorrelação parcial. A partir da análise dos gráficos, pode-se inferir que o valor de  $p = 1$  é o mais adequado. Já o valor de  $q$  é definido com base no número de *lags* que ultrapassam o limite, utilizando o *plot ACF* em vez do *PACF*. Ao analisar os gráficos nas figuras 14 e 15, conclui-se que o valor ideal para  $q$  é 1.

Figura 14 – Autocorrelation Function (ACF)



Fonte: Produzido pelo Autor

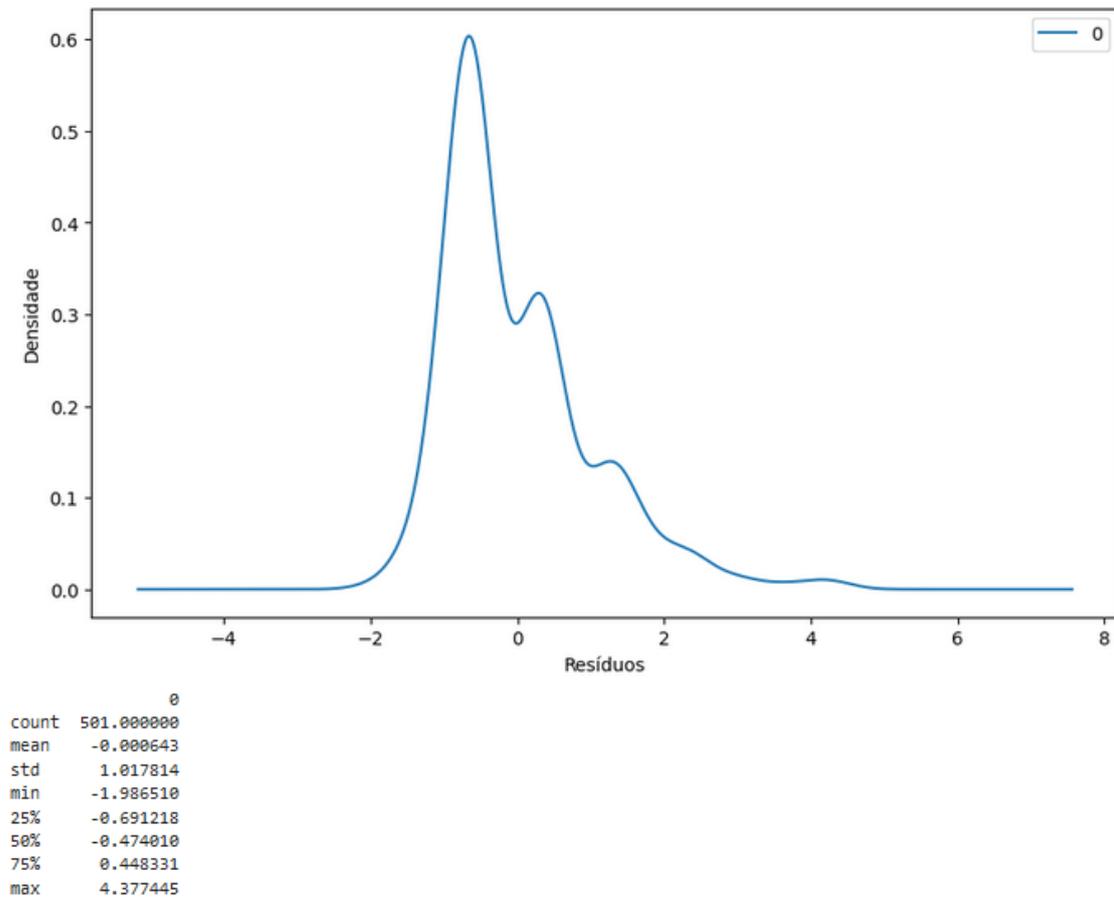
Figura 15 – Partial Autocorrelation (PACF)



Fonte: Produzido pelo Autor

Em seguida, foram avaliados os resíduos para verificar a adequação do modelo aos dados. Os resultados estão ilustrados na figura 16.

Figura 16 – Análise Residual de Quantidade de Ocorrências



Fonte: Produzida pelo Autor

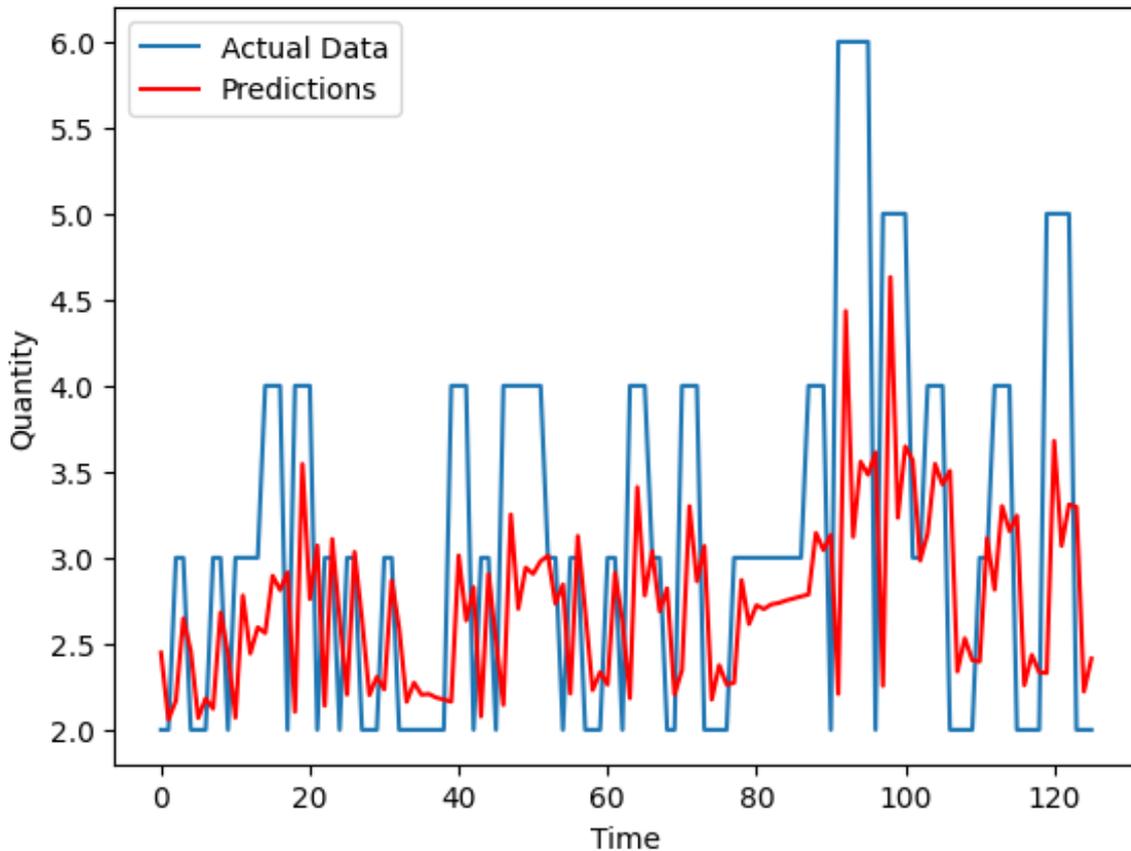
A falta de correlação ilustrada na figura 16 pode sugerir que a variável *Quantity* não depende fortemente de seus valores passados. Nesse caso, um modelo *ARIMA*, *RNN* ou *LSTM* pode ter dificuldade em fazer previsões precisas, pois essas abordagens dependem de padrões temporais.

A análise dos resíduos do modelo revela alguns pontos importantes sobre sua performance. A média dos resíduos é de -0.0006, o que está muito próxima de zero e sugere que o modelo não apresenta viés sistemático. Isso indica que as previsões não estão tendendo consistentemente para mais ou para menos em relação aos valores reais. No entanto, o desvio padrão relativamente alto, de 1.017, aponta que existe uma variação considerável nas diferenças entre os valores previstos e os reais, o que pode ser um sinal de que o modelo não está capturando toda a complexidade dos dados, deixando um erro considerável em algumas previsões. Além disso, a amplitude dos resíduos, que varia de -1.98 a 4.37, sugere que o modelo apresenta algumas previsões muito distantes dos valores reais, com grandes desvios em algumas observações.

## Resultados do ARIMA

A imagem 17 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *ARIMA* como modelo utilizado.

Figura 17 – Ocorrências Florianópolis - ARIMA



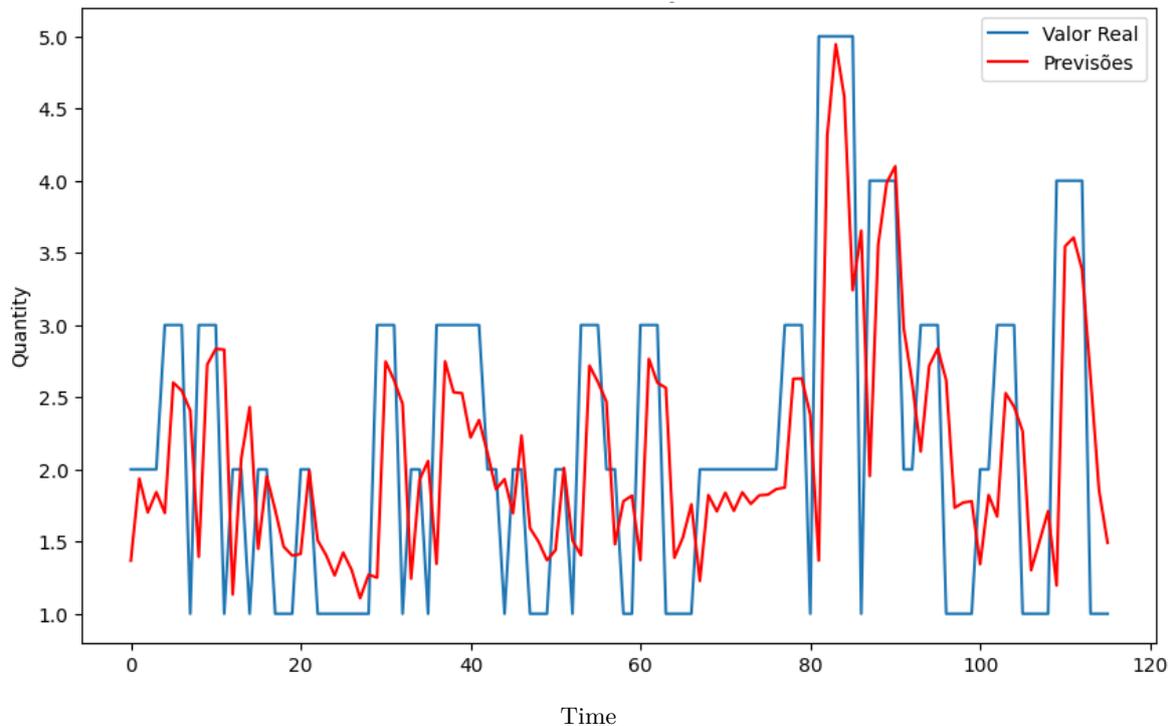
Fonte: Produzido pelo autor

O modelo *ARIMA* apresentou os seguintes resultados para o experimento com dados das Forças de Segurança e Salvamento. O *Mean Squared Error (MSE)* foi de 1.08, enquanto o *Root Mean Squared Error (RMSE)* foi de 1.04. O modelo também teve um *Mean Absolute Error (MAE)* de 0.79 e um *Mean Absolute Percentage Error (MAPE)* de 24.02%. Esses resultados indicam que o modelo *ARIMA* foi capaz de capturar alguns padrões nos dados, mas ainda apresenta uma margem significativa de erro. O *MSE* e o *RMSE* relativamente baixos sugerem que as previsões feitas pelo modelo não estão totalmente distantes dos valores reais, embora ainda haja oportunidades de melhoria. O *MAPE* de 24.02% sugere que, em média, o erro percentual entre as previsões e os valores reais é considerável.

## Resultados do RNN

A imagem 18 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *RNN* como modelo utilizado.

Figura 18 – Ocorrências Florianópolis - RNN



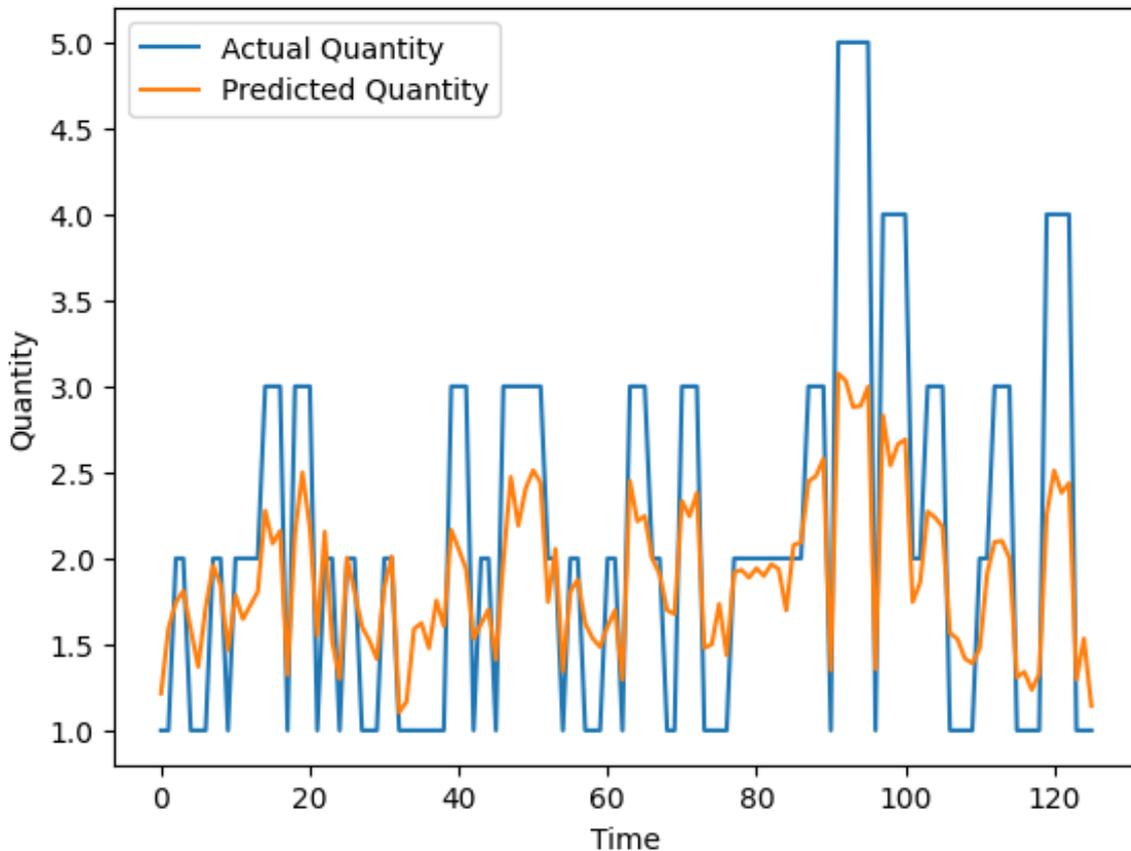
Fonte: Produzido pelo autor

O modelo *RNN* apresentou os seguintes resultados para o experimento com dados das Forças de Segurança e Salvamento. O *Mean Squared Error (MSE)* foi de 0.84, enquanto o *Root Mean Squared Error (RMSE)* foi de 0.92. O modelo também obteve um *Mean Absolute Error (MAE)* de 0.68 e um *Mean Absolute Percentage Error (MAPE)* de 41.57%. Esses resultados indicam que, embora o modelo tenha mostrado um desempenho razoável, ainda existe uma margem de erro considerável nas previsões. O *MSE* e o *RMSE* sugerem que as previsões estão relativamente próximas dos valores reais, mas os erros ainda são significativos. O *MAPE* de 41.57% indica que, em média, as previsões apresentam um erro percentual considerável, o que pode comprometer a confiança nas previsões do modelo.

