



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA BIOMÉDICA

ARACELY ANDRADE DA SILVA

**PREDIÇÃO DA DISTRIBUIÇÃO DE CRIADOUROS DE *Aedes Aegypti* POR
MEIO DE ANÁLISE ESPAÇO-TEMPORAL E APRENDIZADO DE MÁQUINA:
estudo de caso em Recife, Pernambuco**

Recife
2020

ARACELY ANDRADE DA SILVA

**PREDIÇÃO DA DISTRIBUIÇÃO DE CRIADOUROS DE *Aedes Aegypti* POR
MEIO DE ANÁLISE ESPAÇO-TEMPORAL E APRENDIZADO DE MÁQUINA:
estudo de caso em Recife, Pernambuco**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Mestre em Engenharia Biomédica.

Área de concentração: Computação Biomédica.

Orientadora: Profa. Dra. Cristine Martins Gomes de Gusmão.

Coorientador: Prof. Dr. Wellington Pinheiro dos Santos.

Recife

2020

Catálogo na fonte
Bibliotecária Margareth Malta, CRB-4 / 1198

S586p

Silva, Aracely Andrade da.

Predição da distribuição de criadouros de *Aedes aegypti* por meio de análise espaço-temporal e aprendizado de máquina: estudo de caso em Recife, Pernambuco / Aracely Andrade da Silva - 2020.

70 folhas, il., gráfs., tabs.

Orientadora: Profa. Dra. Cristine Martins Gomes de Gusmão.

Coorientador: Prof. Dr. Wellington Pinheiro dos Santos.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.
Programa de Pós-Graduação em Engenharia Biomédica, 2020.

Inclui Referências.

1. Engenharia Biomédica. 2. Aprendizado de máquina. 3. Previsões.
4. Infecções por arbovírus. 5. Ovoposição. 6. Controle de mosquitos. 7.
Aedes aegypti. I. Gusmão, Cristine Martins Gomes de (Orientadora). II.
Santos, Wellington Pinheiro dos (Coorientador). III. Título.

UFPE

610.28 CDD (22. ed.)

BCTG/2020-264

ARACELY ANDRADE DA SILVA

**PREDIÇÃO DA DISTRIBUIÇÃO DE CRIADOUROS DE *Aedes Aegypti* POR
MEIO DE ANÁLISE ESPAÇO-TEMPORAL E APRENDIZADO DE MÁQUINA:
estudo de caso em Recife, Pernambuco**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Biomédica da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de Mestre em Engenharia Biomédica.

Aprovada em: 17/08/2020

BANCA EXAMINADORA

Profa. Dra. Cristine Martins Gomes de Gusmão (Orientadora)

Universidade Federal de Pernambuco

Prof. Dr. Ricardo Emmanuel de Souza (Examinador Interno)

Universidade Federal de Pernambuco

Prof. Dr. Sidney Marlon Lopes de Lima (Examinador Externo)

Universidade Federal de Pernambuco

RESUMO

O controle da distribuição e disseminação do *Aedes aegypti* demonstra um verdadeiro desafio. Apesar de serem consideradas as situações em que os recursos destinados ao combate desse vetor sejam apropriados para a implementação de políticas públicas para enfrentamento deste, em sua maioria não se tem alcançado êxito. Neste contexto, o uso de preditores baseados em algoritmos de aprendizagem de máquina além da análise espaço-temporal apresentam-se eficazes para predição de criadouros de *Aedes aegypti*, fornecendo mapas de distribuição que apontam onde encontram-se as maiores concentrações de criadouros deste vetor. Este estudo apresenta como objetivo construir um protótipo de um sistema preditor da distribuição de criadouros de *Aedes aegypti* em Recife-PE utilizando métodos de regressão a fim de auxiliar gestores de saúde a planejarem ações de prevenção e promoção à saúde. Como metodologia aplicada, selecionou-se como sendo a área de estudo a cidade do Recife-PE, onde dados referentes ao levantamento rápido de índices de infestação pelo *Aedes aegypti* foram fornecidos pela prefeitura municipal. Utilizando o *software* Quantum GIS (QGIS), versão 2.18, onde uma camada vetorial de pontos foi construída (.shp) localizando os pontos das amostras. Para estimar a distribuição de criadouros do mosquito em pontos desconhecidos, foi utilizada a interpolação pelo inverso da distância (IDW). O conjunto de predição foi elaborado separando cada ano por bimestres. Para cada bimestre, foi gerado um conjunto de imagens as quais contemplam a distribuição dos criadouros, e os *rasters* de distribuição de variáveis climáticas (temperatura, velocidade dos ventos e pluviometria). A partir dessa sequência, foram gerados arquivos (.arff) referentes aos conjuntos de imagens dos seis bimestres que antecederam o bimestre que se desejava prever. Foram realizados experimentos computacionais utilizando um *software* para aprendizado de máquina, o Weka, versão 3.8. Utilizou-se 30% dos dados para o treinamento do modelo e 70% dos dados para testar o modelo. O treinamento e o teste utilizaram validação cruzada. Os testes foram individuais e repetidos 30 vezes para a predição da distribuição de criadouros de *Aedes aegypti* para cada bimestre de cada ano. Foi realizada uma avaliação quantitativa dos regressores utilizados nesta pesquisa, onde para análise dos dados, foram calculados o Coeficiente de Correlação (CC), como qualidade global e, o Erro Quadrático Relativo Percentual (RMSE%), como qualidade local. Além destes, também foi calculado o Erro Quadrático Médio (MAE). Após as análises, foram gerados mapas para o melhor e o pior preditores, realizando ao final, uma comparação entre eles. Verificou-se que o preditor *kernel 2* apresentou maior coeficiente de correlação ($> 0,9$) e menor erro quadrático relativo

percentual (< 1%). A partir dos resultados obtidos, pode-se concluir que o uso de preditores baseados em algoritmos de aprendizado de máquina apresentou-se eficaz para predição de criadouros de *Aedes aegypti*. A análise espaço-temporal foi capaz de fornecer uma ampla avaliação das áreas onde ocorrem mais ou menos focos de criadouros, sendo possível, diferenciar através de mapas de distribuição, as localidades com maior índice de focos de criadouros daquelas com baixa concentração, além das áreas estabelecidas dentro de um intervalo de transição.

Palavras-chave: Aprendizado de máquina. Previsões. Infecções por arbovírus. Ovoposição. Controle de mosquitos. *Aedes aegypti*.

ABSTRACT

Controlling the distribution and dissemination of *Aedes aegypti* demonstrates a real challenge. Despite considering the situations in which the resources destined to combat this vector are appropriate for the implementation of public policies to face this, most of them have not been successful. In this context, the use of predictors based on machine learning algorithms in addition to spatio-temporal analysis are effective for predicting *Aedes aegypti* breeding sites, providing distribution maps that point out where the highest breeding concentrations of this vector are found. This study aims to build a prototype of a prediction system for the distribution of *Aedes aegypti* breeding sites in Recife-PE using regression methods in order to assist health managers in planning prevention and health promotion actions. As an applied methodology, the city of Recife-PE was selected as the study area, where data referring to the rapid survey of infestation rates by *Aedes aegypti* were provided by the city hall. Using Quantum GIS software (QGIS), version 2.18, where a vector layer of points was built (.shp) locating the sample points. To estimate the distribution of mosquito breeding sites at unknown points, interpolation by the inverse of distance (IDW) was used. The prediction set was prepared separating each year by two months. For each two months, a set of images was generated which contemplate the distribution of breeding sites, and the rasters of distribution of climatic variables (temperature, wind speed and rainfall). From this sequence, files (.arff) were generated referring to the sets of images of the six bimonths that preceded the bimester that it was intended to predict. Computational experiments were performed using a machine learning software, Weka, version 3.8. 30% of the data was used for training the model and 70% of the data to test the model. Training and testing used cross-validation. The tests were individual and repeated 30 times to predict the distribution of *Aedes aegypti* breeding sites for each two months of each year. A quantitative assessment of the regressors used in this research was carried out, where for data analysis, the Correlation Coefficient (CC) was calculated as the global quality and the Percentage Relative Quadratic Error (RMSE%) as the local quality. In addition to these, the Mean Square Error (WEM) was also calculated. After the analysis, maps were generated for the best and worst predictors, making a comparison between them at the end. It was found that the kernel 2 predictor presented a higher correlation coefficient (> 0.9) and a lower percentage relative square error ($< 1\%$). From the results obtained, it can be concluded that the use of predictors based on machine learning algorithms was effective for predicting *Aedes aegypti* breeding sites. The spatio-temporal analysis was able to provide a broad assessment of the areas where more or

less breeding sites occur, making it possible to differentiate, through distribution maps, the locations with the highest rate of breeding sites from those with low concentration, in addition to the areas established within a transition interval.

Keywords: Machine learning. Forecasting. Arbovirus infections. Ovoposition. Mosquito control. *Aedes aegypti*.

LISTA DE FIGURAS

Figura 1 – Demonstração esquemática do ciclo biológico do <i>Aedes aegypti</i>	18
Figura 2 – Divisão territorial do Recife-PE.....	35
Figura 3 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do primeiro bimestre de 2014.....	45
Figura 4 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do segundo bimestre de 2014.....	46
Figura 5 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do terceiro bimestre de 2014.....	47
Figura 6 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do quarto bimestre de 2014.....	48
Figura 7 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do quinto bimestre de 2014.....	49
Figura 8 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do sexto bimestre de 2014.....	50
Figura 9 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do primeiro bimestre de 2015.....	51
Figura 10 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do segundo bimestre de 2015.....	52
Figura 11 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do terceiro bimestre de 2015.....	53
Figura 12 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do quarto bimestre de 2015.....	54
Figura 13 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do quinto bimestre de 2015.....	55
Figura 14 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do sexto bimestre de 2015.....	56
Figura 15 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do primeiro bimestre de 2016.....	57
Figura 16 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do segundo bimestre de 2016.....	58
Figura 17 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do terceiro bimestre de 2016.....	59
Figura 18 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do quarto bimestre de 2016.....	60
Figura 19 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do	

quinto bimestre de 2016.....	61
Figura 20 – Resultados da predição da distribuição dos criadouros de <i>Aedes aegypti</i> do	
sexto bimestre de 2016.....	62

LISTA DE TABELAS

Tabela 1 – Resumo dos trabalhos relacionados e suas principais características.....	31
Tabela 2 – Comparação dos resultados obtidos para regressão linear e SVM - <i>Kernel</i> 2.....	42
Tabela 3 – Tabela 2 - Comparação dos resultados obtidos para SVM - <i>Kernel</i> 1 e SVM – RBF.....	43
Tabela 4 – Rótulos numéricos dos bairros do Recife-PE.....	44

LISTA DE SIGLAS

AG	Algoritmo genético
APAC	Agência Pernambucana de Águas e Climas
CC	Correlation Coefficient / Coeficiente de Correlação
CHIKV	Chikungunya
DENV	Dengue
MAE	Mean Absolute Error / Erro Quadrático Médio
RMSE%	Percentual Root Mean-Squared Error
IDH	Índice de Desenvolvimento Humano
IDHM	Índice de Desenvolvimento Humano Municipal
INMET	Instituto Nacional de Meteorologia
MERG	Grupo de Resposta de Emergência da Microcefalia
MS	Ministério da Saúde
OMS/WHO	Organização Mundial de Saúde
RPA	Região Político-Administrativa
SUS	Sistema Único de Saúde
VSA	Vigilância em Saúde Ambiental
ZIKV	Zika

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	Motivação e justificativa.....	14
1.2	Objetivos	15
1.3	Organização do Trabalho.....	16
2	FUNDAMENTAÇÃO TEÓRICA.....	17
2.1	Bioecologia do <i>Aedes aegypti</i> (^a BRASIL,2001)	17
2.2	Arboviroses	18
2.3	Política de Vigilância Ambiental	23
2.4	Predição de arboviroses e criadouros	24
2.5	Aprendizado de máquina	25
2.5.1	Regressão linear	25
2.5.2	Máquina de Vetores de Suporte.....	26
3	TRABALHOS RELACIONADOS.....	27
4	PROPOSTA: MODELO PREDITOR DE CRIADOUROS DE <i>Aedes</i>	
	<i>AEGYPTI</i>.....	33
4.1	Área de estudo.....	33
4.2	Base LIRAa (Brasil, 2012)	36
4.3	Métodos de predição e configurações utilizadas	37
5	MATERIAIS E MÉTODOS.....	40
5.1	Python	40
5.2	Quantum GIS (QGIS).....	40
5.3	Weka.....	40
6	RESULTADOS E DISCUSSÃO.....	42
7	CONCLUSÃO E TRABALHOS FUTUROS.....	63
7.1	Conclusão geral.....	63
7.2	Dificuldades apresentadas	63
7.3	Contribuições	64
7.4	Trabalhos Futuros	64
	REFERÊNCIAS.....	65

1 INTRODUÇÃO

O mosquito *Aedes aegypti* pertence ao gênero *Aedes*, subgênero *Stegomyia*. Esses vetores são encontrados principalmente nos trópicos e subtropicais, onde as fêmeas se alimentam preferencialmente de sangue humano, sendo mais ativas durante o dia, prosperando-se em ambientes peridoméstico, picando muitas vezes várias pessoas em um curto período de tempo. A superpopulação humana e vetorial facilita a transmissão de arboviroses, onde habitats larvais artificiais, juntamente com o superpovoamento em regiões tropicais de países de baixa renda corroboram para os surtos epidêmicos sazonais das arboviroses. Além disso, viagens internacionais e globalização aceleram a introdução em novas áreas ampliando sua expansão geográfica global (LINDSEY *et al.*, 2017; WILDER-SMITH *et al.*, 2017).

As arboviroses são transmitidas para pessoas pela picada de um mosquito-fêmea *Aedes* infectado. Tradicionalmente, é dada baixa prioridade à pesquisa para arbovírus, no entanto, o precedente dos surtos epidêmicos mudaram as percepções sobre sua contribuição à mortalidade humana global (POSSAS *et al.*, 2017; WILDER-SMITH *et al.*, 2017).

Dentre as principais espécies de arbovírus conhecidas, tem-se o vírus da dengue, onde cerca de mais de 2,5 bilhões de pessoas em mais de 100 países correm o risco de contrair a doença sozinha, o vírus do Nilo Ocidental que, apesar de ocasionar pequenos surtos ocasionais, mostra uma taxa de mortalidade extremamente alta, da Chikungunya, anteriormente restrito a partes da África, está agora globalmente disseminado e, mais recentemente, do Zika vírus, onde após os surtos iniciais na região do Pacífico em 2007, avançou para uma maior disseminação nas Américas, incluindo o Brasil (PRADIER *et al.*, 2012; CAUCHEMEZ *et al.*, 2014; LORENZO *et al.*, 2014; MORENS, FAUCI, 2014; ROTH *et al.*, 2014; WHO, 2015; ZANLUCA *et al.*, 2015; SLAVOV *et al.*, 2016).

Apesar das extensas medidas de controle de vetores para conter a transmissão, incluindo redução de fonte, pesticidas, educação pública e controle biológico, esses esforços foram amplamente mal sucedidos. Destaca-se a necessidade de métodos mais aprimorados de controle e melhor conhecimento sobre a biologia desses mosquitos (MEDLOCK *et al.*, 2012; PORSE *et al.*, 2015).

Dentro dos modelos de predição existentes, um dos principais métodos utilizados para análise populacional de mosquitos vetores das arboviroses corresponde ao uso de ovitrampas, que se constituem de armadilhas de ovoposição, o qual demonstra ser um método eficaz para fornecer dados úteis sobre distribuição espacial tanto do *Aedes aegypti* como de outras

espécies de mosquitos, o que permite obter um melhor conhecimento de sua população e atividade (SCAVUZZO *et al.*, 2017).

Ainda sob essa óptica, no contexto da epidemiologia da paisagem, a utilização de dados de satélite sobre observação da terra e utilização de tecnologias geoespaciais são ferramentas operacionais preditivas essenciais. Baseados nessas ideias, estudos foram publicados recentemente adotando medidas interdisciplinares para o caso de epidemias de arboviroses, como modelos preditivos de risco baseados em condições ambientais (ESTALLO *et al.*, 2014; ESPINOSA *et al.*, 2016).

Existe um grande interesse em modelar a evolução temporal, com aplicação de séries de alguns anos, das populações de mosquitos com a utilização de variáveis ambientais obtidas de sensores remotos, em um esforço para melhorar tais estimativas, em modelos desenvolvidos com base em um grande número de variáveis de diferentes sensores em um lapso temporal aproximado de quatro anos, onde alguns baseiam seus algoritmos em modelos multivariados lineares (ESTALLO *et al.*, 2012; ESTALLO *et al.*, 2014; ESPINOSA, GERMAN, SCAVUZZO, 2017).

1.1 Motivação e justificativa

As arboviroses são um crescente problema de saúde pública no mundo, principalmente pelo potencial de dispersão, pela capacidade de adaptação a novos ambientes e hospedeiros (vertebrados e invertebrados), pela possibilidade de causar epidemias extensas, pela susceptibilidade universal e pela ocorrência de grande número de casos graves, com acometimento neurológico, articular e hemorrágico. A introdução de qualquer arbovírus em área indene ou com a presença do vetor nunca deve ser negligenciada. O enfrentamento de arboviroses emergentes exige políticas e intervenções de amplo espectro, envolvendo vários setores da sociedade, não somente a área da saúde (DONALISIO, FREITAS, VON ZUBEN, 2017).

A Vigilância em Saúde Ambiental (VSA) consiste em um conjunto de ações que proporcionam o conhecimento e a detecção de mudanças nos fatores determinantes e condicionantes do meio ambiente que interferem na saúde humana, com a finalidade de identificar as medidas de prevenção e controle dos fatores de risco ambientais relacionados às doenças ou a outros agravos à saúde (MS, 2019).

A importância da avaliação da atuação das ações de vigilância em saúde tem como propósito principal, apreciar a produção de decisões que desencadeiem o processo de

intermediação e implementação de ações e políticas que impactem diretamente a sociedade. No Brasil, a tríplice epidemia de Dengue, Zika e Chikungunya vivenciada, demonstra o insucesso das ações de combate ao *Aedes aegypti* até o presente momento (DONATELI *et al.*, 2017).

Este estudo é norteado pela pergunta de pesquisa: como construir modelos preditivos de criadouros de *Aedes aegypti* que sejam eficazes, apresentem baixo custo e pequeno erro, utilizando bases de dados de informações geográficas e variáveis climáticas que possam ser utilizados como ferramenta de apoio aos gestores de saúde pública no planejamento, vigilância em saúde e tomada de decisão de combate ao vetor?

Modelos de predição que utilizam modelagem e simulação matemática-computacional constituem uma ferramenta interessante para o estudo de fenômenos complexos, podendo assim apoiar atividades de planejamento, avaliação de cenários e tomada de decisão. A utilização de ferramentas que auxiliam na modelagem e simulação de sistemas complexos são bastante úteis, por exemplo, para identificar padrões espaço-temporais de transmissão das arboviroses, que apresentam uma dinâmica complexa, tanto em relação à transmissão viral quanto à ecologia de seu vetor, que é influenciada por um amplo conjunto de fatores ambientais e sociais.

1.2 Objetivos

Este trabalho tem como objetivo geral construir um método de predição de criadouros do mosquito *Aedes aegypti* a partir de informações climáticas e ambientais e do histórico da ocorrência de criadouros utilizando uma abordagem espaço-temporal.

Como objetivos específicos ou metas, têm-se:

- a) Investigar a distribuição espacial dos criadouros *Aedes aegypti* na Cidade do Recife, de 2013 a 2016;
- b) Investigar modelos preditivos para predição em ciclos de 02 meses utilizando 12 meses de informações prévias;
- c) Avaliar modelos preditivos considerando métricas de regressão;
- d) Gerar mapas de predição da distribuição dos criadouros para a melhor e a pior técnica avaliada.

1.3 Organização do Trabalho

A presente dissertação está dividida em sete capítulos. No capítulo 1 iniciou-se realizando uma breve explanação sobre arboviroses e sua importância no contexto epidemiológico atual. Além disso, citou-se a importância dos modelos preditivos para diagnóstico espaço-temporal da ocorrência dos surtos epidêmicos destas. Justificaram-se a realização desse estudo e sua motivação, baseados na importância que tais doenças trazem como consequência para a população e gestores governamentais.