## Resultados do LSTM

A imagem 19 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *LSTM* como modelo utilizado.

Figura 19 – Ocorrências Florianópolis - LSTM



Fonte: Produzido pelo autor

No modelo *LSTM*, os resultados indicam um desempenho moderado na previsão da variável alvo *Quantity*. O *Mean Squared Error (MSE)* foi de 0.536, sugerindo que, embora as previsões estejam relativamente próximas dos valores reais, há espaço para melhorias. O *Root Mean Squared Error (RMSE)* foi de 0.732, o que também demonstra uma precisão razoável, mas não ideal, em relação aos dados observados.

O *Mean Absolute Error (MAE)* foi de 0.566, refletindo que, em média, a diferença absoluta entre os valores reais e previstos foi considerável, mas ainda assim dentro de limites razoáveis. O *Mean Absolute Percentage Error (MAPE)* foi de 28.79%, o que indica que as previsões, em média, apresentaram um erro percentual de quase 29%, uma margem mais ampla de erro comparada a modelos com melhor desempenho.

A tabela 5 apresenta um comparativo detalhado dos resultados obtidos pelos diferentes modelos aplicados no experimento **Ocorrências em Florianópolis**. As métricas de avaliação, como erro médio absoluto (MAE), erro quadrático médio (MSE) e raiz do erro quadrático médio (RMSE), foram calculadas para medir a precisão e a robustez das previsões. Este comparativo visa identificar qual modelo apresenta melhor desempenho

em relação ao conjunto de dados e aos objetivos do experimento.

Tabela 5 – Resumo do desempenho dos modelos no experimento Ocorrências em Florianópolis

Experimento	Modelo	MSE	RMSE	MAE	MAPE
Dados históricos de ocorrências em Florianópolis	ARIMA	1.08	1.04	0.79	<b>24.02%</b>
	RNN	0.84	0.92	0.68	41.57%
	LSTM	<b>0.54</b>	<b>0.73</b>	<b>0.57</b>	28.79%

Esses resultados indicam que, apesar de o modelo *LSTM* ter uma capacidade aprimorada para lidar com dependências temporais em séries de dados, a precisão das previsões poderia ser melhorada.

## 4.2 FLORIANÓPOLIS COM DADOS METEOROLÓGICOS

No segundo experimento de previsão, foi mantida a estrutura original de dados do primeiro experimento, que utilizou as ocorrências registradas no *dataset* das Forças de Segurança e Salvamento, com a quantidade de registros sendo 493, mas agora com o acréscimo de informações meteorológicas associadas ao momento de cada chamada. Com essa abordagem, a inclusão de variáveis climáticas, como precipitação e umidade, visa enriquecer a base de dados e capturar o impacto potencial das condições meteorológicas nas chamadas diárias para serviços de segurança e salvamento.

O objetivo principal deste experimento é verificar se o enriquecimento do *dataset* com dados meteorológicos pode aprimorar a capacidade dos modelos em prever a demanda diária, identificando padrões adicionais que poderiam ajudar no planejamento de recursos e na alocação de equipes de forma ainda mais precisa. O treinamento desse experimento ocorreu da mesma maneira que o anterior.

### Enriquecimento INMET

Para enriquecer a análise e a previsão de eventos, utilizamos dados do *INMET* (Instituto Nacional de Meteorologia) abrangendo variáveis climáticas, como temperatura, precipitação, umidade e vento, de 2017 a 2021. Esses dados foram integrados ao *dataset* principal após padronização e tratamento, incluindo a uniformização das colunas, conversão de tipos de dados, e harmonização das datas e horários das medições. Cada registro meteorológico foi associado a uma ocorrência de segurança específica com base na data e no local, permitindo que cada ponto de ocorrência contivesse informações sobre as condições meteorológicas no momento ou nas proximidades da chamada.

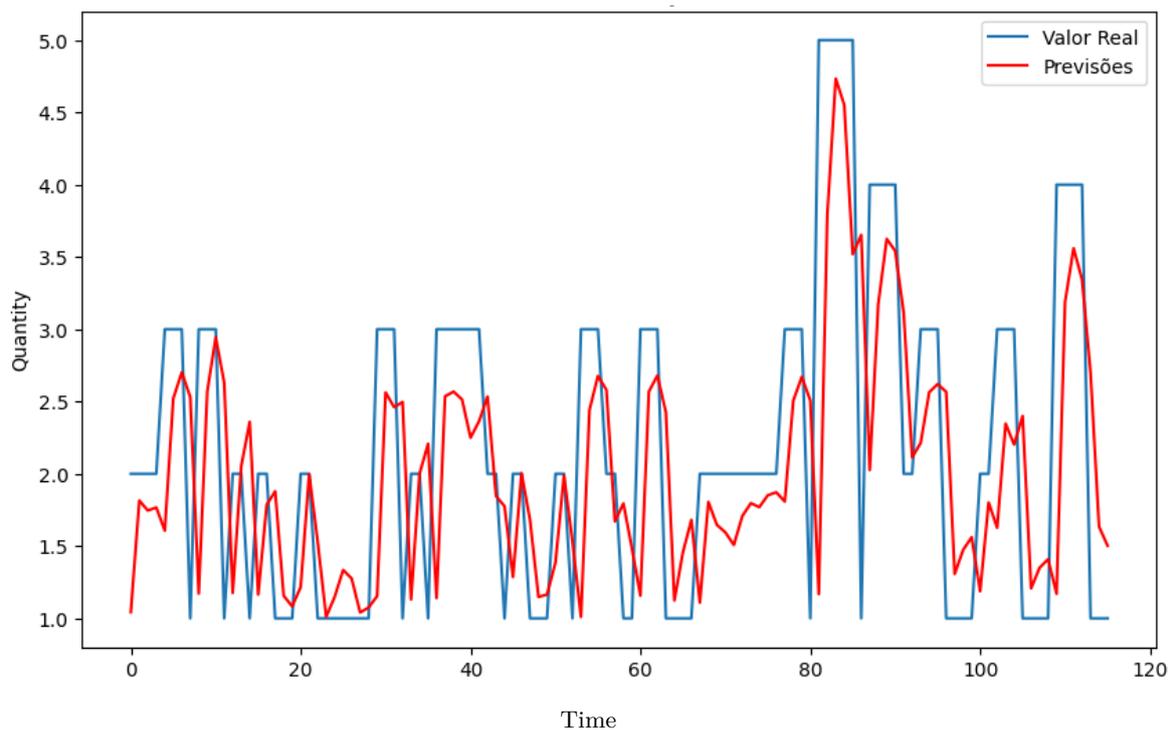
Além disso, foi possível agregar variáveis meteorológicas médias para cada dia ou hora, dependendo da granularidade dos dados, criando um contexto climático específico para cada evento. Esse enriquecimento foi realizado com base nas variáveis mais relevantes, como precipitação (chuvas), temperatura, umidade do ar e velocidade do vento, que podem influenciar diretamente a dinâmica de eventos como desastres naturais ou acidentes.

Com a finalidade de facilitar a manipulação dos dados e junção do *dataset* com as informações do *INMET*, o tempo apresentado em cada registro do *dataset* foi alterado, sendo separado em Data, Dia, Mês, Ano, além de Horário e Hora.

## Resultados do RNN

A imagem 20 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *RNN* como modelo utilizado, e o *dataset* foi enriquecido com dados meteorológicos.

Figura 20 – Ocorrências Florianópolis com dados meteorológicos - RNN



Fonte: Produzido pelo autor

No experimento com enriquecimento de dados meteorológicos utilizando o modelo *RNN*, os resultados mostram um desempenho moderado. O *Mean Squared Error (MSE)* foi de 0.9088, o que indica que o modelo não conseguiu capturar com grande precisão as variações da série temporal, embora o erro não seja extremamente alto. O *Root Mean Squared Error (RMSE)* foi de 0.953, o que é relativamente elevado, indicando que as

previsões ainda estão um pouco distantes dos valores reais.

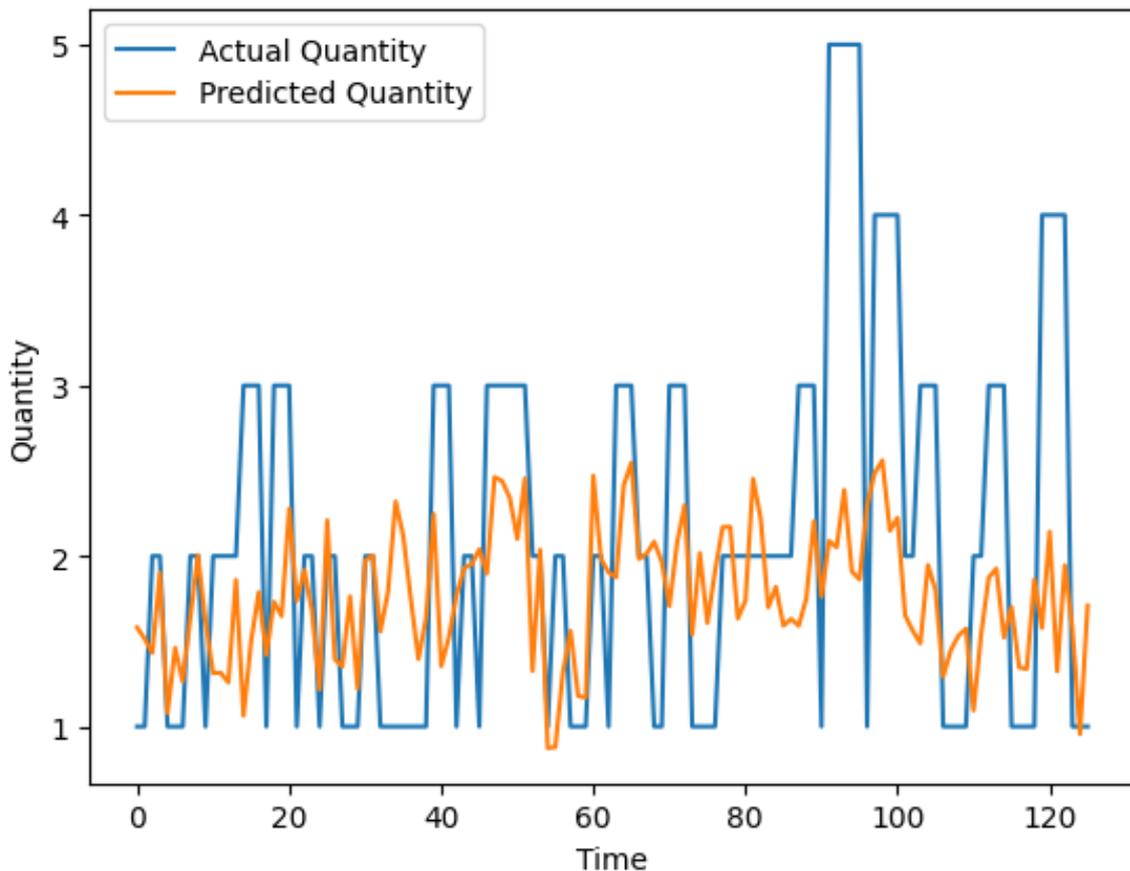
O *Mean Absolute Error (MAE)* foi de 0.702, sugerindo que, em média, o modelo cometeu um erro de cerca de 0.702 unidades nas previsões. Já o *Mean Absolute Percentage Error (MAPE)* foi de 40.21%, o que indica que, em média, as previsões apresentaram um erro percentual considerável, refletindo a dificuldade do modelo em prever com alta precisão os valores de *Quantity* ao incorporar os dados meteorológicos.

Esses resultados sugerem que, embora o modelo tenha se beneficiado dos dados meteorológicos adicionais, ainda há uma margem considerável de melhoria na capacidade do *RNN* de capturar e prever as flutuações das chamadas de emergência. O enriquecimento com dados meteorológicos não foi suficiente para alcançar um desempenho robusto.

### Resultados do LSTM

A imagem 21 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *LSTM* como modelo utilizado, e o *dataset* foi enriquecidos com dados meteorológicos.

Figura 21 – Ocorrências Florianópolis com dados meteorológicos - LSTM



Fonte: Produzido pelo autor

No experimento com enriquecimento de dados meteorológicos utilizando o modelo *LSTM*, os resultados indicam um desempenho moderado, com uma leve diferença em relação ao modelo *RNN*. O *Mean Squared Error (MSE)* foi de 1.1248, o que é relativamente alto, sugerindo que o modelo *LSTM* teve dificuldades em capturar as variações na série temporal de maneira precisa. O *Root Mean Squared Error (RMSE)* foi de 1.0606, um valor que reflete o mesmo padrão de erro observado no *MSE*, com as previsões ainda apresentando um desvio considerável em relação aos valores reais.

O *Mean Absolute Error (MAE)* foi de 0.812, o que também indica um erro médio de 0.812 unidades nas previsões feitas pelo modelo. O *Mean Absolute Percentage Error (MAPE)* foi de 40.52%, o que é relativamente alto, indicando que, em média, as previsões do modelo apresentaram um erro percentual significativo.

A tabela 6 apresenta um comparativo detalhado dos resultados obtidos pelos diferentes modelos aplicados no experimento **Ocorrências em Florianópolis com dados meteorológicos**. As métricas de avaliação, como erro médio absoluto (MAE),

erro quadrático médio (MSE) e raiz do erro quadrático médio (RMSE), foram calculadas para medir a precisão e a robustez das previsões. Este comparativo visa identificar qual modelo apresenta melhor desempenho em relação ao conjunto de dados e aos objetivos do experimento.

Tabela 6 – Resumo do desempenho dos modelos no experimento Ocorrências em Florianópolis com dados meteorológicos

Experimento	Modelo	MSE	RMSE	MAE	MAPE
Florianópolis com dados meteorológicos	RNN	<b>0.91</b>	<b>0.95</b>	<b>0.70</b>	<b>40.21%</b>
	LSTM	1.12	1.06	0.81	40.52%

Esses resultados sugerem que, assim como o *RNN*, o *LSTM*, apesar de incorporar dados meteorológicos, não foi capaz de alcançar uma precisão muito alta nas previsões de chamadas de emergência.

### 4.3 FLORIANÓPOLIS COM DADOS DE ÁREAS DE RISCO

No terceiro experimento, foi mantida a estrutura dos dados do primeiro experimento, com a quantidade de registros sendo 493, e foram adicionados dados de áreas de risco associadas ao período de tempo de cada chamada. Esse enriquecimento buscou capturar o impacto de regiões mais propensas a eventos críticos, como inundações e deslizamentos, que podem influenciar a demanda por serviços de segurança e salvamento.

O objetivo deste experimento é investigar se a inclusão dos dados de áreas de risco melhora a precisão das previsões, possibilitando uma análise mais completa dos fatores que influenciam o volume de chamadas diárias. Assim, espera-se que o modelo resultante possa oferecer *insights* ainda mais detalhados para o planejamento e a distribuição de recursos de emergência. O treinamento desse experimento ocorreu da mesma maneira que o anterior.

#### Enriquecimento com Informações Geoespacial

O processo de enriquecimento dos dados do *dataframe* foi realizado com o objetivo de associar informações geográficas específicas a cada ocorrência registrada em Florianópolis, permitindo uma análise mais detalhada do contexto de risco e vulnerabilidade. Para isso, foram utilizados diversos *shapefiles* que contêm dados espaciais sobre diferentes tipos de suscetibilidade, como bacias hidrográficas, enxurradas, inundações e movimentos de massa, obtidos de fontes relacionadas ao monitoramento ambiental e de desastres.

Inicialmente, os dados de ocorrências registrados no *dataframe* foram transformados em um formato geoespacial, permitindo associá-los a um sistema de coordenadas específico,

adequado para a análise geoespacial. Esse processo envolveu a conversão das coordenadas de latitude e longitude das ocorrências para um sistema de referência de coordenadas (CRS) compatível com os dados geográficos dos *shapefiles*, o que garantiu que as análises de sobreposição espacial entre os pontos de ocorrência e as áreas de risco fossem realizadas de maneira precisa.

Após essa transformação, foi atribuído a cada ponto de ocorrência uma classificação de risco, proveniente de duas fontes principais: as bacias hidrográficas e as áreas susceptíveis a movimentos de massa. Esses tipos de risco foram selecionados por serem diretamente relevantes para a segurança da população, dado que as ocorrências de acidentes podem estar fortemente associadas a características geográficas, como proximidade de áreas de risco de inundação ou escorregamentos de terra.

O primeiro passo foi classificar as ocorrências com base nas áreas geográficas delimitadas nos *shapefiles* de Suscetibilidade de Bacias e Suscetibilidade Movimento De Massa. Para cada ponto de ocorrência, foi verificado se ele estava localizado dentro de uma das áreas de risco delimitadas pelos polígonos presentes nesses *shapefiles*. Essa análise envolveu a verificação espacial de cada ponto com relação aos polígonos, atribuindo a cada ocorrência a "classe" de risco correspondente à área onde o ponto se encontrava.

Se a ocorrência se encontrasse dentro de uma área de bacia ou de movimento de massa, o valor correspondente à classe de risco dessa área foi atribuído ao ponto. Por exemplo, se uma ocorrência estivesse dentro de uma bacia de risco elevado, o ponto receberia a classificação associada a essa bacia. Da mesma forma, se estivesse dentro de uma área de risco de movimento de massa, a classificação relacionada a esse risco seria atribuída.

Em alguns casos, pode ter ocorrido que uma ocorrência não estivesse diretamente dentro de uma área delimitada por um polígono de risco, resultando em valores ausentes nas colunas de classificação de risco. Para lidar com esses casos, foi implementado um processo de preenchimento desses valores ausentes com a classificação mais próxima. Esse preenchimento foi realizado com base na distância entre a ocorrência e os polígonos de risco. Para cada ocorrência com valores ausentes, foi calculada a distância para as áreas de risco mais próximas, e a classificação do polígono mais próximo foi atribuída àquela ocorrência.

Esse método de preenchimento foi realizado para ambas as classificações de risco: bacias e movimento de massa. Dessa forma, mesmo que uma ocorrência não estivesse localizada dentro de uma área de risco específica, ela foi associada à área mais próxima, garantindo que todos os pontos tivessem uma classificação de risco associada.

Uma vez realizadas as classificações e preenchimentos, o *dataframe* enriquecido foi preparado para visualização e análise. A adição dessas informações geoespaciais e de risco proporcionou uma base de dados mais robusta, permitindo não apenas análises quantitativas, mas também visuais. A visualização das áreas de risco sobrepostas ao mapa

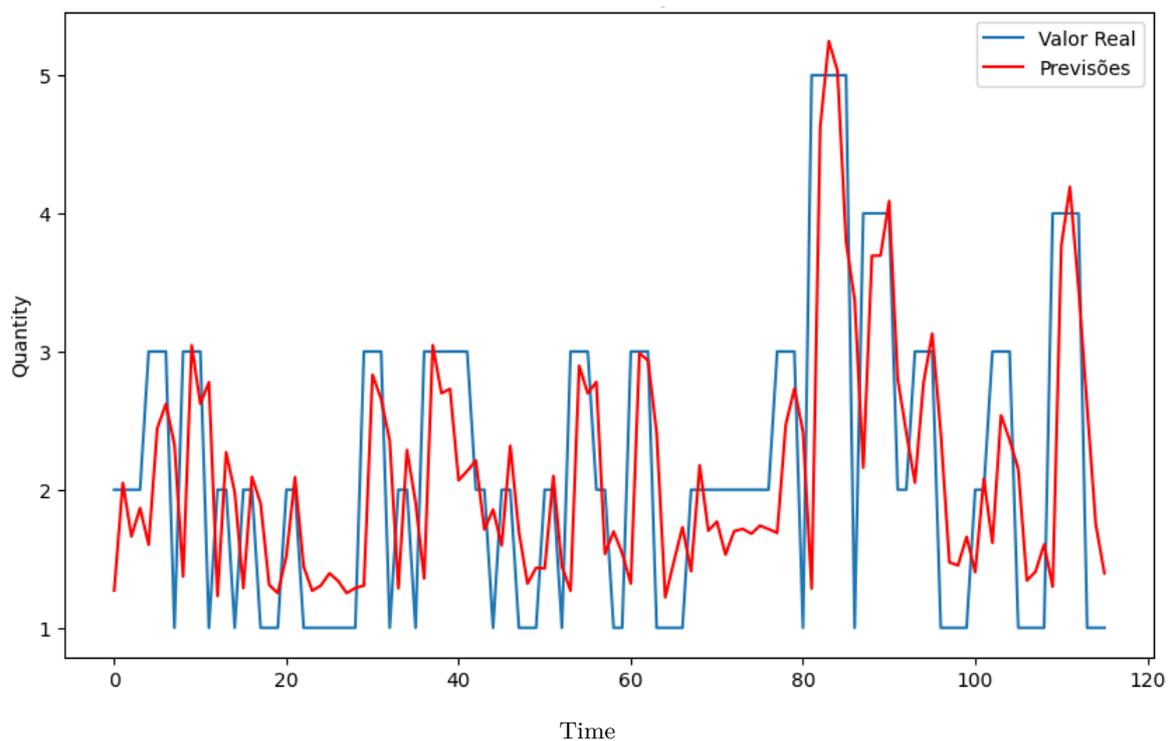
de ocorrências, por exemplo, facilita a identificação de padrões espaciais de risco e pode ser útil para decisões estratégicas de planejamento urbano, gestão de emergências e alocação de recursos de forma mais eficaz.

Além disso, foi possível realizar comparações e integrar os dados dos diferentes *shapefiles*, criando uma visão mais completa e detalhada das vulnerabilidades do município. A combinação dessas informações geográficas com os dados históricos das ocorrências oferece uma base rica para futuras análises preditivas e de mitigação de riscos.

## Resultados do RNN

A imagem 22 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *RNN* como modelo utilizado, e o *dataset* foi enriquecidos com dados de áreas de risco.

Figura 22 – Ocorrências Florianópolis com dados de áreas de risco - RNN



Fonte: Produzido pelo autor

No terceiro experimento, que envolveu o modelo *RNN* com o adicional de áreas de risco sem dados meteorológicos, os resultados mostram uma melhoria significativa em relação aos experimentos anteriores. O *Mean Squared Error (MSE)* foi de 0.7657, indicando um erro quadrático médio menor, o que sugere que o modelo conseguiu capturar melhor os padrões da série temporal. O *Root Mean Squared Error (RMSE)* foi de 0.8751, um valor

mais baixo do que o registrado nos experimentos anteriores, indicando que as previsões estavam mais próximas dos valores reais.

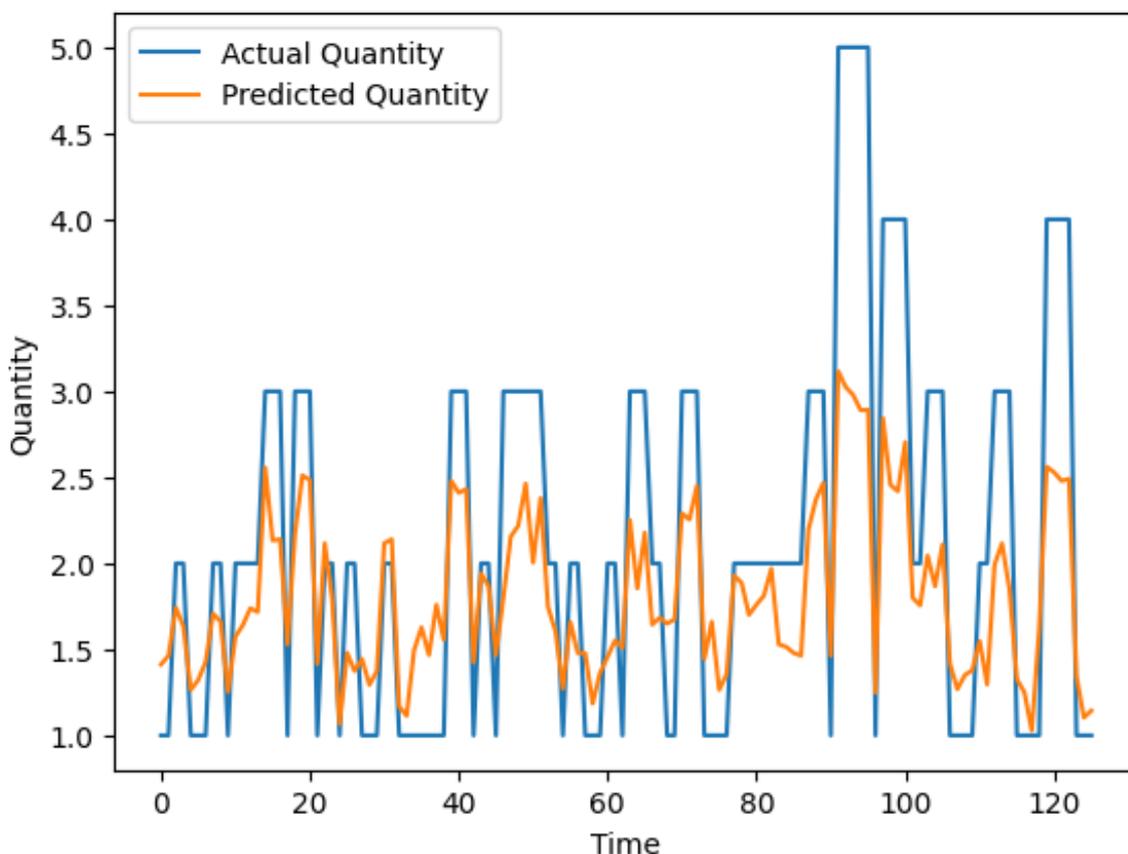
O *Mean Absolute Error (MAE)* foi de 0.6387, mostrando uma redução no erro absoluto médio das previsões, em comparação aos experimentos anteriores. Já o *Mean Absolute Percentage Error (MAPE)* foi de 38.70%, o que também indica uma melhoria na acurácia das previsões, pois o erro percentual ficou abaixo de 40

Esses resultados sugerem que a inclusão de dados sobre as áreas de risco no modelo *RNN* contribuiu positivamente para a precisão das previsões, mesmo sem o enriquecimento com dados meteorológicos. O modelo foi capaz de ajustar melhor suas previsões ao considerar a localização e os riscos associados às ocorrências, o que destaca a relevância de incorporar informações geográficas para aprimorar a previsão de demandas emergenciais.

### **Resultados do LSTM**

A imagem 23 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *LSTM* como modelo utilizado, e o *dataset* foi enriquecidos com dados de áreas de risco.

Figura 23 – Ocorrências Florianópolis com dados de áreas de risco - LSTM



Fonte: Produzido pelo autor

No terceiro experimento, com o modelo *LSTM* e a inclusão de áreas de risco sem dados meteorológicos, os resultados indicam uma performance de previsão robusta. O *Mean Squared Error (MSE)* foi de 0.5514, o que representa uma redução significativa no erro quadrático médio em relação aos modelos anteriores, sugerindo que o modelo *LSTM* conseguiu captar bem os padrões dos dados. O *Root Mean Squared Error (RMSE)* foi de 0.7426, um valor relativamente baixo, o que reforça a precisão das previsões, com uma variação menor em comparação com os dados reais.