No capítulo 2 foi realizada a fundamentação teórica. Abordando a bioecologia do *Aedes aegypti* e trazendo o conceito de arboviroses, falando sobre sua situação atual no Brasil e no mundo. Descreveu-se a Política de Vigilância Ambiental e abordou-se a importância e o papel dos agentes de combate às endemias e os tipos de criadouros. Explicou-se como é realizada a predição de arboviroses, tipos de criadouros e a aprendizagem de máquina.

No Capítulo 3 relacionaram-se sete trabalhos relativos ao tema do presente estudo. Realizou-se um resumo crítico, apresentando vantagens e desvantagens, pontos fortes e pontos fracos.

No Capítulo 4 apresentou-se a região estudada e suas principais características. Descreveu-se a base de dados LIRAA de Recife e como os dados foram organizados e reunidos com as informações climáticas e ambientais. Ao final deste capítulo foram apresentados os métodos de predição e as configurações utilizadas.

No Capítulo 5 apresentamos os softwares utilizados para desenvolvimento do presente estudo.

No Capítulo 6 os resultados foram apresentados e discutidos de acordo com o estabelecido nos objetivos.

No sétimo capítulo estão apresentadas as conclusões dos resultados obtidos e, como continuidade, também estão elencadas as dificuldades apresentadas, contribuições e sugestões para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo tem por objetivo apresentar a fundamentação teórica Abordando a bioecologia do *Aedes aegypti* e trazendo o conceito de arboviroses, falando sobre sua situação atual no Brasil e no mundo.

2.1 Bioecologia do *Aedes aegypti* (^aBRASIL,2001)

O *Aedes aegypti* é uma espécie tropical e subtropical, encontrada em todo mundo, durante a estação quente, não sobrevivendo ao inverno. Pertencem ao ramo *Arthropoda* (pés articulados), classe *Hexapoda* (três pares de patas), ordem *Diptera* (um par de asas anterior funcional e um par posterior transformado em halteres), família *Culicidae*, gênero *Aedes*. O ciclo de vida do mosquito apresenta quatro fases: ovo, larva, pupa e adulto.

Os ovos são depositados próximos à superfície da água, medem cerca de 1mm de comprimento e contorno alongado e fusiforme. Em sua postura são brancos, mas logo adquirem a cor negra brilhante. A fecundação acontece no momento da postura e o desenvolvimento se completa em 48 horas, através de condições propicias de umidade e temperatura. Os ovos são resistentes a longos períodos de dessecação podendo prolongar-se por mais de doze meses. Sendo o principal desafio para sua erradicação.

A fase larvária possuem quatro estágios, sendo o período de alimentação e crescimento. O período de eclosão varia de acordo com a temperatura, disponibilidade de alimento e densidade das larvas no criadouro. Em condições adequadas, o período entre a eclosão e a pupação não excede cinco dias. Porém em baixa temperatura e escassez de alimento, o 4º estágio larvário pode prolongar-se por semanas, antes de sua transformação em pupa.

A fase pupar corresponde à transformação do estágio de larva para a fase adulta do *Aedes* que dura cerca de dois a três dias. As pupas quando inativas mantêm-se na região superficial da água, facilitando a emergência do inseto adulto.

Após emergir da fase de pupa, o mosquito adulto pousa sobre as paredes do recipiente onde se deu seu desenvolvimento, permanecendo assim por horas. Essa ação visa o endurecimento do seu exoesqueleto e, nos machos, a rotação da genitália em 180°.

O mosquito adulto representa a fase reprodutora e de dispersão do inseto. Após 24 horas de sua emersão podem acasalar, onde este geralmente se dá durante o voo, mas também

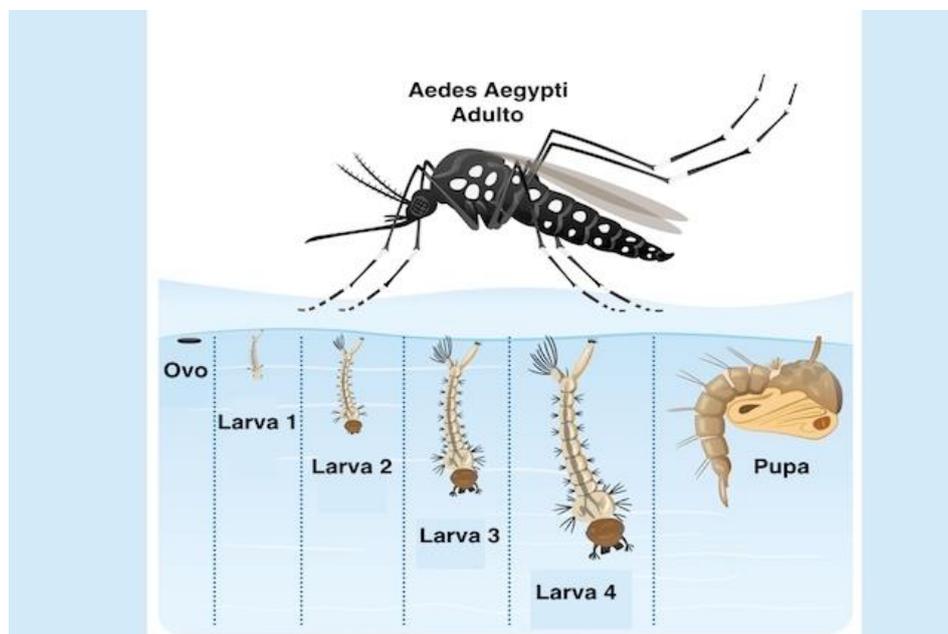
sobre uma superfície, vertical ou horizontal. Uma única inseminação é capaz de fecundar todos os ovos que o mosquito fêmea venha a produzir durante sua vida.

As fêmeas geralmente se alimentam de sangue onde este repasto sanguíneo fornece os nutrientes necessários para o desenvolvimento dos ovos. Essas geralmente fazem uma postura após cada repasto e, o intervalo entre a alimentação e a postura é em média de três dias, sob condições favoráveis de temperatura.

A oviposição ocorre frequentemente no fim da tarde, onde as fêmeas são atraídas por recipientes escuros ou sombreados, com superfície rugosa, nas quais depositam os ovos em vários recipientes distintos.

A dispersão do mosquito se dá a grandes distâncias como resultado do transporte dos ovos e larvas em recipientes. Os adultos podem permanecer vivos na natureza em média de 30 a 35 dias, com uma mortalidade diária de 10%, sendo que a metade destes morre durante a primeira semana de vida e cerca de 95%, no primeiro mês. Qualquer depósito que possa acumular água pode servir como criadouro ou foco de mosquitos.

Figura 1 – Demonstração esquemática do ciclo biológico do *Aedes aegypti*



Fonte: Brasil Escola, 2019.

2.2 Arboviroses

As arboviroses são causadas por vírus (arbovírus) transmitidos para pessoas através da picada de um artrópode infectado, predominantemente mosquitos e carrapatos. Englobam-se

nessa classificação diversos vírus de RNA (alfavírus, flavivírus, bunyavírus, nairovírus, flebovírus, orbivírus, vesiculovírus e togotovírus) e apenas um vírus de DNA; o vírus da febre suína africana (asfarvírus) (MUSSO; CAOLORMEAU; GUBLER, 2015).

No Brasil encontramos uma variedade de vírus em circulação, vistos em diversos estudos de soro-prevalência e vigilância de doenças exantemáticas (NUNES *et al.*, 2009). Esses arbovírus circulam em áreas urbanas e periurbanas como vírus da dengue (DENV), chikungunya (CHIKV) e zika (ZIKV) (BATISTA *et al.*, 2012).

O zika vírus, um arbovírus do gênero *Flavivírus*, tendo sido identificado pela primeira vez em macacos Rhesus, os quais viviam na floresta de Zika, Uganda, na África, em 1947. O primeiro caso de isolamento do vírus em humanos ocorreu em 1954, em uma jovem garota no leste da Nigéria – África. Contudo, apenas em 2007, foi reportado o primeiro caso de epidemia fora do continente africano e asiático, a qual ocorreu na ilha Yap, nos Estados Federados da Micronésia, Oceania (JAENISCH *et al.*, 2017; POSSAS *et al.*, 2017; WILDER-SMITH *et al.*, 2017).

Em junho de 2015, no Brasil o Ministério da Saúde identificou os primeiros casos de síndromes neurológicas em pacientes com história de doença exantemática em regiões endêmicas para arbovírus (ZIKV, DENV e CHIKV). Em outubro um crescente número de nascimentos de bebês com microcefalia foi noticiado na cidade do Recife-PE, localizada na região nordeste do país, onde esses números continuaram a crescer nos meses seguintes. Em 01 de fevereiro de 2016, a Organização Mundial de Saúde (OMS/WHO) declarou que os casos de microcefalia e outros distúrbios neurológicos em bebês constituíram uma Emergência em Saúde Pública de preocupação internacional. Através da cronologia filogenética e molecular, estima-se que o ZIKV foi introduzido no Brasil em maio de 2013 (CAVALCANTI *et al.*, 2016; JAENISCH *et al.*, 2017; POSSAS *et al.*, 2017).

Embora provoque infecção assintomática ou clinicamente leve na maioria dos casos, o ZIKV tem um tropismo por células neurais progenitoras no desenvolvimento do feto humano, resultando em aglomerados de desenvolvimento neurológico defeitos congênitos que são ainda agravados por doença neurológica grave em adultos. Como por exemplo, os sintomas da síndrome de Guillain-Barré e outras complicações neurológicas levantam questões sobre se esses fenômenos são devidos da neuro invasão direta ou devido à autoimunidade pós-infeciosa (WILDER-SMITH *et al.*, 2017).

A identificação do vírus no LCR correspondeu à principal hipótese proposta por pesquisadores da FIOCRUZ - Pernambuco e o Grupo de Resposta de Emergência da Microcefalia (MERG) pelo aumento acentuado nos casos de microcefalia por ZIKV na

gravidez. Logo, ficou claro que a microcefalia severa é um dos sintomas no espectro da síndrome congênita por Zika. Em muitos casos, o dano ao cérebro de recém-nascidos, como partes do cérebro que não foi formado, calcificações e outras patologias neurológicas e oculares, foram tão graves que levou a uma condição quase equivalente à anencefalia (POSSAS *et al.*, 2017).

A superpopulação facilita transmissão via mosquitos urbanos *Aedes*, mais composto por habitats larvais artificiais, sugerindo que a urbanização sem precedentes em regiões tropicais de países de baixa renda nos últimos 50 anos é o principal motor de doenças transmitidas por *A. aegypti*. Além disso, aumentando viagens internacionais e globalização aceleram a introdução de arbovírus em novas áreas e sua expansão geográfica (WILDER-SMITH *et al.*, 2017).

O CHIKV, pertencente ao gênero *Alphavirus* e família *Togaviridae* transmitido pelos vetores *Aedes aegypti* e *Aedes albopictus*, sendo encontrado principalmente em regiões tropicais e subtropicais da África, nas ilhas do Oceano Índico, no Sul e Sudeste da Ásia. Foi descrita inicialmente em 1952 na África e sua propagação para outros países aconteceu após 2005 quando houve um número elevado de casos nas Ilhas Reunión (CAMPION; WEAVER; LECUIT, 2015).

A partir de 2013, o vírus se estabeleceu nas Américas, iniciando uma epidemia na América Central e em diversas ilhas do Caribe (BRASIL, 2017). No Brasil, o primeiro caso confirmado foi em setembro de 2014, na cidade de Oiapoque, localizada no Amapá, tendo sua difusão dada de maneira rápida, principalmente nos estados do Nordeste (NUNES *et al.*, 2015).

Inúmeras manifestações neurológicas foram descritas durante a epidemia nas Ilhas Reunión, como a síndrome de Guillain-Barré (GBS), encefalites, meningites e mielites. No Brasil, diversas manifestações neurológicas, incluindo GBS, mielite, encefalomielite, miosites, dentre outras, foram descritas (MEHTA *et al.*, 2018).

O período relacionado à viremia vai até 10 dias após o surgimento das primeiras manifestações clínicas. Infecções verticais podem ocorrer e são descritas apenas no momento do parto em gestantes virêmicas e, quando ocorrem, em sua maioria, provocam uma infecção neonatal grave. A transmissão transfusional é rara, devido aos rigorosos protocolos instituídos para realização desse procedimento. A infecção aguda é controlada pela resposta imune, o que torna a replicação viral indetectável a partir de 10 dias após o contágio (GERARDIN *et al.*, 2008; ^e BRASIL, 2017).

Há outras complicações graves não neurológicas como alterações cardíacas, choque, entre outras. Cefaleia, dor difusa nas costas, mialgia, náusea, vômito, poliartrite, erupção cutânea e conjuntivite podem estar presentes, porém em menor frequência. Os sintomas articulares ocorrem em maior frequência nas mãos e pés, podendo acometer ombro, cotovelo, tornozelo e joelho. Edema também pode ocorrer e geralmente é associado com uma tenossinovite. Os pacientes podem ficar incapacitados devido à intensa artralgia, à fragilidade, ao edema e à rigidez articular, sendo incapazes de realizar tarefas normais ou laborais (OPAS, 2011).

A CHIK faz diagnóstico diferencial com doenças febris associadas à artralgia, tais quais a Dengue e Zika, além das causas infecciosas, como febre reumática, artrite reumatoide e artrite séptica. Em comparação com a dengue, a Chikungunya (CHIK) possui características tais como: maior número de casos sintomáticos (> 90%); tempo de incubação curto (de 2 a 7 dias); maior período de viremia (entre 2 dias antes e 10 depois do início dos primeiros sintomas); e menor período de incubação no vetor. Tais características contribuem para o aumento da disseminação da doença e, a chance do surgimento de grandes epidemias (DONALISIO, FREITAS, 2015; ^e BRASIL, 2017).

As formas clínicas dos pacientes sintomáticos são divididas em três fases: aguda ou febril, semelhante a dengue e outras arboviroses, com duração de até 10 dias (quadro súbito de febre alta, cefaleia, dor retro-orbitária, astenia, mialgia e artralgia simétrica. Pode ainda haver exantema e outras manifestações dermatológicas, conjuntivite, sintomas gastrointestinais, neurite); subaguda, que dura até 3 meses (desaparecimento da maioria dos sintomas iniciais com exacerbação da artralgia, e tenossinovite hipertrófica subaguda em punhos e tornozelos, além de edema articular de variável intensidade); e crônica, que pode chegar a anos (permanência da artralgia devido a persistência do CHIKV nas articulações o que leva a uma inflamação local crônica, a qual resulta em dor). Casos graves da doença e óbitos ocorrem principalmente em pacientes com comorbidades e extremos de idades. Porém a letalidade do CHIKV observada até o momento é baixa e inferior a da dengue (KOHLENER *et al.*, 2018).

Já a dengue é causada por um arbovírus do gênero *Flavivirus*, pertencente à família *Flaviviridae*, sendo O DENV uma das arboviroses que apresenta grande impacto de saúde pública no Brasil, devido à ocorrência de consecutivas epidemias. Existem 04 sorotipos (DENV1 – DENV4) em cocirculação em nosso país (FARES *et al.*, 2015; ZARA *et al.*, 2016).

Igualmente às demais arboviroses, tem como vetor principal o mosquito *Aedes aegypti* (Linnaeus, 1762) (Diptera: *Culicidae*), uma espécie sinantrópica e antropofílica, a qual tem

preferência e facilidade de proliferar em áreas urbanas densamente povoadas. A infestação por *A. aegypti* e, conseqüentemente a transmissão da Dengue, tem sido um problema de saúde pública desde o início do século XX, agravando-se pela introdução do ZIKV e CHIKV no país, e recentemente com a reurbanização da Febre Amarela. Considerada pela Organização Mundial da Saúde (OMS) como uma doença negligenciada, a Dengue ganhou status de promotora e perpetuadora de pobreza, devido à associação de suas epidemias à precariedade de saneamento básico, comum em áreas de pobreza (CAVALLI *et al.*, 2019).

Diversos fatores têm sido descritos como responsáveis pela reincidência de endemias causadas por estes sorotipos virais: programas de controle e prevenção ineficazes; vigilância ineficiente; falta de recursos para pesquisas em saúde pública; urbanização e transporte de produtos; mudanças climáticas, demográficas e sociais, e; inapetência quanto aos vetores e doenças infecciosas. Em regiões ainda livres da circulação viral cresce o alerta das autoridades de saúde, principalmente com o trânsito internacional de pessoas e mercadorias que têm sido descrito como um fator que atua positivamente para a dispersão do vírus e para o aumento de casos (CAVALLI *et al.*, 2019).

A doença se destaca pelo impacto social, pois exige grande demanda por atendimento clínico e hospitalar, além de comprometer a qualidade de vida das pessoas e familiares afetados. A literatura sugere que as mudanças climáticas severas se tornam fator importante em relação à transmissão vetorial e complicações decorrentes da doença (SHEPARD *et al.*, 2011).

A dengue é uma doença dinâmica e o paciente pode apresentar rápida evolução a um quadro mais grave. O manejo dos pacientes depende do reconhecimento precoce dos sinais de alarme e do monitoramento contínuo, já que os sinais de alarme e o agravamento do quadro costumam ocorrer na fase de remissão febril. Pacientes que apresentam febre alta, acompanhada de pelo menos dois dos seguintes sintomas: cefaleia, mialgia, artralgia, prostração, são considerados casos suspeitos, com devida notificação à Vigilância Epidemiológica. Aqueles que, além dos sinais clássicos, apresentarem sinais de alarme como: vômitos persistentes, dor abdominal, hemorragia, letargia, edema, hipotensão postural, aumento de hematócrito, hepatomegalia e plaquetopenia abrupta, são considerados com maior potencialidade de agravamento do quadro, necessitando de atendimento especializado (^dBRASIL, 2016).

Manifestações graves como meningites ou encefalites, são exemplos de complicações descritas em estudos realizados no mundo, porém essas manifestações neurológicas mais graves são incomuns, porém podem ser potencialmente graves levando a óbito. Faz-se

necessário estar atento a alterações neurológicas compatíveis com tais complicações. (ARAÚJO *et al.*, 2012)

2.3 Política de Vigilância Ambiental

A Vigilância em Saúde Ambiental (VSA) no Brasil teve seu processo de estruturação institucional iniciado no fim dos anos 90, a partir da sistematização dos principais problemas de saúde e ambiente e diretrizes programáticas decorrentes de discussões durante eventos de grande impacto para as questões ambientais planetárias, os quais foram referência para as ações de planejamento em saúde e meio ambiente na época (VILLARDI, 2015).

A proposta de uma vigilância em saúde para as questões ambientais se estruturou a fim de ocupar um espaço para o desenvolvimento de atividades relacionadas ao impacto do ambiente na saúde humana. Sendo assim, a discussão e a incorporação da temática, binômio, Saúde e Ambiente no campo do conhecimento e das práticas de intervenção em saúde coletiva implicaram no desenvolvimento de uma abordagem teórico conceitual com eixo nas relações entre produção, ambiente e a saúde (VILLARDI, 2015).

As atividades que compõem a ação de vigilância devem conter processos de identificação, integração, processamento e interpretação de dados e informações, incluir o conhecimento dos problemas de saúde existentes relacionados aos fatores ambientais, sua priorização para tomadas de decisão e execução de ações relativas às atividades de promoção, prevenção e controle recomendadas e executadas pelo Sistema Único de Saúde (SUS), além de sua permanente avaliação (° BRASIL, 2015).

A dificuldade de caracterização da área, bem como os métodos e ferramentas para a produção do conhecimento e ação prática de intervenção tem sido tema de discussão entre pesquisadores e profissionais. A necessidade de estudos e ações que dizem respeito à relação da saúde com o ambiente, a importância cada vez maior das doenças e agravos não transmissíveis, a preocupação com os riscos sanitários, o desenvolvimento e implementação de instrumentos e métodos para uma vigilância da saúde com o olhar da exposição humana às situações ambientais, de contribuições às ações de promoção da saúde e da redução da morbimortalidade da população, incluindo a massa trabalhadora, foram motivadores neste processo de instituição da vigilância em saúde ambiental no Brasil (VILLARDI, 2015).

Do ponto de vista da implementação das ações de VSA no SUS, de acordo com o Ministério da Saúde (MS), a forma de inserção institucional para a realização das atividades da VSA ocorre de forma diferenciada em cada esfera de gestão, respeitando as

particularidades da organização local em função dos seus contextos e necessidades. No início dos anos 2000, foram desenvolvidas diversas ações e construídas diretrizes as quais consolidaram a Política Nacional de Saúde Ambiental no país (BRASIL, 2015).