O *Mean Absolute Error (MAE)* foi de 0.5900, indicando que o modelo conseguiu minimizar o erro absoluto nas previsões. O *Mean Absolute Percentage Error (MAPE)* foi de 28.53%, mostrando que o modelo apresentou uma precisão considerável nas previsões, com um erro percentual abaixo de 30

A tabela 7 apresenta um comparativo detalhado dos resultados obtidos pelos diferentes modelos aplicados no experimento **Ocorrências em Florianópolis com dados de áreas de risco**. As métricas de avaliação, como erro médio absoluto (MAE), erro quadrático médio (MSE) e raiz do erro quadrático médio (RMSE), foram calculadas

para medir a precisão e a robustez das previsões. Este comparativo visa identificar qual modelo apresenta melhor desempenho em relação ao conjunto de dados e aos objetivos do experimento.

Tabela 7 – Resumo do desempenho dos modelos no experimento Ocorrências em Florianópolis com dados de áreas de risco

Experimento	Modelo	MSE	RMSE	MAE	MAPE
Florianópolis com dados de áreas de risco	RNN	0.76	0.87	0.64	38.70%
	LSTM	<b>0.55</b>	<b>0.74</b>	<b>0.59</b>	<b>28.53%</b>

Esses resultados indicam que o modelo *LSTM*, ao incorporar dados de áreas de risco, conseguiu melhorar a previsão de ocorrências, mostrando-se mais eficaz do que o modelo *RNN* no mesmo experimento. A introdução das áreas de risco parece ter proporcionado uma maior precisão nas previsões, indicando que fatores geográficos podem ter um impacto significativo nas demandas emergenciais.

#### 4.4 FLORIANÓPOLIS COM DADOS METEOROLÓGICOS E DE ÁREAS DE RISCO

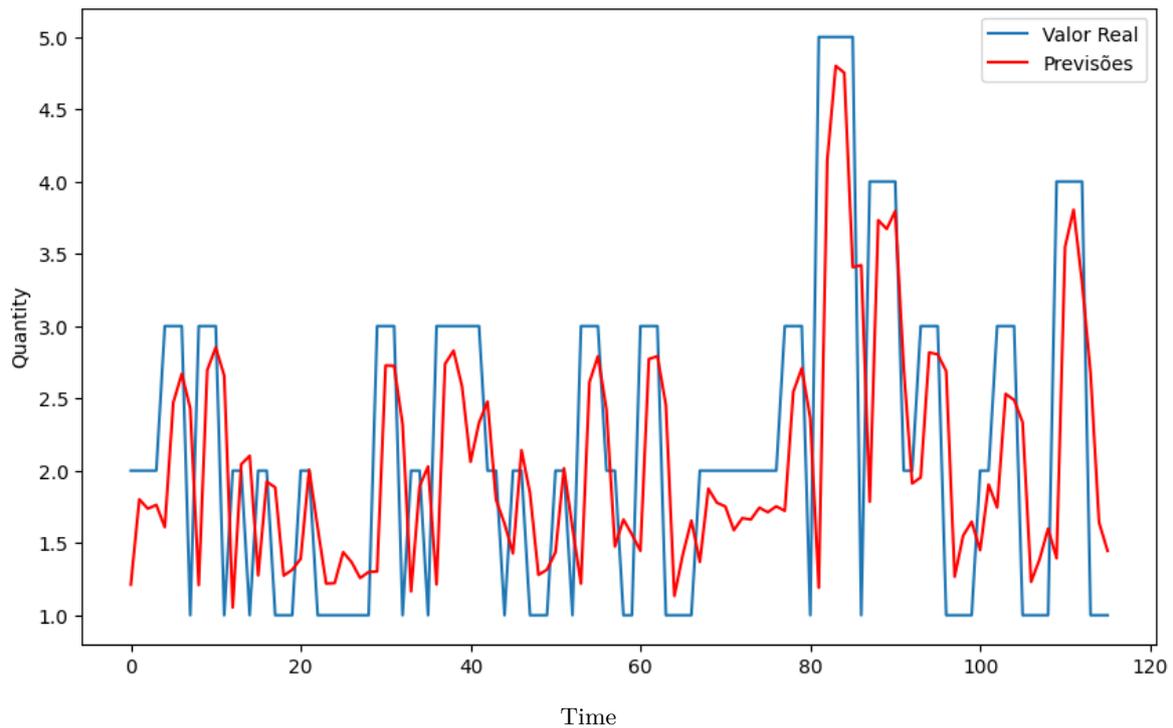
No quarto experimento, foi mantida a estrutura dos dados do primeiro segundo, que incluía informações meteorológicas, e adicionados dados de áreas de risco associadas ao período de tempo de cada chamada. O objetivo deste experimento é investigar se a inclusão dos dados de áreas de risco em conjunto com dados meteorológicos melhora a precisão das previsões. O *dataframe* contém 493 registros, sendo ele enriquecido com colunas cadastrando os riscos das ocorrências e dados meteorológicos adicionais.

O objetivo desse experimento é avaliar se o enriquecimento do conjunto de dados com informações de áreas de risco, aliado aos dados meteorológicos, contribui para melhorar a capacidade preditiva dos modelos em relação à demanda por chamadas emergenciais.

##### Resultados do RNN

A imagem 24 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *RNN* como modelo utilizado, e o *dataset* foi enriquecidos com dados meteorológicos e dados de áreas de risco.

Figura 24 – Ocorrências Florianópolis com dados meteorológicos e de áreas de risco - RNN



Fonte: Produzido pelo autor

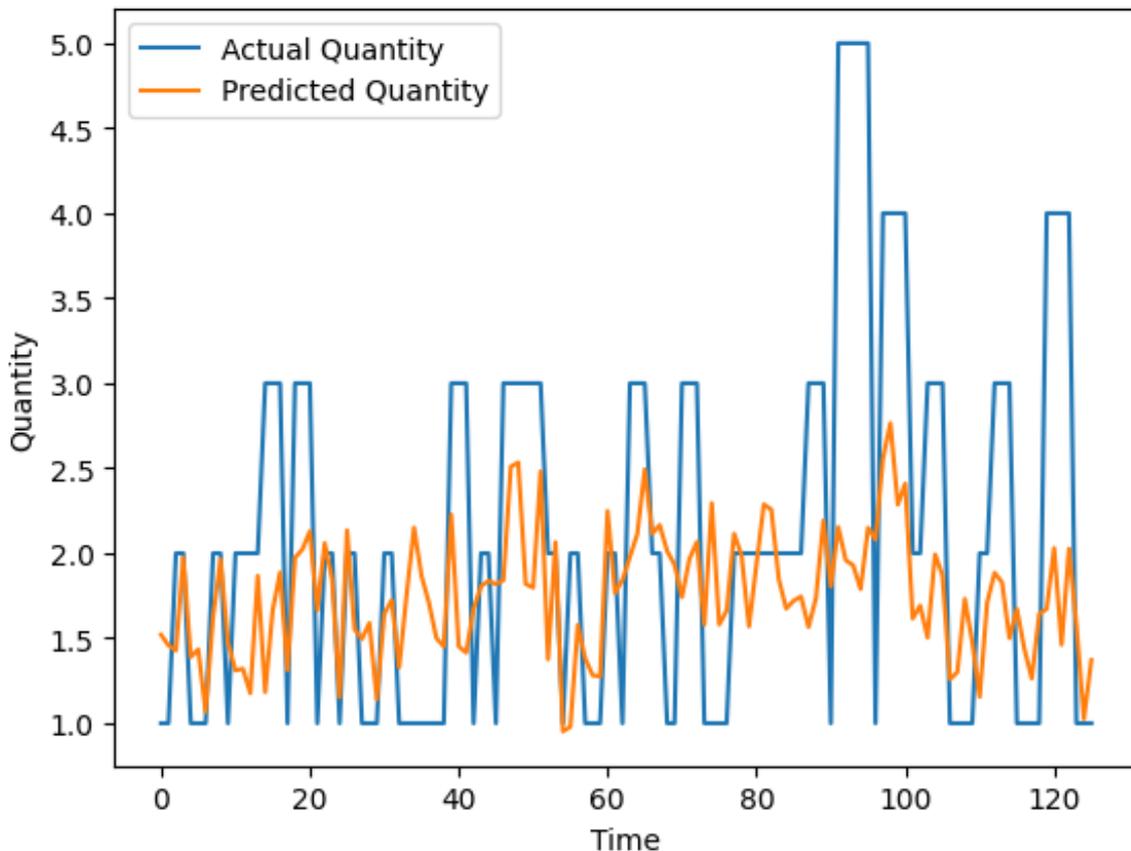
No quarto experimento, com o modelo *RNN* e o enriquecimento tanto de dados meteorológicos quanto de áreas de risco, os resultados indicam um desempenho preditivo razoável, com algumas melhorias em comparação com os experimentos anteriores. O *Mean Squared Error (MSE)* foi de 0.8158, o que demonstra uma boa capacidade de modelagem, mas ainda com margem para ajustes. O *Root Mean Squared Error (RMSE)* foi de 0.9032, o que indica uma variação aceitável entre os valores previstos e os reais, embora o erro quadrático ainda seja significativo.

O *Mean Absolute Error (MAE)* foi de 0.6571, indicando que o modelo conseguiu prever razoavelmente as ocorrências, mas com um erro absoluto considerável. O *Mean Absolute Percentage Error (MAPE)* foi de 39.19%, o que sugere que, apesar de algum progresso, ainda há espaço para melhorias na precisão das previsões, especialmente considerando que o erro percentual está acima de 30%.

### Resultados do LSTM

A imagem 25 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *LSTM* como modelo utilizado, e o *dataset* foi enriquecidos com dados meteorológicos e dados de áreas de risco.

Figura 25 – Ocorrências Florianópolis com dados meteorológicos e de áreas de risco - LSTM



Fonte: Produzido pelo autor

No quarto experimento, com o modelo *LSTM* e o enriquecimento tanto de dados meteorológicos quanto de áreas de risco, os resultados mostram um desempenho que ainda está dentro de uma faixa aceitável, mas com oportunidades de melhoria. O *Mean Squared Error (MSE)* foi de 1.0783, o que indica que o modelo conseguiu capturar alguns padrões dos dados, embora ainda haja uma diferença considerável entre as previsões e os valores reais.

O *Root Mean Squared Error (RMSE)* foi de 1.0384, um valor relativamente alto, sugerindo que o modelo tem certa dificuldade em prever com precisão as ocorrências, embora o erro não seja tão expressivo quanto em experimentos anteriores. O *Mean Absolute Error (MAE)* foi de 0.7853, indicando que, em média, as previsões se desviaram por cerca de 0.785 em relação aos valores reais, o que é razoável, mas ainda pode ser aprimorado.

O *Mean Absolute Percentage Error (MAPE)* foi de 38.16%, o que, embora seja um pouco mais baixo que o valor obtido no modelo *RNN*, ainda sugere que o modelo *LSTM* tem margem para uma maior acuracidade. Esse erro percentual está em um nível

moderado, o que indica que o modelo pode se beneficiar de ajustes em sua arquitetura ou da inclusão de outras variáveis.

A tabela 8 apresenta um comparativo detalhado dos resultados obtidos pelos diferentes modelos aplicados no experimento **Ocorrências em Florianópolis com dados meteorológicos e de áreas de risco**. As métricas de avaliação, como erro médio absoluto (MAE), erro quadrático médio (MSE) e raiz do erro quadrático médio (RMSE), foram calculadas para medir a precisão e a robustez das previsões. Este comparativo visa identificar qual modelo apresenta melhor desempenho em relação ao conjunto de dados e aos objetivos do experimento.

Tabela 8 – Resumo do desempenho dos modelos no experimento Ocorrências em Florianópolis com dados meteorológicos e de áreas de risco

Experimento	Modelo	MSE	RMSE	MAE	MAPE
Florianópolis com dados meteorológicos e dados de áreas de risco	RNN	<b>0.81</b>	<b>0.90</b>	<b>0.66</b>	39.19%
	LSTM	1.08	1.04	0.78	38.16%

Esses resultados refletem uma melhora, mas também indicam que, mesmo com o enriquecimento dos dados, o modelo *LSTM* ainda não alcançou o nível de precisão desejado.

#### 4.5 TODAS AS OCORRÊNCIAS SANTA CATARINA COM DADOS DE ÁREAS DE RISCO

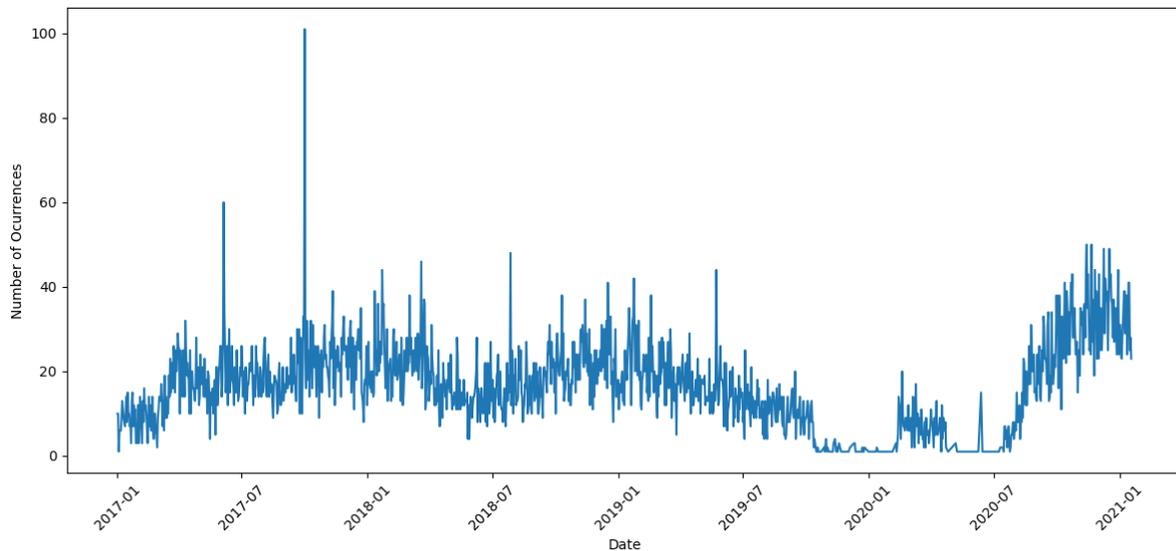
No quinto experimento, foi mantida a estrutura dos dados do terceiro experimento, que incluía dados de áreas de risco associados a cada ocorrência, entretanto o escopo dos dados foi maior, utilizando todas as ocorrências que não foram retiradas no tratamento em Santa Catarina. O *dataframe* contém 23.285 registros. Essa estrutura de dados foi mantida por ter apresentado os melhores resultados dos experimentos analisados até o momento.