2.4 Predição de arboviroses e criadouros

No preparo de modelos de predição, os dados colhidos e agrupados constituem um importante elemento para a relevância e utilização dos resultados obtidos. No processo de predição, os modelos são elaborados a partir de análises ancestrais do evento a ser estudado. Portanto, existe a necessidade de obter-se grande quantidade de dados para a criação deste modelo de predição. A quantidade de dados disponíveis é tão importante quanto à confiança desses, onde, em via de regra, tais dados são obtidos através de instituições governamentais e agências reguladoras oficiais. Contudo novas fontes de dados vêm sendo requisitadas para a elaboração de modelos preditivos (SIRIYASATIEN *et al.*, 2018).

As fontes de dados podem ser classificadas como: convencionais e modernas. As fontes convencionais incluem: Informações médicas e epidemiológicas (obtidas através de centros de saúde); Dados climáticos e ambientais (obtidos através de departamentos meteorológicos) e; Dados demográficos e geográficos (obtidos através de fontes governamentais e agências reguladoras) (MARQUES-TOLEDO *et al.*, 2017; MORSY *et al.*, 2018).

Quanto às fontes de dados modernos, essas são obtidas através de redes sociais e através de busca na internet. Em localidades onde não há disponibilidade de internet, pode-se utilizar o telefone para obtenção destes dados de predição. Após a aquisição dos dados, estes são processados antes de sua aplicação em um modelo de predição. Este processamento é importante para aumentar a acurácia e consistência destes. Quando existem uma grande quantidade de dados incompletos ou incorretos dentro do conjunto de dados, ocorre comprometimento da eficácia do modelo preditor (LI *et al.*, 2017; SIRIYASATIEN *et al.*, 2018).

Para a predição de arboviroses, existem duas abordagens: a abordagem estatística e a modelagem dinâmica. Na abordagem estatística, os métodos mais comuns são: ARIMA, SARIMA e regressão multivariada de Poisson. Contudo tais métodos não permitem compreender as características dinâmicas da transmissão de doenças (CAO *et al.*, 2018).

Trabalhos recentes para predição de arboviroses têm se concentrado em modelos populacionais, ou seja, na modelagem da transmissão entre indivíduos em uma população.

Para tal, aplicam-se técnicas de aprendizagem de máquina para a criação de um modelo que será utilizado na predição. Os algoritmos de aprendizagem mais utilizados são: as redes neurais artificiais e a máquina de vetores de suporte (BELTRÁN *et al.*, 2018; CAO *et al.*, 2018; MUSAH *et al.*, 2019; RUBIO-SOLIS *et al.*, 2019).

2.5 Aprendizado de máquina

É a área da inteligência artificial que possui a capacidade de aprender, por métodos e algoritmos, através de informações obtidas em uma base de dados, ou seja, por técnicas computacionais, a máquina é capaz de identificar e descrever padrões estruturais de um grupo de dados (WITTEN, FRANK, 2005; SIRIYASATIEN *et al.*, 2018).

O aprendizado é classificado em: Supervisionado, onde este método fornece ao programa um conjunto de exemplos para o treinamento do *software*, com padrões esperados ou pré-determinados. Geralmente, determina-se antecipadamente este conjunto de parâmetros com o objetivo de construir um classificador capaz de identificar de maneira correta a situação em que tais dados estão definidos; e Não-supervisionado, onde o algoritmo não precisa do fornecimento de exemplos, sendo este o responsável em procurar e determinar os padrões, agrupando-os de forma aprendida e automática (PIMENTA, ALVIM, MEIRELLES, 2020).

2.5.1 Regressão linear

Regressão linear corresponde a um método de análise estatística capaz de avaliar a correlação entre duas ou mais variáveis. Para tal, assume-se que os dados possuem um comportamento linear. Sua ideia é expressar a classe, como uma combinação linear dos atributos com seu pesos pré-determinados (WITTEN, FRANK, 2005).

Quando um resultado ou classe é numérico, e todos os atributos também são numéricos, lineares, a regressão linear é uma técnica a ser considerada. Esse é um método básico em estatística (WITTEN, FRANK, 2005).

No método da regressão linear, o algoritmo calcula os pesos (coeficientes da equação), em busca da melhor representação dos dados, buscando minimizar a soma dos quadrados da diferença de todos os dados do treinamento. A técnica é simples, basta ter o conhecimento matemático adequado. Esta envolve uma operação de inversão de matriz, contudo, isso está disponível no software que será utilizado. Realizada a conclusão matemática, o resultado

obtido corresponde a um conjunto de pesos numéricos, com base nos dados de treinamento, que podem ser usados para prever a classe de novas instâncias (WITTEN, FRANK, 2005).

A regressão linear é um método simples e excelente para previsão numérica, tendo sido amplamente utilizado em aplicações estatísticas por anos. Contudo modelos lineares sofrem com a desvantagem de serem lineares. Por exemplo, se os dados exibirem um valor não linear dependente, a linha reta mais adequada será encontrada, onde o “ser melhor” será interpretado como sendo a menor diferença ao quadrado da média. Todavia, modelos lineares servem bem como blocos de construção para uma aprendizagem mais complexa de métodos (WITTEN, FRANK, 2005).

2.5.2 Máquina de Vetores de Suporte

A máquina de vetores de suporte ou SVM (*Support Vector Machine*) corresponde a uma técnica de aprendizagem de máquina supervisionado, utilizada para análise de dados e reconhecimento de padrão para classificação e regressão (SHARMA *et al.*, 2015). A ideia do SVM para regressão visa encontrar o melhor hiperplano “H” para representar os dados $x \in \mathbb{R}^n$, onde esses são mapeados através de uma função matemática também conhecida como *kernel*, onde uma regressão linear é aplicada no hiperplano correspondente (LIU *et al.*, 2019).

3 TRABALHOS RELACIONADOS

Diversos estudos vêm sendo realizados por parte da comunidade acadêmica para exploração de diferentes técnicas para redução e controle do *Aedes aegypti*, visto que apresenta impacto social e ambiental. Verísimo *et al.* (2016) propuseram políticas de controle da dengue em cada estação do ano, através do algoritmo genético (AG), com a finalidade de minimizar os gastos da gestão pública relacionados ao controle do *Aedes aegypti*. Este algoritmo, em que a busca segue à direção de uma tendência (com uma informação semelhante à fornecida pelo gradiente), o que não é feito por nenhum operador genético convencional, mas mantendo a vantagem do AG de avaliar apenas a função objetivo (sem nenhum cálculo de derivadas). Neste trabalho foram propostas três políticas de controle do vetor da dengue, considerando o ano com 360 dias e dividido em três períodos: favorável, intermediário e desfavorável. O algoritmo genético real polarizado foi implementado no software MATLAB, sendo simulado 30 vezes. O estudo verificou que o controle realizado na estação do verão foi mais eficiente quando comparado com o controle realizado nas demais estações do ano.

Freitas *et al.* (2018) em sua pesquisa propuseram modelos estatísticos de séries temporais capazes de prever possíveis surtos. Os dados utilizados se referem a número de notificações mensais de dengue em cinco municípios de Pernambuco (Serra Talhada, Ipojuca, Vitória de Santo Antão, Recife e Petrolina) que foram disponibilizados pelo Instituto Nacional de Meteorologia (INMET), no período de janeiro de 2000 a dezembro de 2016. A metodologia de Box & Jenkins foi utilizada no estudo, isto é, os modelos SARIMA. Foram feitas as previsões e a análise residual a partir dos modelos propostos. Verificou-se que os resíduos não se comportam como uma sequência de variáveis aleatórias independentes, identicamente distribuídas com média zero e variância constante. Esses modelos conseguem captar o nível e inclinação (valores centrais), tais modelos são bons em prever as observações para longos intervalos de tempo. Concluíram que o modelo SARIMA apresenta melhores resultados, pois consegue captar os comportamentos sazonais, além de apresentar com boa acurácia os casos de dengue de tais municípios. Como vantagem, esse modelo permite prever o número de casos em períodos subsequentes às séries estudadas. O uso da SARISMA (Média Móvel Integrada Autorregressiva Sazonal) é útil em situações em que os dados de séries temporais exibem flutuações sazonais periódicas que se repetem com aproximadamente a mesma intensidade a cada ano.

Mittelmann e Soares (2017) em seu estudo propuseram desenvolver um modelo de previsão de casos de dengue com Redes Neurais Artificiais (RNAs) para o município de Guarulhos – São Paulo. Este trabalho compara a utilização de duas distintas RNAs, as redes Perceptron Multicamadas (MLPs) e as Redes Neurais Auto-Regressivas (NARXs) com entradas Exógenas. As redes MLPs e NARXs foram comparadas entre si para eleição da rede com melhor desempenho na previsão de dengue na área estudada. O melhor desempenho foi obtido pela MLP modelada com 10 neurônios na camada oculta. O conjunto de entrada que obteve este resultado foi composto pela quantidade de casos de dengue dos dois meses anteriores ao mês em que se realizava a previsão. Nota-se que as variáveis climáticas não foram as mais adequadas para estimar a quantidade de casos de dengue, pois a rede treinada com informações sobre casos passados de dengue teve um desempenho superior. As amostras de dados da cidade estudada são constituídas de cinco atributos de entrada (precipitação total, temperatura máxima, temperatura mínima, temperatura do ar média e umidade relativa média) e um de saída (número de casos de dengue). A base de dados meteorológicos consiste em dados mensais de janeiro de 2009 a novembro de 2014 referentes à precipitação total (mm), temperatura máxima média, temperatura compensada média, temperatura mínima média e umidade relativa média(%). Foram selecionados apenas os dados quantitativos referentes aos casos autóctones de dengue na cidade, a fim de alcançar maior correlação com as variáveis climáticas da região. 70% do conjunto total de dados disponíveis foi aleatoriamente escolhido para o subconjunto de treinamento. Por sua vez, os dados restantes (30%) integraram o subconjunto de teste e validação. Foram modeladas e treinadas redes com diferentes parâmetros iniciais. Os resultados apresentados pelas redes mostram que é possível fazer a previsão de casos de dengue na área de estudo, com erro e antecedência aceitáveis, utilizando RNAs com dados meteorológicos e/ou históricos da quantidade de casos de dengue de meses anteriores. No entanto, toda modelagem matemática, a generalização dos resultados obtidos em um estudo de caso específico não pode ser utilizada diretamente para outros casos, pois se deve levar em consideração que as características de cada região são únicas, sendo a utilização dos modelos construídos neste trabalho restrito a área e estudo selecionado.