O objetivo desse experimento é avaliar se a quantidade presente no conjunto de dados com informações de áreas de risco, contribui para melhorar os resultados de predição dos modelos analisados.

Após a explicação sobre a metodologia e o objetivo do quinto experimento, é fundamental incluir uma visualização das séries temporais das ocorrências em Santa Catarina. A Figura 26 exibe a evolução das ocorrências ao longo do tempo, oferecendo uma representação clara e detalhada dos dados. A utilização dessa figura proporciona uma visão intuitiva do comportamento temporal das ocorrências, permitindo identificar

padrões e tendências que são essenciais para entender a dinâmica dos dados. Além disso, a visualização facilita a comparação entre períodos de maior e menor atividade, o que pode ser crucial para avaliar a eficácia dos modelos de previsão.

Figura 26 – Série Temporal: Número de ocorrências de eventos do TIPO Salvamento/-Busca/Resgate em Santa Catarina ao longo do tempo



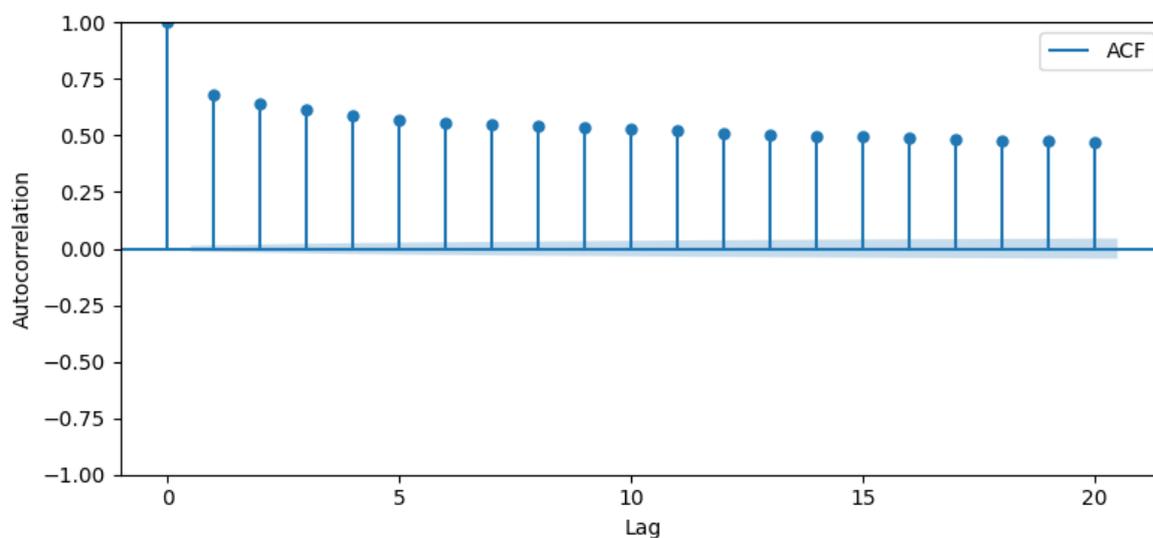
Fonte: Produzido pelo Autor

## ARIMA

Para determinar a ordem de diferenciação o método *adfuller* foi utilizado. O valor de  $d$  foi 0, pois os dados estavam estacionários quando analisados.

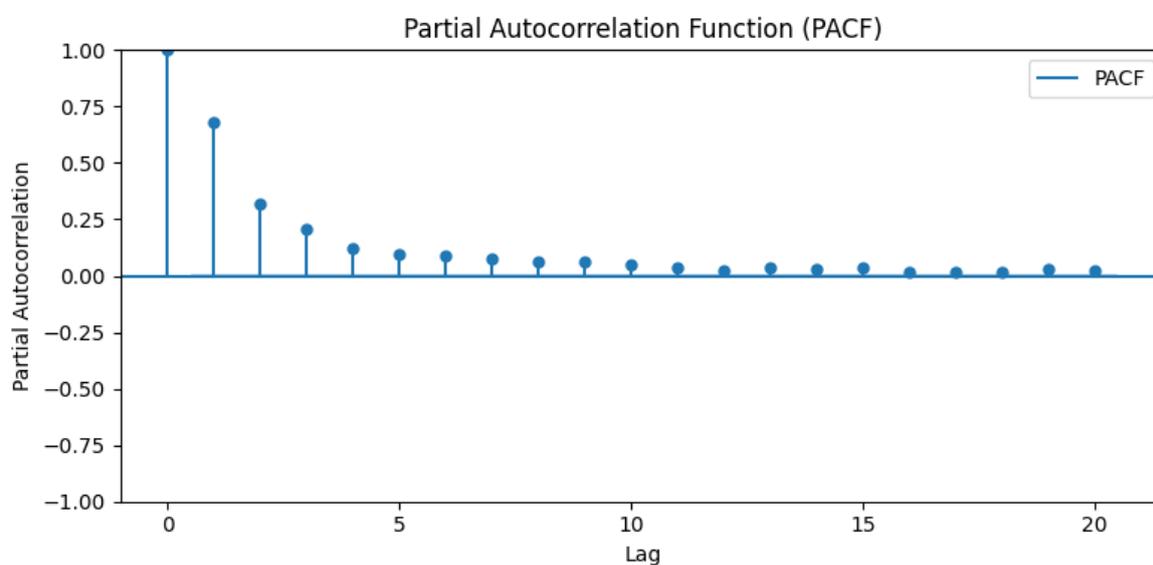
O próximo passo é determinar o valor de  $p$ , que é delimitado pela maior *lag* identificada nos *plots* de autocorrelação parcial. A partir da análise dos gráficos, pode-se inferir que o valor de  $p = 1$  é o mais adequado. Já o valor de  $q$  é definido com base no número de *lags* que ultrapassam o limite, utilizando o *plot ACF* em vez do *PACF*. Ao analisar o gráficos nas figuras 27 e 28, conclui-se que o valor ideal para  $q$  é 1.

Figura 27 – Autocorrelação (ACF) com dados de SC



Fonte: Produzido pelo Autor

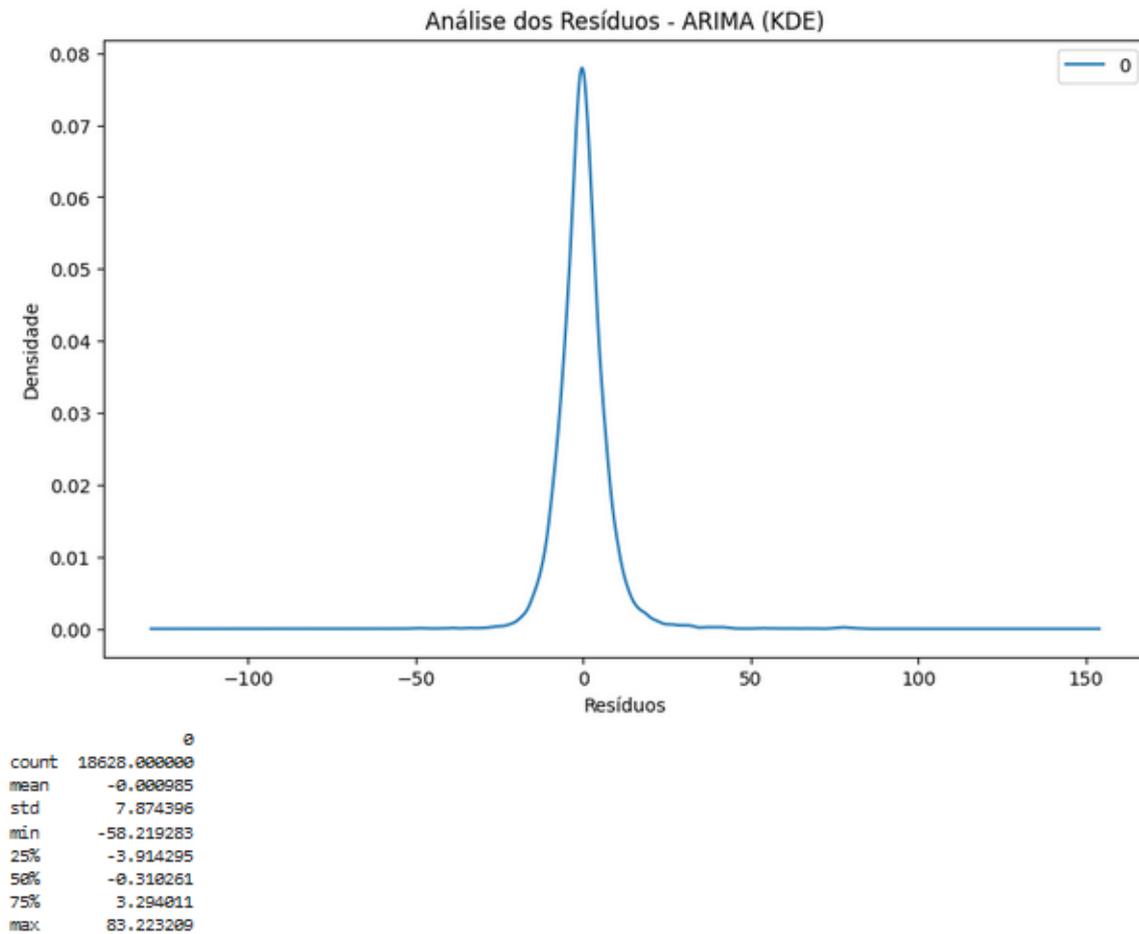
Figura 28 – Autocorrelação Parcial (PACF) com dados de SC



Fonte: Produzido pelo Autor

Em seguida, foram avaliados os resíduos para verificar a adequação do modelo aos dados. Os resultados estão ilustrados nas figuras 29.

Figura 29 – Residual dos Dados de Santa Catarina



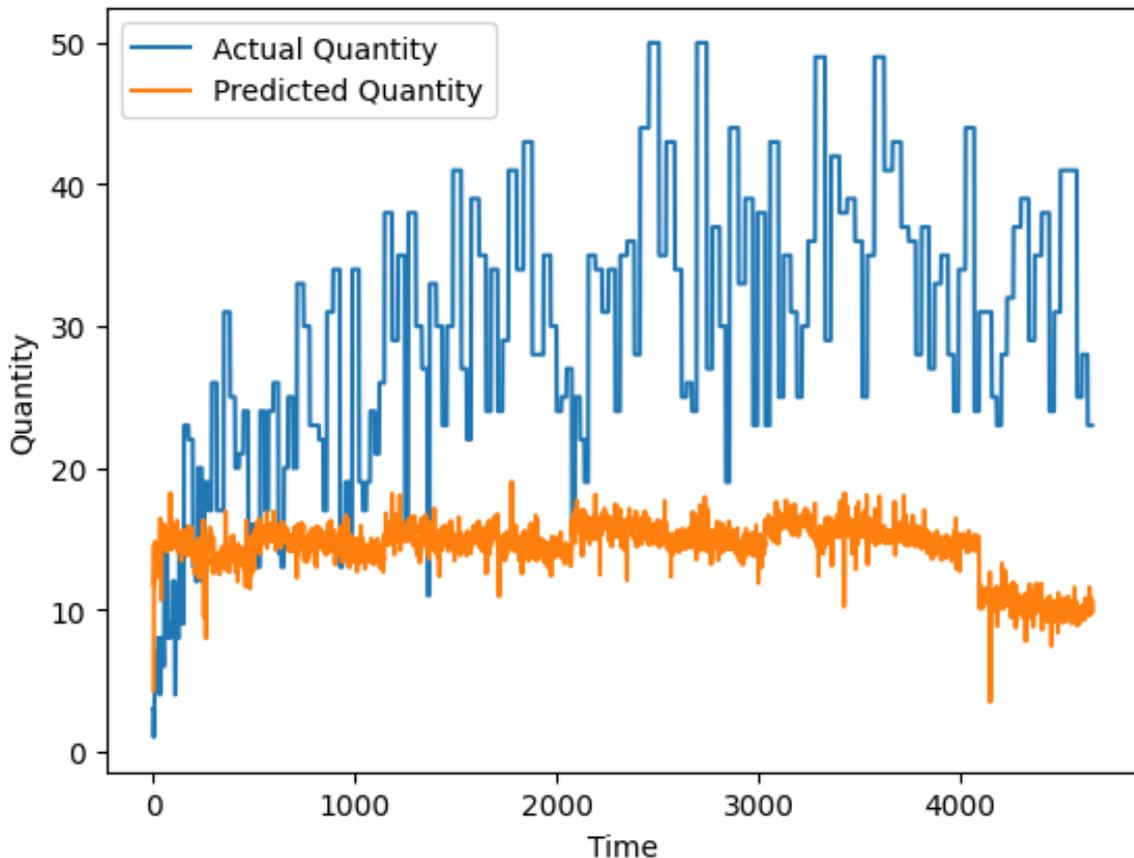
Fonte: Produzido pelo Autor

A média próxima de zero é um bom indicativo, mas o desvio padrão relativamente alto e os valores extremos nos resíduos (min e max) indicam que o modelo *ARIMA* pode não ser adequado para todos os pontos de dados, especialmente para aqueles com erros grandes.

## Resultados do ARIMA

A imagem 30 representa a previsão de quantidade de ocorrências no decorrer do tempo, sendo o *ARIMA* como modelo utilizado, e o *dataset* foi enriquecido com dados meteorológicos e dados de áreas de risco, sendo composto por ocorrências de Santa Catarina, em vez de apenas Florianópolis.

Figura 30 – Ocorrências Santa Catarina com dados de áreas de risco - ARIMA



Fonte: Produzido pelo autor

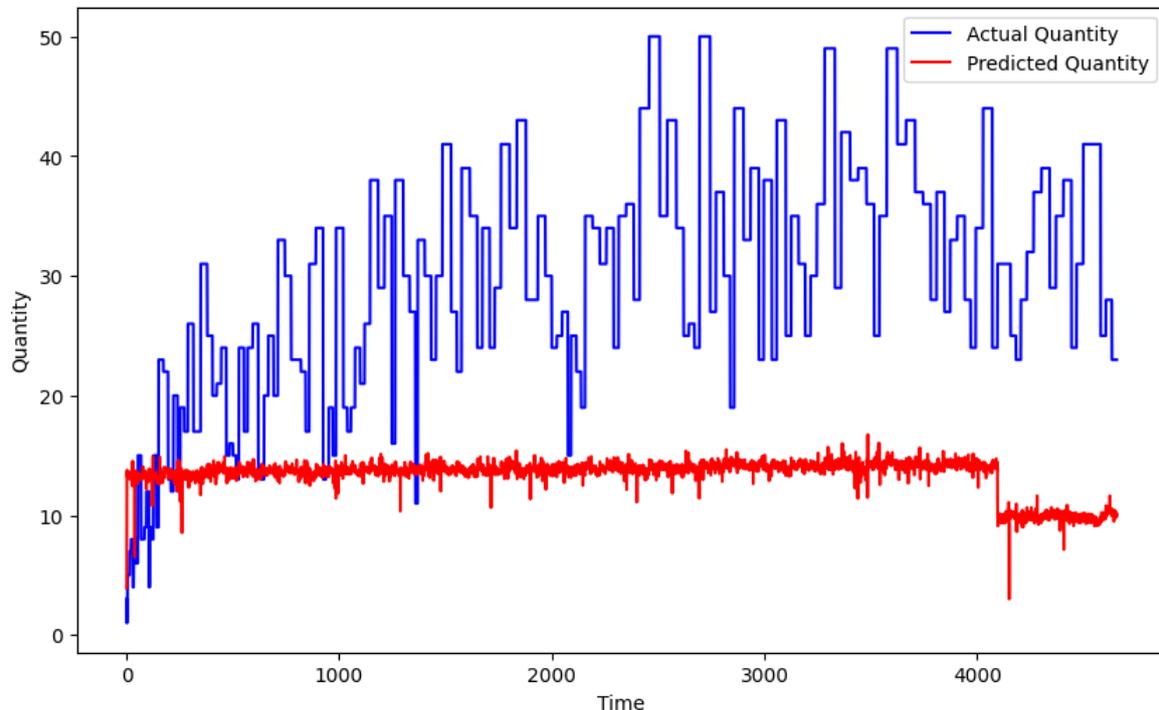
O experimento realizado, utilizando dados de ocorrências emergenciais em Santa Catarina e enriquecido com informações sobre áreas de risco, foi conduzido com o modelo *ARIMA*. Os resultados obtidos indicam o seguinte: o *Mean Squared Error (MSE)* foi de 215,64, o que mostra a média dos quadrados das diferenças entre os valores previstos e os reais; o *Root Mean Squared Error (RMSE)* foi de 14,68, refletindo a magnitude do erro médio das previsões; o *Mean Absolute Error (MAE)* foi de 12,46, sugerindo que, em média, as previsões estavam a 12,46 ocorrências do valor real; e o *Mean Absolute Percentage Error (MAPE)* foi de 36,81%, o que indica que o modelo teve um erro médio de aproximadamente 36,81% em relação aos valores reais.

Embora os resultados indiquem que o modelo *ARIMA* tenha sido capaz de capturar a tendência temporal das ocorrências emergenciais, a inclusão dos dados adicionais além das áreas de risco não gerou uma melhoria substancial na acurácia das previsões.

## Resultados do RNN

A imagem 31 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *RNN* como modelo utilizado, e o *dataset* foi enriquecido com dados meteorológicos e dados de áreas de risco, sendo composto por ocorrências de Santa Catarina, em vez de apenas Florianópolis.

Figura 31 – Ocorrências Santa Catarina com dados de áreas de risco - RNN



Fonte: Produzido pelo autor

No experimento com ocorrências de Santa Catarina, utilizando o modelo *RNN* para previsão de chamadas de emergência, o *Mean Squared Error (MSE)* foi de 383.13, indicando uma média elevada das diferenças quadráticas entre as previsões e os valores reais.

O *Root Mean Squared Error (RMSE)*, de 19.57, reflete um desvio padrão significativo dos erros, enquanto o *Mean Absolute Error (MAE)*, com valor de 17.48, demonstra que, em média, as previsões se distanciaram consideravelmente dos valores observados.

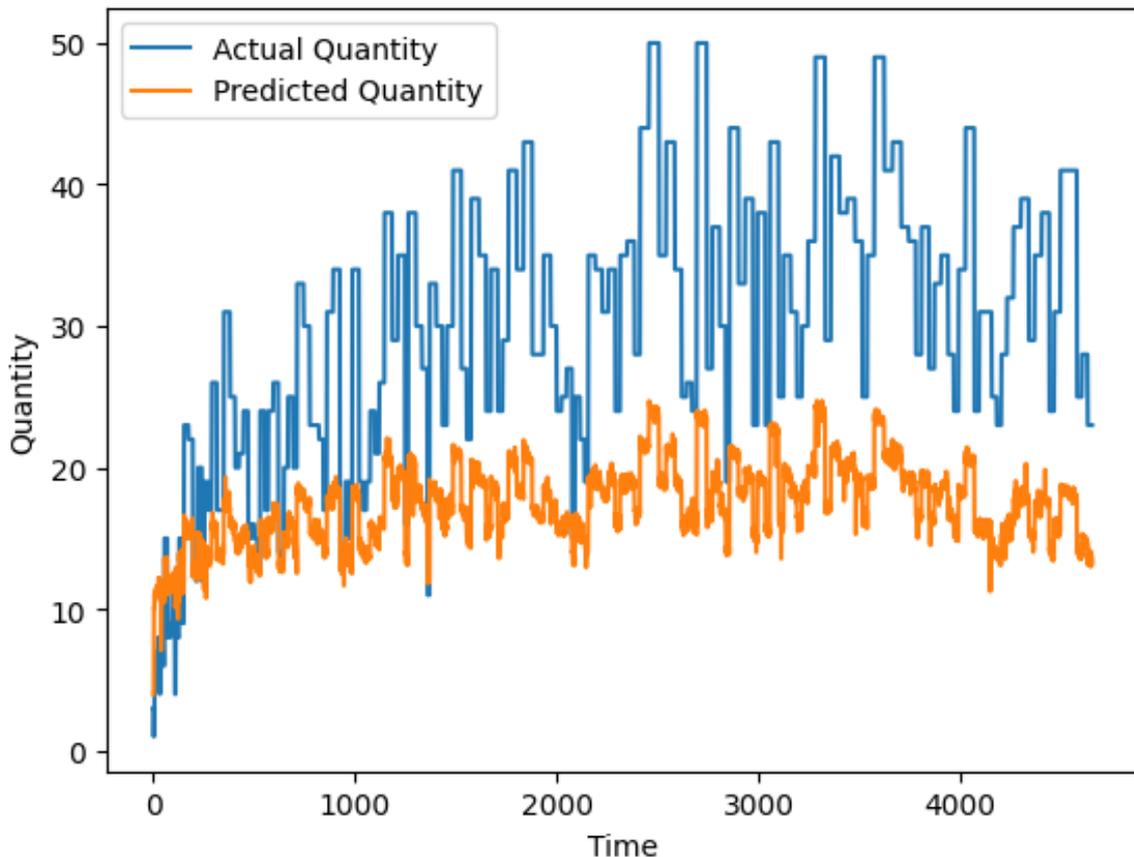
O *Mean Absolute Percentage Error (MAPE)*, de 0.54%, sugere um desvio percentual baixo em relação aos valores reais, apesar dos erros absolutos mais altos.

Esse resultado evidencia que o modelo *RNN* apresentou limitações em capturar os padrões e tendências presentes no conjunto de dados de Santa Catarina, possivelmente devido à complexidade das ocorrências.

## Resultados do LSTM

A imagem 32 representa a predição de quantidade de ocorrências no decorrer do tempo, sendo o *LSTM* como modelo utilizado, e o *dataset* foi enriquecidos com dados meteorológicos e dados de áreas de risco, sendo composto por ocorrências de Santa Catarina, em vez de apenas Florianópolis.

Figura 32 – Ocorrências Santa Catarina com dados de áreas de risco - LSTM



Fonte: Produzido pelo autor

No experimento com ocorrências de Santa Catarina, utilizando o modelo *LSTM* para previsão de chamadas de emergência, os resultados indicaram um desempenho moderado. O *Mean Squared Error (MSE)* foi de 217.61, sugerindo que as diferenças quadráticas entre as previsões e os valores reais foram mais acentuadas em comparação ao modelo *RNN*.

O *Root Mean Squared Error (RMSE)*, de 14.75, evidencia um desvio considerável dos erros em relação aos valores observados. O *Mean Absolute Error (MAE)*, de 13.30, reforça que, em média, as previsões apresentaram uma distância significativa dos valores reais.

Por outro lado, o *Mean Absolute Percentage Error (MAPE)*, de 41.48%, reflete um desvio percentual substancial em relação aos valores reais, indicando que o modelo encontrou dificuldade para capturar adequadamente as complexidades do conjunto de dados.

A tabela 9 apresenta um comparativo detalhado dos resultados obtidos pelos diferentes modelos aplicados no experimento **Todas as ocorrências Santa Catarina com dados de áreas de risco**. As métricas de avaliação, como erro médio absoluto (MAE), erro quadrático médio (MSE) e raiz do erro quadrático médio (RMSE), foram calculadas para medir a precisão e a robustez das previsões. Este comparativo visa identificar qual modelo apresenta melhor desempenho em relação ao conjunto de dados e aos objetivos do experimento.

Tabela 9 – Resumo do desempenho dos modelos no experimento Todas as ocorrências Santa Catarina com dados de áreas de risco

Experimento	Modelo	MSE	RMSE	MAE	MAPE
Santa Catarina com dados de áreas de risco	ARIMA	<b>215.64</b>	<b>14.68</b>	<b>12.46</b>	<b>36.81%</b>
	RNN	383.13	19.57	17.48	54%
	LSTM	217.61	14.75	13.30	41.48%

Esses resultados sugerem que, embora o *LSTM* tenha capacidade para modelar dependências temporais, neste experimento, sua performance foi inferior ao *RNN*, especialmente devido à maior complexidade dos dados enriquecidos com informações sobre áreas de risco.

## 4.6 DISCUSSÃO

Após a análise detalhada dos resultados obtidos nos diversos experimentos realizados, é possível identificar padrões consistentes no desempenho dos modelos de previsão utilizados (*ARIMA*, *LSTM* e *RNN*). De forma geral, o desempenho dos modelos variou conforme a complexidade dos dados fornecidos, a estratégia adotada para o treinamento e a inclusão de dados externos, como informações meteorológicas e geográficas.

A inclusão de uma tabela contendo todos os valores das métricas analisadas é fundamental para proporcionar uma visão clara e objetiva dos desempenhos dos modelos em cada experimento. Essa tabela permite a comparação direta entre as diferentes abordagens, facilitando a análise das variações nas métricas como *MSE*, *RMSE*, *MAE* e *MAPE*, e oferecendo uma referência rápida para avaliar a eficácia de cada modelo e conjunto de dados utilizado. Logo, a tabela 10 representa os diferentes resultados de cada experimento.

Tabela 10 – Resumo do desempenho dos modelos nos experimentos

Experimento	Modelo	MSE	RMSE	MAE	MAPE
Só dados históricos de ocorrências em Florianópolis	ARIMA	1.08	1.04	0.79	<b>24.02%</b>
	RNN	0.84	0.92	0.68	41.57%
	LSTM	<b>0.54</b>	<b>0.73</b>	<b>0.57</b>	28.79%
Florianópolis com dados meteorológicos	RNN	<b>0.91</b>	<b>0.95</b>	<b>0.70</b>	<b>40.21%</b>
	LSTM	1.12	1.06	0.81	40.52%
Florianópolis com dados de áreas de risco	RNN	0.76	0.87	0.64	38.70%
	LSTM	<b>0.55</b>	<b>0.74</b>	<b>0.59</b>	<b>28.53%</b>
Florianópolis com dados meteorológicos e dados de áreas de risco	RNN	<b>0.81</b>	<b>0.90</b>	<b>0.66</b>	39.19%
	LSTM	1.08	1.04	0.78	<b>38.16%</b>
Santa Catarina com dados de áreas de risco	ARIMA	<b>215.64</b>	<b>14.68</b>	<b>12.46</b>	<b>36.81%</b>
	RNN	383.13	19.57	17.48	54%
	LSTM	217.61	14.75	13.30	41.48%

A tabela 10 apresenta as métricas de desempenho dos modelos *ARIMA*, *RNN* e *LSTM* aplicados a diferentes recortes de dados, permitindo uma análise comparativa sobre sua eficácia em prever a quantidade de eventos emergenciais. No contexto de Florianópolis com dados históricos, o modelo *LSTM* destaca-se como o mais eficiente, apresentando os menores valores de *MSE* (0.54), *RMSE* (0.73) e *MAE* (0.57), além de um *MAPE* de 28.79%, evidenciando sua capacidade de capturar padrões temporais de maneira mais precisa em séries temporais complexas. O *ARIMA*, embora seja um modelo tradicional, apresentou métricas superiores ao *RNN* em termos de precisão, indicando que, para dados históricos simples, ele ainda é uma escolha competitiva.

Ao incluir dados meteorológicos no recorte de Florianópolis, observa-se uma mudança no desempenho. O *LSTM*, que anteriormente liderava, apresentou um aumento nos erros (*MSE* de 1.12 e *MAPE* de 40.52%), enquanto o *RNN* manteve resultados consistentes, mas sem superar o desempenho em dados históricos. Essa piora pode sugerir que os dados meteorológicos introduziram ruído ou não foram suficientemente significativos para melhorar o ajuste dos modelos. Por outro lado, ao utilizar dados de áreas de risco, tanto o *RNN* quanto o *LSTM* mostraram ganhos significativos, com o *LSTM* novamente se destacando (*MSE* de 0.55 e *MAPE* de 28.53%), confirmando a eficácia do modelo em integrar variáveis espaciais com séries temporais.

Nos experimentos que abrangem todo o estado de Santa Catarina, os modelos tiveram desempenhos piores, indicando dificuldades em capturar padrões complexos com a mesma precisão. Um fator que deve ser levado em conta, é a mudança de padrão na série temporal, onde a porcentagem utilizada para testes, teve uma mudança de padrão em relação ao restante dos dados históricos, isso pode ser observado na figura 26. Em contrapartida a porcentagem utilizada para testes nos experimentos anteriores tiveram padrão similar sendo repetido, sendo ilustrado na figura 13.

### **Impacto da Inclusão de Dados Meteorológicos e Geográficos**

A adição de dados meteorológicos e informações de áreas de risco influenciou significativamente os resultados, mas nem sempre de maneira positiva. Em muitos casos, como nos experimentos que incorporaram apenas dados meteorológicos, houve um aumento considerável no *MAPE* e nas demais métricas de erro, indicando que os modelos tiveram dificuldade em integrar essas informações de forma eficiente. Isso pode ser atribuído à complexidade adicional introduzida pelos novos dados, que pode não ter sido totalmente capturada pelos modelos em sua configuração atual.