Mattioli, Andrade e Estevez (2017) apresentaram um modelo de predição de casos dengue através da aplicação de treinamento de rede neural do tipo Perceptron de múltiplas camadas. Realizaram testes com diferentes configurações, sendo para cada configuração foram realizadas 10 repetições, calculando-se o erro médio e o tempo médio de execução. A rede neural foi alimentada com os dados oferecidos pela Secretaria de Estado de Saúde e o SINAM (Sistema de Informação de Agravos de Notificação). Observou-se que a rede neural

resultante foi muito próxima ao resultado obtido por uma série real que serviu como parâmetro de comparação para verificarmos o desempenho da rede neural desenvolvida. Esse trabalho utilizou uma rede neural artificial do tipo Perceptron de múltiplas camadas (MLP). Sendo indicada para previsão de dados, já que seu treinamento pode ser supervisionado com algoritmos de *backpropagation* (retropropagação). Os MLP têm sido aplicados, através do seu treinamento de forma supervisionada com um algoritmo de retropropagação de erro. Concluíram que a rede desenvolvida no trabalho realizado poderá servir como método de predição e poderá sugerir atos futuros de prevenção contra a dengue.

Melo e Moraes (2018) em seu trabalho visaram o desenvolvimento de um sistema de suporte à decisão baseado em informação espacial, que considera diferentes fatores relacionados a uma situação de incerteza através da aplicação de um sistema baseado em regras fuzzy que permite a geração de mapas de decisão para detectar áreas de prioridade de combate a dengue. Essa arquitetura apresenta como vantagem ser flexível e permite que apenas alguns módulos sejam utilizados na solução de problemas, de acordo com a sua especificidade e necessidade. Os mapas têm por objetivo orientar os gestores de saúde em tomada de decisões, como a intervenção ou não sobre determinadas doenças. O sistema foi aplicado ao estudo no estado da Paraíba entre os anos de 2009 a 2013. Os resultados obtidos são utilizados para se gerar mapas coropléticos (coloridos) para melhor visualizar a região geográfica. O espaço de decisões usando regras fuzzy é dado pelo conjunto: Não prioritário, Possivelmente não prioritário, Possivelmente prioritário e Prioritário, o qual representa todos os níveis de prioridade em que um município pode ser classificado. Sendo possível que o modelo informe a condição dos municípios que devem ser prioritários. Foram realizadas 1115 aplicações para contemplar os 223 municípios da Paraíba nos cinco anos abordados, para no fim serem gerados os cinco mapas de decisão, sendo um para cada ano.

Hamlet *et al.*(2018) em seus estudos, procuraram avaliar a influência das variações sazonais nos fatores climáticos em associação à sazonalidade dos relatórios do *Aedes aegypti*. Para tal, foi construído um índice de adequação de temperatura para a transmissão da febre amarela, capturando a dependência da temperatura do comportamento do vetor e a replicação viral dentro deste. Também, foi ajustada uma série de modelos de regressão logística multinível a um conjunto de dados de relatórios de inteligência artificial em todo o continente africano, levando em considerando a localização e a sazonalidade da ocorrência de modelos sazonais, quanto ao índice de adequação da temperatura, precipitação e índice de vegetação aprimorado como co-variáveis, associados a outros indicadores demográficos. O ajuste realizado no modelo foi avaliado pela área sob a curva e, tais modelos foram classificados de

acordo com o critério de informação de Akaike, o qual foi utilizado para ponderar as saídas do modelo visando criar previsões combinadas de modelos. O modelo sazonal foi capaz de capturar, com precisão, as heterogeneidades geográficas e temporais na transmissão da febre amarela, não apresentando desempenho significativamente pior do que o modelo anual, o qual apenas capturou a distribuição geográfica. A validade das previsões foi avaliada através da validação cruzada de exclusão única, onde dividiu-se o conjunto de dados atribuindo de maneira aleatória os países a subconjuntos, sendo ajustado os modelos ao conjunto de dados, visando criar previsões fora da amostra, sendo repetido 10 vezes, o que resultou em 10 alocações diferentes de províncias. Para cada uma destas, foi calculada a média entre as 10 realizações. A relação entre adequação da temperatura e precipitação foi tida como responsável pela grande parte da ocorrência da doença, oferecendo assim, uma explicação estatística para a variabilidade espaço-temporal em sua transmissão.

Salami *et al.*(2020) em seu estudo, teve por objetivo prever a importação de casos de dengue na Europa em 21 países, através do aprendizado de máquina e métodos independentes de modelo. Realizou-se o treinamento de quatro algoritmos de classificação: Mínimos quadrados parciais (pls), modelos lineares generalizados regularizados de laço e rede elástica (glmnet), floresta aleatória (randomForest), impulso extremo do gradiente (xgboost), usando dados históricos de 06 anos (2010 -2015). O conjunto de dados foi dividido aleatoriamente em dois conjuntos, 70% para treinamento e 30% teste.

O desempenho de cada classificador foi avaliado usando a área sob a curva característica de operação receptora (AUC), medidas de sensibilidade (taxa positiva verdadeira) e especificidade (taxa positiva falsa). Todos os quatro modelos tiveram um desempenho bom. Porém avaliando a pontuação da AUC, as previsões do randomForest e xgboost foram melhor adaptados ao conjunto de dados, com diferenças quase insignificantes. O xgboost modelo supera o randomForest, com uma taxa positiva verdadeira de 0,88 e uma taxa positiva falsa de 0,12, o xgboost foi elegido como o modelo ideal para conjunto de dados. Sendo capaz de prever 88% dos casos de importação de dengue em nosso conjunto de dados de teste.

As variáveis preditoras mais importantes foram a taxa de incidência de dengue no país de origem, tamanho da população e volume de passageiros aéreos. Medidas de centralidade da rede de transporte aéreo, descrevendo o posicionamento dos países europeus na rede de viagens aéreas também influenciaram nas predições. Concluiu-se que o estudo apresentou alta capacidade preditiva. Com o modelo preditivo e as ferramentas de interpretabilidade pode ser

aplicado em nível regional ou nacional para desenvolver uma ferramenta de predição visando evitar a importação de dengue.

Tabela 1 – Resumo dos trabalhos relacionados e suas principais características

Estudo	Proposta	Experimento	Método de classificação
Verísimo <i>et al.</i> 2016	Propuseram políticas de controle da dengue em cada estação do ano, através do algoritmo genético.	algoritmo genético real polarizado	software MATLAB®
Freitas <i>et al.</i> 2018	Propuseram modelos estatísticos de séries temporais capazes de prever possíveis surtos de dengue.	notificações mensais de dengue em 05 municípios de PE, no período de janeiro de 2000 a dezembro de 2016	modelos SARIMA
Mittelmann e Soares 2017	Propuseram desenvolver um modelo de previsão de casos de dengue	compara a utilização das redes Perceptron Multicamadas (MLPs) e as Redes Neurais Auto-Regressivas (NARXs) com entradas Exógenas.	Redes Neurais Artificiais
Mattioli, Andrade e Estevez 2017	Apresentar um modelo de predição de casos dengue.	treinamento de rede neural do tipo Perceptron de múltiplas camadas	rede neural artificial do tipo Perceptron de múltiplas camadas
Melo e Moraes 2018	visaram o desenvolvimento de	mapas de decisão para detectar áreas de	aplicação de um sistema baseado em

	um sistema para detectar áreas de prioridade de combate a dengue	prioridade de combate a dengue.	regras fuzzy
Hamlet <i>et al.</i> 2018	procuraram avaliar a influência das variações sazonais nos fatores climáticos em associação à sazonalidade dos relatórios do <i>Aedes aegypti</i>	construído um índice de adequação de temperatura para a transmissão da febre amarela, capturando a dependência da temperatura do comportamento do vetor e a replicação viral dentro deste.	-
Salami <i>et al.</i> 2020	prever a importação de casos de dengue na Europa em 21 países, através do aprendizado de máquina e métodos independentes de modelo	treinamento de quatro algoritmos de classificação	-

Fonte: A Autora, 2019.

4 PROPOSTA: MODELO PREDITOR DE CRIADOUROS DE *Aedes aegypti*

Neste capítulo, apresenta-se a área de estudo utilizada nesta pesquisa para a predição dos criadouros de *Aedes aegypti*. Também são apresentadas as configurações utilizadas e as bases de dados que foram utilizadas ao longo da pesquisa: a base de dados dos criadouros de *Aedes aegypti* (2013- 2016), disponibilizada pela Prefeitura da Cidade do Recife, e as bases de dados das variáveis climáticas (temperatura, velocidade dos ventos e pluviometria), que são disponibilizadas pelo Instituto Nacional de Meteorologia e pela Agência Pernambucana de Águas e Climas.

4.1 Área de estudo

A pesquisa foi realizada no município do Recife, capital do estado de Pernambuco, com população de 1.537.704 habitantes, com uma densidade demográfica de 7.039, 64 habitantes/Km², segundo o último censo realizado (IBGE, 2011) e com estimativa de 1.633.697 habitantes, para o ano de 2019 (IBGE, 2019).

O município se situa no litoral nordestino e ocupa uma posição central, a 800 km das outras duas metrópoles regionais, Salvador e Fortaleza. Apresenta uma superfície territorial de 218,4 km² e limita-se ao norte com as cidades de Olinda e Paulista, ao sul com o município de Jaboatão dos Guararapes, a oeste com São Lourenço da Mata e Camaragibe e a leste com o Oceano Atlântico (RECIFE, 2014).