Por outro lado, a inclusão de dados de áreas de risco trouxe melhorias perceptíveis, especialmente no modelo *LSTM*. No experimento correspondente, o *LSTM* apresentou um *MAPE* de 28,53%, indicando uma redução nos erros de previsão e maior robustez nas análises. Esses resultados sugerem que os dados geográficos têm um impacto mais direto na previsão de ocorrências emergenciais, talvez devido à sua relação mais intrínseca com as chamadas de emergência analisadas.

## 5 CONCLUSÕES

O objetivo do presente trabalho foi a utilização de diferentes métodos de predição de eventos, afim de obter predições da quantidade de ocorrências emergenciais futuras, utilizando dados das Forças de Segurança e Salvamento de Santa Catarina, além de dados auxiliares do *INMET* e de áreas de risco para melhores resultados. Nesse contexto, foram escolhidos três métodos com ótimos resultados em diversas pesquisas, nos quais foram *ARIMA*, *RNN* e *LSTM*. Além disso foi feita uma pesquisa a respeito do estado da arte referente a *machine learning*, *data mining* e previsão de eventos futuros, com isso foi possível ter um embasamento teórico para realizar o presente trabalho.

Por meio das pesquisas realizadas, e das informações presentes no trabalho, é possível inferir que os métodos de tomada de decisão das Forças de Segurança e Salvamento podem ser melhoradas utilizando técnicas de predição para melhor distribuição de recursos. Com aprendizado de máquina, vários padrões são analisados, os quais são difíceis de visualizar e definir utilizando métodos comuns de classificação, logo o objetivo desse trabalho é válido e pode se tornar útil, quando utilizado em campo.

Os resultados dos experimentos realizados, embora interessantes, indicam que há espaço significativo para melhorias. Durante a avaliação dos modelos *ARIMA*, *RNN* e *LSTM*, foi possível perceber que a inclusão de dados adicionais, como informações geográficas e meteorológicas, não contribuiu significativamente para a melhoria da acurácia das previsões. Uma abordagem futura poderia envolver o desenvolvimento de métodos híbridos, combinando diferentes tipos de modelos, como *ARIMA* com redes neurais, para aproveitar as forças de cada técnica e, assim, gerar previsões mais robustas e precisas.

Outro aspecto que pode ser explorado em trabalhos futuros é a melhoria da memória e processamento, superando as limitações de memória e armazenamento enfrentadas neste trabalho. Embora o volume de dados seja considerável, com informações de todo o estado de Santa Catarina, as restrições de RAM e espaço no disco dificultaram a experimentação com grandes volumes de dados. Esses desafios impactaram a realização de alguns testes, pois a capacidade de processamento da máquina utilizada foi insuficiente para lidar com a quantidade e complexidade dos dados. No entanto, em ambientes com maior capacidade de processamento, como servidores com maior poder computacional ou soluções em nuvem com uma limitação menor, seria possível trabalhar com esse mesmo volume de dados de forma mais eficiente, permitindo a realização de experimentos mais robustos e a obtenção de resultados mais precisos.

Adicionalmente, uma análise mais aprofundada dos dados temporais e geoespaciais pode ser realizada, incorporando técnicas de séries temporais multivariadas e redes neurais convolucionais ou recorrentes avançadas para capturar padrões de longo prazo e comportamentos regionais específicos. A integração de outras fontes de dados, como dados de tráfego, meteorológicos em tempo real, e informações de outros órgãos de segurança,

também pode enriquecer a capacidade preditiva do sistema.

Portanto, os próximos passos envolvem o aprimoramento dos modelos utilizados, explorando novas fontes de dados e técnicas de otimização para superar as dificuldades encontradas, com o objetivo de criar um sistema de previsão robusto e eficiente.

## REFERÊNCIAS

- BEJARANO, Gissella *et al.* A Deep Learning based Emergency Resolution Time Prediction System. IEEE, 2020. DOI: 10.1109/iThings-GreenCom-CPSCoM-SmartData-Cybermatics50389.2020.00090.
- BOHM, Ivo Guilherme. **Antecipação de Emergências Utilizando Técnicas Baseadas em Séries Temporais e Aprendizado de Máquina**. 2022. F. 43. Monografia (Trabalho de Conclusão de Curso) – Faculdade de Ciências da Computação, Universidade Federal de Santa Catarina, Santa Catarina.
- C., Yu *et al.* A COVID-19 Pandemic Artificial Intelligence-Based System With Deep Learning Forecasting and Automatic Statistical Data Acquisition: Development and Implementation Study. **J Med Internet Res**, J Med Internet Res, 2021.
- CHAKRABORTY, Tanujit; GHOSH, Indrajit. Real-time forecasts and risk assessment of novel coronavirus (COVID-19) cases: A data-driven analysis. **Chaos, Solitons Fractals**, Chaos, Solitons Fractals, v. 135, 2020.
- CORTEZ, Bitzel *et al.* An architecture for emergency event prediction using LSTM recurrent neural networks. **Expert Systems with Applications**, Elsevier, v. 97, 2018. DOI: 10.1016/j.eswa.2017.12.037.
- GADU *et al.* ARIMAX and ARIMA models for nowcasting unemployment rate in Ghana using Google trends. **Journal of Electrical Systems and Inf Technol**, Springer, v. 10, 2023. DOI: 110.1007/978-3-319-40973-3\_5.
- GALLAGHER, C.V.; BRUTON, K.; O’SULLIVAN, D.T.J. (2016). Utilising the Cross Industry Standard Process for Data Mining to Reduce Uncertainty in the Measurement and Verification of Energy Savings. **International Conference on Data Mining and Big Data**, Springer, v. 9714, 2016. DOI: 10.1007/978-3-319-40973-3\_5.
- GHOJOGH, Benyamin; GHODSI, Ali. **Recurrent Neural Networks and Long Short-Term Memory Networks: Tutorial and Survey**. [*S.l.: s.n.*], 2023. arXiv: 2304.11461 [cs.LG]. Disponível em: <https://arxiv.org/abs/2304.11461>.
- HYNDMAN, R.J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. [*S.l.: s.n.*], 2018. v. 2.
- IBM. **CRISP-DM Help Overview**. [*S.l.: s.n.*], 2021. <https://www.ibm.com/>. Disponível em: <https://www.ibm.com/docs/en/spss-modeler/18.2.0?topic=dm-crisp-help-overview>.
- MUKHOPADHYAY, Ayan *et al.* A Review of Emergency Incident Prediction, Resource Allocation, and Dispatch Models. **arXiv**, Elsevier, 2020.

NAVARRO, Juan Miguel *et al.* Sound Levels Forecasting in an Acoustic Sensor Network Using a Deep Neural Network. **sensors**, MDPI, 2020. DOI: 10.3390/s20030903.

RAMASWAMI, M.; BHASKARAN, R. A CHAID Based Performance Prediction Model in Educational Data Mining. **International Journal of Computer Science Issues**, v. 7, 2010. DOI: 10.48550/arXiv.1002.1144.

SANTOS, Thiago Rodrigues dos; SANTOS, Thais Rodrigues Dos. ANÁLISE DA ATUAÇÃO DO GRUPO DE AÇÕES COORDENADAS (GRAC) DE BARRA VELHA NO INCÊNDIO FLORESTAL DE 2020. **Ignis**, Ignis, 2021.

SCHRÖER, Christoph; KRUSE, Felix; GÓMEZ, Jorge Marx. **A Systematic Literature Review on Applying CRISP-DM Process Model**. [*S.l.: s.n.*], 2021. v. 181, p. 526–534. DOI: 10.1016/j.procs.2021.01.199.

ZELENETZ; JACOB, Michael. **Predicting the Unpredictable: Comparing Statistical Forecasting and Deep Learning Models for Forecasting Emergency Department Arrivals**. 2020. Master's Thesis – Harvard University Division of Continuing Education.

# Apêndices

## APÊNDICE A – CÓDIGO DO TRABALHO

O repositório que contém o código com os experimentos se encontra no site <https://github.com/TheUegg/Prediction-Emergency-Events> onde as informações e arquivos pertinentes ao projeto estão presentes.

**APÊNDICE B – ARTIGO**

# **Previsão de eventos emergenciais utilizando séries temporais e aprendizado de máquina**

**Gabriel Dutra**

Departamento de Informática e Estatística - Universidade Federal de Santa Catarina (UFSC) –  
Florianópolis - SC – Brasil

## **ABSTRACT**

Emergency situations can occur due to natural causes (e.g. meteorological conditions) and other ones (e.g. accidents). In order for occurrences to be handled efficiently, service facilities must be strategically installed and configured, based on geographic issues and the demand occasionated by incidents that happen in each region. However, emergency events vary over time, as several factors such as meteorological and social events can change the dynamics of occurrences. Thus, the efficiency of fire department facilities positioned according to incident averages is hindered by these dynamics, especially when these facilities are not prepared for peaks in the number of occurrences. Emergency event forecasting techniques with good results can enable better decision making. However, accurate forecasting of emergency events is still a challenge, despite the recent developments in machine learning. This work aims to exploit temporal series of emergency events to build ARIMA, RNN and LSTM models to predict emergency events along time and space. Other data, such as historic meteorological data and geographic data related to risky areas will also be considered for building distinct models. The performance of these models and state-of-the-art solutions will be evaluated to compare prediction quality.

## RESUMO

Situações emergenciais podem ocorrer devido a causas naturais (e.g. condições meteorológicas) além de outras (e.g. acidentes). Para que as ocorrências sejam tratadas de forma eficaz, unidades de atendimento são instaladas e configuradas estrategicamente, baseadas em questões geográficas e demanda causada por incidentes que ocorrem em cada região. Entretanto, eventos emergenciais variam com o tempo, devido a diversos fatores tais quais meteorológicos e eventos sociais podem modificar a dinâmica das ocorrências. Então, a eficiência das instalações do departamento de bombeiros é posicionada de acordo com a média de incidentes por essas dinâmicas, especialmente quando elas não estão preparadas para picos nos números de ocorrências. Técnicas para previsões de eventos emergenciais com bons resultados podem possibilitar melhor tomada de decisão. Contudo, previsões de eventos emergenciais precisas ainda são um desafio, apesar de recentes desenvolvimentos em aprendizagem de máquina. Esse trabalho visa explorar séries temporais de eventos emergenciais para construir modelos ARIMA, RNN e LSTM para prever eventos emergenciais atrelado ao tempo e espaço. Outros dados, como dados históricos meteorológicos e geográficos relacionados a áreas de risco também serão considerados para a construção de diferentes modelos. A performance desses modelos e soluções referentes ao estado da arte serão avaliadas para comparar a qualidade das previsões.

## Introdução

Eventos de emergência, como acidentes de trânsito, incêndios e desastres naturais, geram graves prejuízos, incluindo lesões, perdas financeiras e mortes. No mundo, mais de 1,35 milhão de mortes ocorrem anualmente em acidentes rodoviários, enquanto o Brasil registrou 3.369 incêndios em 2020. As forças de salvamento, como bombeiros e defesa civil, buscam minimizar esses impactos, mas enfrentam desafios devido à variabilidade nas demandas e ao número limitado de recursos disponíveis. [SANTOS;SANTOS, 2021]

Neste contexto, técnicas de aprendizado de máquina podem auxiliar na predição de eventos futuros, permitindo uma melhor alocação de recursos. Algoritmos como *ARIMA*, *LSTM* e redes neurais têm sido amplamente utilizados em diversas áreas para análises preditivas. Este trabalho propõe treinar e avaliar modelos baseados em dados históricos de emergências no estado de Santa Catarina, incorporando informações meteorológicas e geográficas, com o objetivo de prever a quantidade de ocorrências futuras e demonstrar o potencial dessas tecnologias para melhorar a tomada de decisão e a resposta a emergências. [HYNDMAN; ATHANASOPOULOS, 2018]

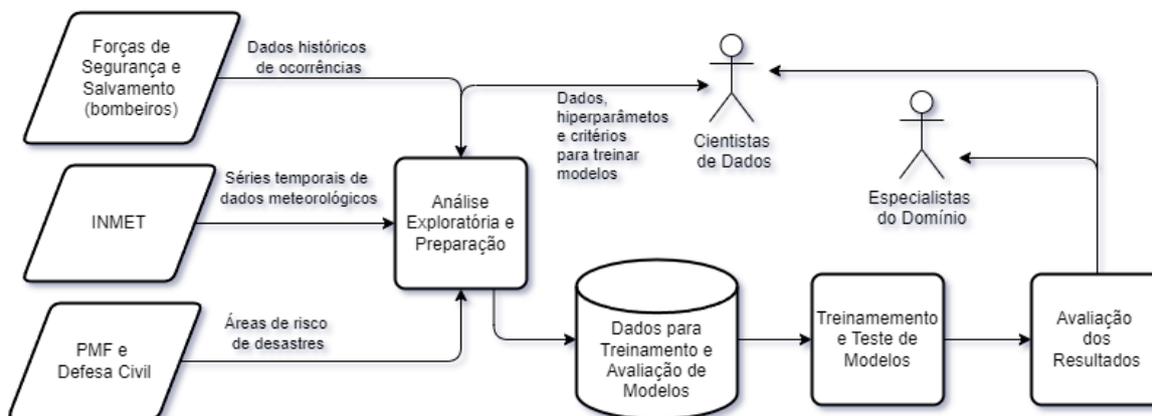
## Proposta

Essa pesquisa visa extrair informações de diversas fontes, começando com dados históricos das Forças de Segurança e Salvamento, organizados em um *dataframe*. Inicialmente, será realizada uma análise exploratória dos dados para filtrar as informações relevantes. Após a preparação dos dados, serão aplicados os métodos de predição *ARIMA*, *RNN* e *LSTM*, e seus resultados serão comparados para determinar qual modelo se adapta melhor aos dados.

Posteriormente, o *dataframe* será ampliado com dados meteorológicos do *INMET*, e uma nova rodada de experimentos será realizada para avaliar a melhoria nos resultados. Em seguida, serão incorporados dados sobre áreas de risco de desastres, obtidos por meio da *PMF*, Defesa Civil e o Serviço Geológico Brasileiro. Após esses ajustes, os modelos serão novamente comparados.

O objetivo final é apresentar métodos alternativos de predição de eventos, demonstrando seus benefícios e oferecendo um processo reutilizável em diferentes contextos. A figura 1 ilustra o fluxo geral deste estudo.

Figura 1 – Fluxo geral de informação.