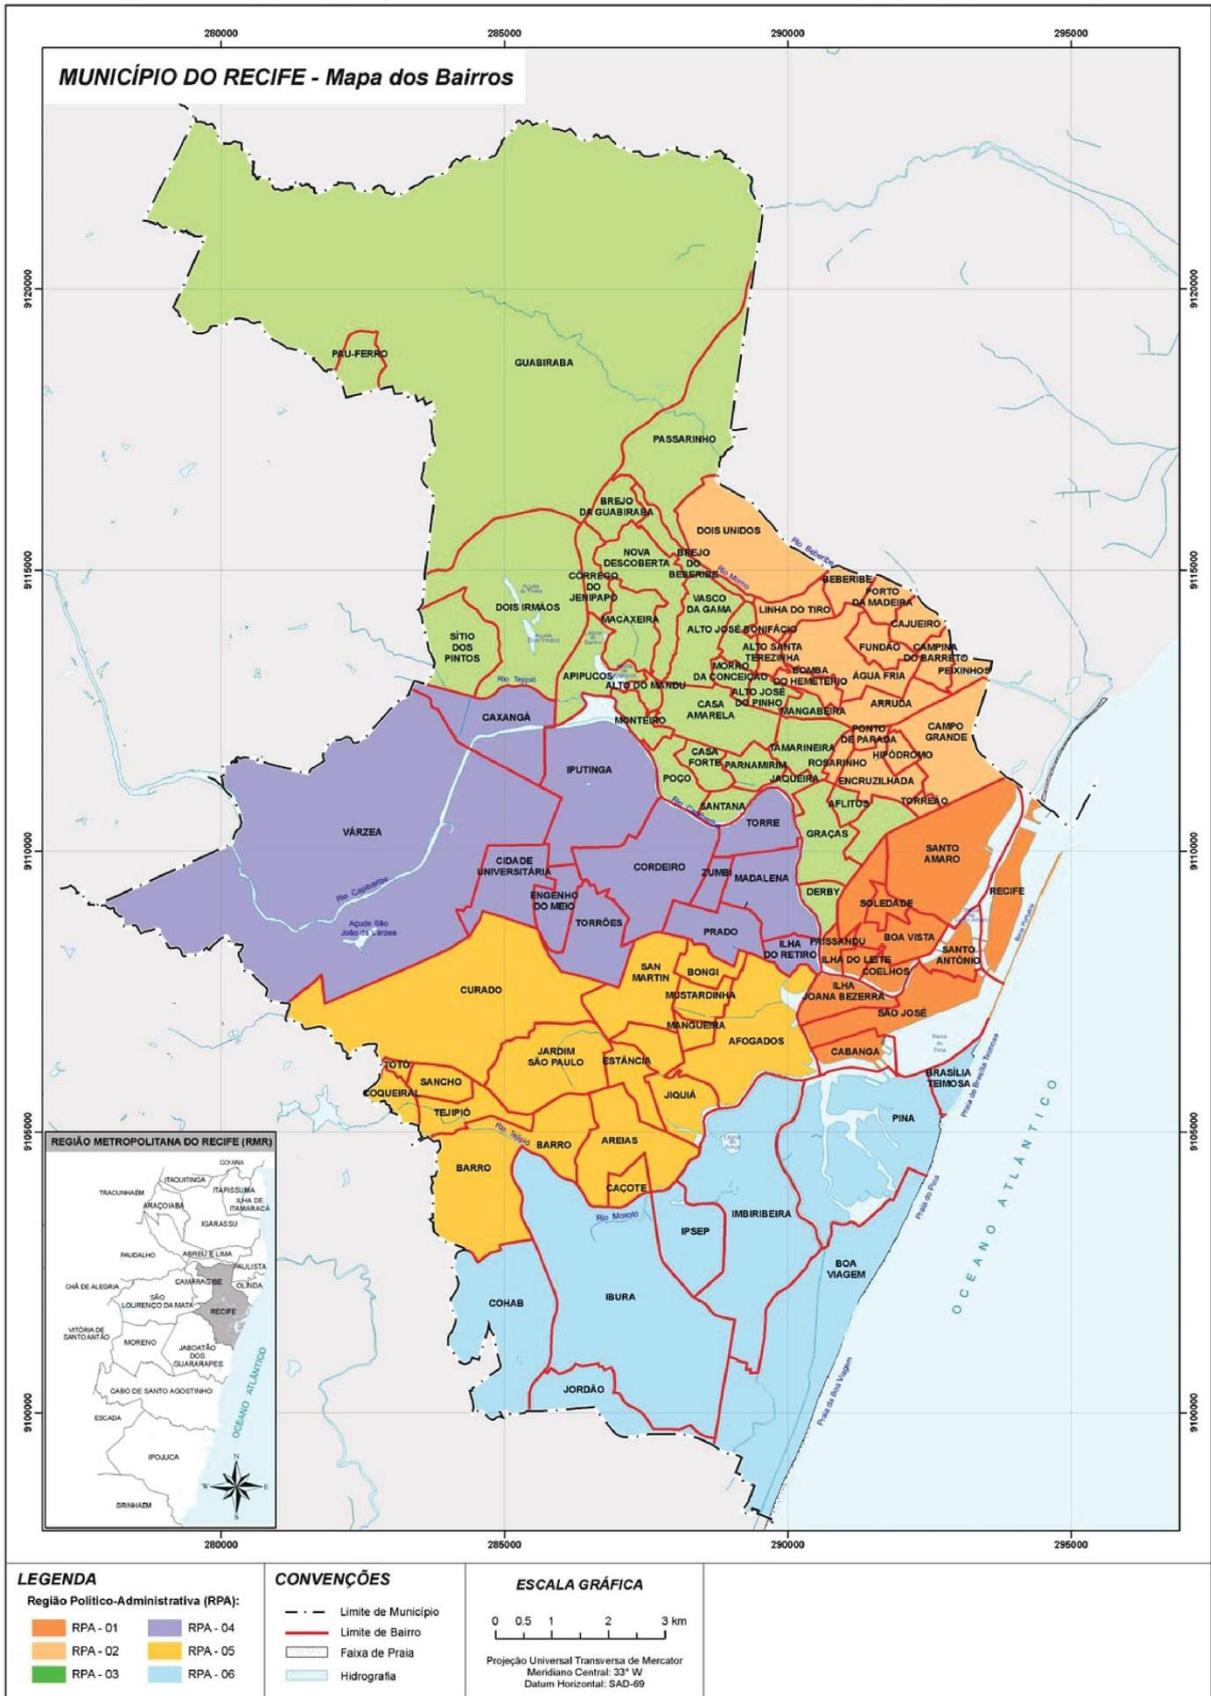
Para efeito de formulação, execução e avaliação permanente das políticas e do planejamento governamentais, o município do Recife-PE foi dividido, para o setor de saúde, em Regiões Político-Administrativas (RPA's) as quais cada uma corresponde a um Distrito Sanitário (DS). A cidade está dividida em 94 bairros aglutinados em 06 RPA's (figura 01) (RECIFE, 2014).

- a) RPA 1: Boa Vista; Cabanga; Coelhos; Ilha do Leite; Ilha Joana Bezerra; Paissandu; Recife; Santo Amaro; Santo Antônio; São José; Soledade.
- b) RPA 2: Água Fria; Alto Santa Terezinha; Arruda; Beberibe; Bomba do Hemetério; Cajueiro; Campina do Barreto; Dois Unidos; Encruzilhada; Fundão; Hipódromo; Linha do Tiro; Peixinhos; Ponto de Parada; Porto da Madeira; Rosarinho; Torreão.
- c) RPA 3: Aflitos; Alto do Mandu; Alto José Bonifácio; Alto José do Pinho; Apipucos; Brejo da Guabiraba; Brejo de Beberibe; Casa Amarela; Casa Forte; Córrego do Jenipapo; Derby; Dois Irmãos; Espinheiro; Graças; Guabiraba; Jaqueira; Macaxeira;

Mangabeira; Monteiro; Morro da Conceição; Nova Descoberta; Pau-Ferro; Parnamirim; Passarinho; Poço da Panela, Santana; Sítio dos Pintos; Tamarineira; Vasco da Gama.

- d) RPA 4: Caxangá; Cidade Universitária; Cordeiro; Engenho do Meio; Ilha do Retiro; Iputinga; Madalena; Prado; Torre; Torrões; Várzea; Zumbi.
- e) RPA 5: Afogados; Areias; Barro; Bongü; Caçote; Coqueiral; Curado; Estância; Jardim São Paulo; Jiquiá; Mangueira; Mustardinha; San Martin; Sancho; Tejipió; Totó.
- f) RPA 6: Boa Viagem; Brasília Teimosa; Cohab; Ibura; Imbiribeira; Ipsep; Jordão; Pina.

Figura 2 – Divisão territorial do Recife-PE



Fonte: Gerência Geral de Planejamento e Orçamento – Sesau / Recife, 2015.

Em relação à distribuição da população por sexo, as mulheres representam o maior percentual com 53,84% enquanto os homens correspondem a 46,16% e a faixa etária com maior percentual foi a de 25 a 29 anos com 9,5% do total da população. Segundo o DATASUS quanto à esperança de vida ao nascer, no estado de Pernambuco, no ano 2000 era de 65 anos e em 2010 passou para 71,1 anos para ambos os sexos, um aumento de 6,1 anos nesse indicador. (NESP, 2016)

O Índice de Desenvolvimento Humano Municipal (IDHM) em Recife em 2010 foi de 0,772. Na classificação dos municípios brasileiros – segundo Atlas do Desenvolvimento Humano no Brasil 2013 - Recife ocupa a 210ª posição. O IDHM é calculado considerando três dimensões no município: a Educação, Longevidade e a Renda. Esta abordagem não se limita ao desenvolvimento econômico e permite que seja realizada uma comparação entre índices de diferentes localidades ao longo do tempo, com isso é possível conhecer melhor o perfil de um município e considerar essas informações na tomada de decisão, criação de políticas públicas visando à melhoria da qualidade de vida da população. (NESP, 2016)

Em Recife, no ano de 2010, o IDHM, para a educação foi de 0,698, em uma escala de 0 a 1. Este índice teve uma grande ascendência entre os anos de 1991 e 2010, o que caracteriza uma maior escolaridade da população do município, com mais crianças e jovens nas escolas ou completando ciclos, no Brasil ensino fundamental e médio (Atlas do Desenvolvimento Humano no Brasil, 2013).

Em Recife a renda per capita cresceu aproximadamente 92,4% nas duas últimas décadas levando-se em consideração o período de 1991 a 2010 –, e no estado de Pernambuco crescendo por volta de 90,8%, sendo a renda per capita maior no município do que no estado. A renda per capita em Recife, em 2010, foi de R\$ 1.144,26 e no estado de Pernambuco foi R\$ 525,64 (NESP, 2016).