Fonte: Produzido pelo autor

## Seleção dos Modelos

O estudo explorou três modelos distintos para prever ocorrências com base em séries temporais: ARIMA, LSTM e RNN Simples, cada qual com características específicas para diferentes aspectos dos dados.

ARIMA é ideal para séries estacionárias, sendo simples, interpretável e eficaz em padrões lineares. Requer pouca parametrização e é indicado para séries temporais historicamente autocorrelacionadas, como as de eventos de salvamento. [ZELENETZ; JACOB, 2020]

LSTM é uma rede neural que captura padrões não-lineares e dependências de longo prazo, adequando-se a séries dinâmicas e complexas. É versátil para dados univariados ou multivariados, como a combinação de ocorrências, meteorologia e áreas de risco, sendo útil em problemas com alta variabilidade. [CORTEZ et al., 2018]

RNN Simples oferece uma abordagem intermediária, capturando dependências temporais de curto e médio prazo. Sua simplicidade e menor custo computacional são vantagens em contextos com dependências imediatas ou menor complexidade, como eventos de curto prazo. [CHAKRABORTY; GHOSH, 2020]

Os três modelos complementam-se, abordando diferentes aspectos das séries temporais e possibilitando previsões mais robustas em segurança e gestão de desastres.

## Seleção dos Dados

Os dados utilizados neste estudo foram obtidos de diversas fontes e integrados por meio de cruzamento de datas e horários entre diferentes datasets. O principal conjunto de dados, cedido por Felipe Siqueira, contém informações detalhadas sobre emergências

atendidas pelo Corpo de Bombeiros de Santa Catarina entre 2017 e 2021. Este dataset, em formato .CSV, possui 22 colunas, incluindo horário e coordenadas das ocorrências, e foi manipulado com a biblioteca Pandas para facilitar a análise.

Além disso, foram incorporados dados meteorológicos do INMET, cobrindo o mesmo período, e informações de áreas de risco fornecidas pelo Serviço Geológico Brasileiro (SGB), categorizadas em níveis de risco (Baixo, Médio e Alto). Essa integração enriqueceu o dataset, aprimorando a previsão de eventos emergenciais e considerando o impacto das condições climáticas e geográficas.

A ocorrência "SALVAMENTO/BUSCA/RESGATE" foi escolhida por sua relevância ao escopo meteorológico e às áreas de risco, permitindo análises detalhadas e fundamentadas.

### Treinamento dos Modelos

A fase de treinamento seguiu a abordagem *CRISP-DM*, transformando os dados preparados em modelos preditivos para gerar previsões e recomendações. Os dados foram divididos em 80% para treinamento e 20% para teste, utilizando a biblioteca *sklearn*. Três modelos principais foram empregados: ARIMA, LSTM e RNN Simples.

No modelo *ARIMA*, a abordagem de *Rolling Forecast* foi utilizada para simular previsões contínuas em séries temporais. Foram analisados os parâmetros  $p$ ,  $d$  e  $q$  com base em gráficos de autocorrelação (ACF), e transformações *Box-Cox* foram aplicadas para estabilizar a variância dos dados. As previsões foram ajustadas e avaliadas no domínio original.

No modelo *LSTM*, os dados foram normalizados com *MinMaxScaler*. A arquitetura incluiu duas camadas *LSTM* com 50 células de memória, regularização por *Dropout* (20%) e uma camada de saída *Dense*. O modelo foi treinado com o otimizador *Adam* e a função de perda *mean\_squared\_error*.

O modelo *RNN* utilizou uma arquitetura com uma camada *SimpleRNN* de 50 unidades, normalização dos dados com *MinMaxScaler*, e uma camada de saída *Dense*. Também foi treinado com o otimizador *Adam* e *mean\_squared\_error*. A janela temporal de entrada foi configurada com 10 passos.

Todos os modelos foram avaliados com métricas de erro para identificar o melhor desempenho preditivo.

### Avaliação dos Modelos

Para avaliar a precisão das previsões dos modelos *ARIMA*, *LSTM* e *RNN Simples*, foram utilizadas quatro métricas de erro amplamente reconhecidas em estudos de séries temporais:

- Mean Squared Error (MSE): Mede a média dos quadrados dos erros, com valores menores indicando melhor desempenho do modelo.
- Root Mean Squared Error (RMSE): A raiz quadrada do *MSE*, tornando a interpretação mais intuitiva e penalizando erros maiores.
- Mean Absolute Error (MAE): Calcula a média das diferenças absolutas, sendo uma medida direta da magnitude média do erro.
- Mean Absolute Percentage Error (MAPE): Mede os erros em termos percentuais, útil para avaliar a precisão relativa do modelo.

Essas métricas foram escolhidas por sua eficácia na avaliação da precisão de modelos de previsão de séries temporais. [HYNDMAN; ATHANASOPOULOS, 2018]

### **Experimentos**

Os experimentos foram realizados para avaliar o impacto do enriquecimento de dados e do escopo geográfico na previsão de ocorrências emergenciais. Foram conduzidos cinco experimentos distintos, conforme descrito a seguir:

- Ocorrências Florianópolis
- Ocorrências Florianópolis com Dados Meteorológicos
- Ocorrências Florianópolis com Dados de Áreas de Risco
- Ocorrências Florianópolis com Dados Meteorológicos e de Áreas de Risco
- Ocorrências Santa Catarina com Dados de Áreas de Risco

Cada experimento foi avaliado utilizando as quatro métricas de erro citadas anteriormente.

O primeiro experimento, Ocorrências em Florianópolis, teve como objetivo prever a quantidade de chamadas diárias para as Forças de Segurança e Salvamento em Florianópolis, utilizando os modelos de predição ARIMA, LSTM e RNN Simples. O conjunto de dados consistiu em 493 registros, contendo informações sobre o tempo, a quantidade de ocorrências, tipo, subtipo e localidade das chamadas. O foco foi identificar padrões temporais para prever a demanda futura e otimizar o planejamento e a alocação de recursos.

O segundo experimento, Ocorrências em Florianópolis com Dados Meteorológicos, manteve a estrutura do primeiro, mas com a adição de informações meteorológicas fornecidas pelo INMET, como temperatura, precipitação, umidade e vento. O objetivo foi verificar se o enriquecimento com dados climáticos poderia melhorar a previsão da

demanda diária, identificando padrões relacionados ao clima que impactam as chamadas emergenciais.

Para este experimento, dados climáticos de 2017 a 2021 foram integrados ao conjunto de dados, realizando a padronização e harmonização para associá-los às ocorrências. Variáveis como precipitação e umidade foram usadas para entender como as condições meteorológicas influenciam a demanda por serviços de emergência.

O terceiro experimento, Ocorrências em Florianópolis com Dados de Áreas de Risco, seguiu a estrutura do primeiro, mas incluiu dados geoespaciais sobre áreas de risco, como zonas propensas a inundações e deslizamentos. O objetivo foi verificar se a inclusão dessas informações geográficas aumentaria a precisão das previsões, proporcionando uma análise mais detalhada dos fatores que influenciam o volume de chamadas para serviços de segurança e salvamento.

Foram utilizados shapefiles geoespaciais sobre bacias hidrográficas e áreas suscetíveis a desastres naturais. As ocorrências foram associadas a essas áreas de risco, permitindo uma análise mais robusta sobre a relação entre localização geográfica e a demanda por serviços emergenciais.

O quarto experimento, Ocorrências em Florianópolis com Dados Meteorológicos e de Áreas de Risco, combinou os dados meteorológicos do segundo experimento com as informações de áreas de risco do terceiro experimento, criando um dataset enriquecido com ambas as variáveis. O objetivo foi avaliar se a combinação desses dados poderia melhorar ainda mais a precisão das previsões de demanda por serviços de emergência.

O quinto experimento, Ocorrências em Santa Catarina com Dados de Áreas de Risco, expandiu o escopo para todas as ocorrências registradas em Santa Catarina, com 23.285 registros, mantendo a inclusão de dados de áreas de risco. O objetivo foi avaliar se o aumento do volume de dados, mantendo as informações geoespaciais de risco, contribuiria para melhorar os resultados preditivos dos modelos. Este experimento teve como base a estrutura do terceiro experimento, que apresentou os melhores resultados até o momento, mas com uma quantidade significativamente maior de dados.

## Resultados dos Experimentos

A tabela 1 apresenta o desempenho dos modelos ARIMA, RNN e LSTM em diferentes cenários, considerando métricas como MSE, RMSE, MAE e MAPE. A comparação entre os resultados dos modelos nos experimentos permite uma análise detalhada de sua eficácia na previsão de ocorrências emergenciais.

No experimento com dados históricos de ocorrências em Florianópolis, o modelo LSTM obteve os melhores resultados, com os menores valores de MSE (0.54), RMSE (0.73) e MAE (0.57), além de um MAPE de 28.79%, destacando sua capacidade de capturar padrões temporais de forma precisa. O ARIMA, apesar de ser um modelo tradicional, se

Tabela 1 – Resumo do desempenho dos modelos nos experimentos

Experimento	Modelo	MSE	RMSE	MAE	MAPE
Só dados históricos de ocorrências em Florianópolis	ARIMA	1.08	1.04	0.79	<b>24.02%</b>
	RNN	0.84	0.92	0.68	41.57%
	LSTM	<b>0.54</b>	<b>0.73</b>	<b>0.57</b>	28.79%
Florianópolis com dados meteorológicos	RNN	<b>0.91</b>	<b>0.95</b>	<b>0.70</b>	<b>40.21%</b>
	LSTM	1.12	1.06	0.81	40.52%
Florianópolis com dados de áreas de risco	RNN	0.76	0.87	0.64	38.70%
	LSTM	<b>0.55</b>	<b>0.74</b>	<b>0.59</b>	<b>28.53%</b>
Florianópolis com dados meteorológicos e dados de áreas de risco	RNN	<b>0.81</b>	<b>0.90</b>	<b>0.66</b>	39.19%
	LSTM	1.08	1.04	0.78	<b>38.16%</b>
Santa Catarina com dados de áreas de risco	ARIMA	<b>215.64</b>	<b>14.68</b>	<b>12.46</b>	<b>36.81%</b>
	RNN	383.13	19.57	17.48	54%
	LSTM	217.61	14.75	13.30	41.48%

mostrou mais eficiente que o RNN.

Ao incluir dados meteorológicos, o desempenho do LSTM diminuiu, com MSE (1.12) e MAPE (40.52%), sugerindo que os dados meteorológicos podem ter introduzido ruído. Em contrapartida, ao adicionar dados de áreas de risco, tanto o RNN quanto o LSTM apresentaram melhorias, com o LSTM se destacando novamente (MSE de 0.55 e MAPE de 28.53

Nos experimentos envolvendo todo o estado de Santa Catarina, os modelos tiveram desempenho inferior, provavelmente devido à mudança no padrão da série temporal durante os testes. A comparação das métricas revela que a inclusão de dados

meteorológicos nem sempre melhora o desempenho, enquanto a inclusão de dados geográficos de áreas de risco teve um impacto positivo, especialmente no LSTM.

## **Conclusão**

Os resultados indicaram que, apesar dos experimentos realizados, há espaço para melhorias. A inclusão de dados adicionais, como informações geográficas e meteorológicas, não trouxe ganhos significativos na acurácia das previsões. Futuras abordagens podem combinar diferentes modelos, como ARIMA com redes neurais, para melhorar a precisão.

Além disso, o trabalho enfrentou limitações de memória e processamento, dificultando a experimentação com grandes volumes de dados. Em ambientes com maior capacidade computacional, seria possível realizar experimentos mais robustos e obter resultados mais precisos.

Futuras melhorias podem incluir o uso de séries temporais multivariadas, redes neurais avançadas, e a incorporação de mais fontes de dados, como informações de tráfego e dados em tempo real. O objetivo é criar um sistema de previsão mais robusto e eficiente, superando os desafios encontrados.

## REFERÊNCIAS

- BEJARANO, Gissella *et al.* A Deep Learning based Emergency Resolution Time Prediction System. IEEE, 2020. DOI: 10.1109/iThings-GreenCom-CPSCoM-SmartData-Cybermatics50389.2020.00090.
- BOHM, Ivo Guilherme. **Antecipação de Emergências Utilizando Técnicas Baseadas em Séries Temporais e Aprendizado de Máquina.** 2022. F. 43. Monografia (Trabalho de Conclusão de Curso) – Faculdade de Ciências da Computação, Universidade Federal de Santa Catarina, Santa Catarina.
- C., Yu *et al.* A COVID-19 Pandemic Artificial Intelligence-Based System With Deep Learning Forecasting and Automatic Statistical Data Acquisition: Development and Implementation Study. **J Med Internet Res**, J Med Internet Res, 2021.
- CHAKRABORTY, Tanujit; GHOSH, Indrajit. Real-time forecasts and risk assessment of novel coronavirus (COVID-19) cases: A data-driven analysis. **Chaos, Solitons Fractals**, Chaos, Solitons Fractals, v. 135, 2020.
- CORTEZ, Bitzel *et al.* An architecture for emergency event prediction using LSTM recurrent neural networks. **Expert Systems with Applications**, Elsevier, v. 97, 2018. DOI: 10.1016/j.eswa.2017.12.037.
- GHOJOGH, Benyamin; GHODSI, Ali. **Recurrent Neural Networks and Long Short-Term Memory Networks: Tutorial and Survey.** [*S.l.: s.n.*], 2023. arXiv: 2304.11461 [cs.LG]. Disponível em: <https://arxiv.org/abs/2304.11461>.
- HYNDMAN, R.J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice.** [*S.l.: s.n.*], 2018. v. 2.
- MUKHOPADHYAY, Ayan *et al.* A Review of Emergency Incident Prediction, Resource Allocation, and Dispatch Models. **arXiv**, Elsevier, 2020.
- RAMASWAMI, M.; BHASKARAN, R. A CHAID Based Performance Prediction Model in Educational Data Mining. **International Journal of Computer Science Issues**, v. 7, 2010. DOI: 10.48550/arXiv.1002.1144.
- SANTOS, Thiago Rodrigues dos; SANTOS, Thais Rodrigues Dos. ANÁLISE DA ATUAÇÃO DO GRUPO DE AÇÕES COORDENADAS (GRAC) DE BARRA VELHA NO INCÊNDIO FLORESTAL DE 2020. **Ignis**, Ignis, 2021.
- ZELENETZ; JACOB, Michael. **Predicting the Unpredictable: Comparing Statistical Forecasting and Deep Learning Models for Forecasting Emergency Department Arrivals.** 2020. Master's Thesis – Harvard University Division of Continuing Education.