4.2 Base LIRAA (Brasil, 2012)

Consiste em uma amostragem larvária bimestral de *Aedes aegypti* em um município para obter a estimativa da infestação pelo vetor da dengue. Essa amostragem deve ser precedida de um mapeamento e estratificação dos imóveis do município em unidades territoriais homogêneas de 2500 a 12000 imóveis denominadas estratos.

É ferramenta fundamental para direcionamento e intensificação das ações antivetoriais, pois apresenta a magnitude e a distribuição da infestação por tipo de criadouro nas diferentes regiões do município.

Os índices obtidos pelo LIRAA são: Índice de Infestação Predial, que corresponde ao percentual de imóveis com presença de criadouros positivos para larvas de *Aedes aegypti*; Índice de Breteau, que quantifica o nº de criadouros positivos para larvas de *Aedes aegypti* em 100 imóveis e; Índice por tipo de Recipiente, que determina a distribuição percentual de cada tipo de recipiente, em relação ao total de criadouros encontrados.

Por meio do Índice de Infestação Predial pode-se levantar o percentual de edifícios positivos (com a presença de larvas de *A. aegypti*). Embora seja utilizado para mensurar o nível populacional do vetor, não considera o número dos recipientes positivos nem o potencial produtivo de cada recipiente. Apesar desses problemas, é de grande utilidade, pois fornece o percentual de casas positivas.

O Índice de Breteau é o índice mais comumente utilizado e leva em consideração a relação entre o número de recipientes positivos e o número de imóveis pesquisados, embora também não leve em conta a produtividade dos diversos tipos de criadouros. É corrigido de forma que o resultado seja expresso para 100 imóveis.

Já o Índice por tipo de Recipiente, corresponde à relação em porcentagem entre o número do tipo de recipiente positivo e o número de recipientes positivos pesquisados (para larvas). Esse índice ressalta a eventual importância de determinado criadouro, dentre os positivos, e, conseqüentemente, indica a necessidade de adoção de medidas específicas de controle.

A utilização concomitante destes índices proporciona uma avaliação satisfatória da densidade vetorial, fornecendo um parâmetro razoável para a indicação do risco de transmissão de dengue, desde que adequadamente interpretados, podendo ser direcionadas ações específicas conforme preconizado.

O LIRAA tem a vantagem de apresentar, de maneira rápida e segura, os índices de infestações larvários (Predial e Breteau), podendo ser empregado como instrumento de avaliação dos resultados das medidas de controle, incluindo-se também dados referentes aos tipos de recipientes, tornando possível redirecionar e/ou intensificar algumas intervenções, ou ainda, alterar as estratégias de controle adotadas.

4.3 Métodos de predição e configurações utilizadas

Os dados referentes aos criadouros do *Aedes aegypti* apresentam-se disponível por bimestre, sendo organizado por ano e bairros. Já para as bases de dados (temperatura, velocidade dos ventos e pluviometria) foram organizadas por bimestre e ano. O conjunto de

predição foi elaborado por bimestre, sendo gerado um conjunto de imagens as quais contemplam a distribuição dos criadouros de *Aedes aegypti* e os *rasters* de distribuição de variáveis climáticas (temperatura, velocidade dos ventos e pluviometria).

Fatores climáticos como chuva, temperatura e umidade estão entre as causas do aumento nos números de criadouros do *Aedes aegypti*. O comportamento dos mosquitos e a eficácia da transmissão dos arbovírus são determinados pelas condições climáticas. Isso ocorre porque chuvas, temperatura e umidade afetam a interação de vetores biológicos e vetores virais, ao longo da vida, idade de acasalamento, disseminação, alimentação e replicação viral mais rápida (TOSEPU *et. al.*, 2018).

Os dados referentes à temperatura e velocidade dos ventos foram obtidos através da base de dados do Instituto Nacional de Meteorologia (INMET), enquanto que os dados relacionados aos índices pluviométricos foram obtidos a partir da base de dados do sistema de informação geográfica da Agência Pernambucana de Águas e Climas (APAC), onde estão registrados dados hidrometeorológicos mensais desde 2006. Para este estudo, foram utilizados os dados dos anos de 2013 a 2014.

Para a cidade do Recife, os registros de temperatura e velocidade dos ventos são realizados por uma estação localizada no bairro da Cohab. Sendo assim, foi utilizada a distribuição gaussiana para estimar os valores dessas variáveis climáticas para um único ponto em cada bairro do município.

Os valores de temperatura e velocidade dos ventos de cada ano foram separados por bimestre e utilizando o software Quantum GIS (QGIS), versão 2.18, uma camada vetorial de pontos foi construída (.shp) para cada variável climática.

Para poder estimar a distribuição de temperatura e velocidade dos ventos em todo o território recifense, foi utilizada a interpolação pelo inverso da distância (IDW), utilizando o software QGIS, para obter os valores das variáveis climáticas nos pontos desconhecidos.

Como resultado da interpolação, obteve-se uma imagem *raster* da distribuição da temperatura e velocidade dos ventos para cada mês dos anos de 2013 a 2016. Os registros pluviométricos da cidade do Recife são realizados por três estações. Para estimar os registros pluviométricos para cada bairro, também foi utilizada a distribuição gaussiana. O valor máximo considerado foi o valor acumulado máximo entre as três estações, enquanto que a média considerada foi a média do acumulado de chuva das três estações. Assim como no caso da distribuição da temperatura e velocidade dos ventos, para estimar a distribuição de chuva em todo território recifense, também foi utilizada a interpolação IDW e como resultado obteve-se uma imagem *raster* da distribuição de chuvas para cada mês dos anos de 2013 a

2016. A escala utilizada em todos os *rasters* gerados foi de 1:174.190, para que as imagens pudessem ficar sobrepostas umas às outras.

Após a elaboração dos conjuntos de predição, foram gerados arquivos (.arff) referentes aos conjuntos de imagens dos seis bimestres que antecedem o bimestre o qual se deseja prever. Desta forma, foram montados 18 conjuntos de predição, cada um com 15446 instâncias e 45 atributos, no qual a saída de cada conjunto de predição é valor do pixel da distribuição dos criadouros de *Aedes aegypti* na coordenada correspondente. Os conjuntos de 155446 instâncias foram estabelecidos como conjuntos de teste.

O conjunto de treino foi elaborado utilizando o software Weka. Esta ferramenta permite que uma nova base de dados seja criada com valores aleatórios para instâncias, com as mesmas características da base original (WITTEN; FRANK, 2005). O número de instâncias da nova base deve ser especificado. Portanto, os conjuntos de treinamento foram gerados com o número de instâncias equivalente a 30% o conjunto original. Os conjuntos contendo 155446 instâncias foram utilizados para testar os modelos criados pelo melhor regressor.

Foram realizados experimentos computacionais utilizando um software para aprendizado de máquina, o Weka, na versão 3.8. Sendo utilizados para predição os regressores: Regressão linear, *Kernel* polinomial 1 e 2, e o *Kernel* RBF. Utilizou-se 30% dos dados para o treinamento do modelo e 70% dos dados para teste deste modelo. O treinamento e o teste utilizaram validação cruzada. Os testes foram individuais e repetidos 30 vezes para a predição da distribuição de criadouros de *Aedes aegypti* para cada bimestre de cada ano.

Os dados referentes ao levantamento rápido de índices de infestação pelo *Aedes aegypti* foram fornecidos pela Prefeitura Municipal do Recife-PE. Os índices de infestação foram separados por bairro e bimestre e utilizando o software Quantum GIS (QGIS), versão 2.18, onde uma camada vetorial de pontos foi construída (.shp) localizando os pontos das amostras. Para estimar a distribuição de criadouros de *Aedes aegypti* em pontos desconhecidos, foi utilizada a interpolação pelo inverso da distância (IDW), a qual é baseada na distância ponderada de um ponto amostral. Como resultado da interpolação, obteve-se uma imagem raster para cada bimestre dos anos de 2013 a 2016.

5 MATERIAIS E MÉTODOS

Neste capítulo, apresenta-se a os *softwares* utilizados ao longo da pesquisa para a predição dos criadouros de *Aedes aegypti*, na cidade do Recife.

5.1 Python

Python é considerada uma linguagem de programação computacional interativa, a qual é orientada a objetos. A mesma incorpora módulos, exceções, digitação dinâmica, tipos de dados dinâmicos de alto nível e classes. O programa é capaz de ser executado em várias plataformas (PYTHON SOFTWARE FOUNDATION, 2020).

Para execução desta pesquisa foi utilizada a versão 3.7.4, a qual destinou-se à organização das bases de dados e estimativa dos valores ausentes da base de dados das variáveis climáticas. Outrossim, o referido programa foi utilizado na geração das imagens de predição das validações dos modelos preditores.

5.2 Quantum GIS (QGIS)

Quantum GIS (QGIS) corresponde a um sistema de informações geográficas de código aberto de fácil manipulação, o qual é licenciado pela *General Public License*. É um projeto oficial e voluntário da *Open Source Geospatial Foundation*. Pode ser executado em diversas plataformas, suportando funcionalidades de vetores, varreduras e bancos de dados. Outros formatos podem ser adicionados através de *plug-in* (QGIS DEVELOPMENT TEAM, 2020). Neste estudo foi utilizada a versão 2.18.25 no intuito de gerar os mapas de distribuição dos criadouros, das variáveis climáticas e das predições realizadas com rótulos e legendas.

5.3 Weka

O programa Weka (*Waikato Enviroment for Knowledge Analysis*), o qual foi desenvolvido pela Universidade de Waikato, Nova Zelândia, corresponde a um *software* que detém uma coleção de algoritmos de aprendizagem de máquina, além de ferramentas para pré-processamento de dados. Possibilita testar uma base de dados utilizando diversos algoritmos. É escrito na linguagem computacional Java e, por ser um *software* de código aberto, está sob os termos da *General Public License*. Podendo o mesmo ser executado em várias plataformas (WEKA, 2020; WITTEN; FRANK, 2005). Nesta pesquisa, foi utilizada a

versão 3.8, visando gerar as bases de dados para treinamento, bem como, para avaliação dos regressores para a predição da distribuição dos criadouros de *Aedes aegypti* no Recife-PE.

6 RESULTADOS E DISCUSSÃO

Foi realizada uma avaliação quantitativa dos regressores utilizados nesta pesquisa, onde para análise dos dados, foram calculados o Coeficiente de Correlação (CC), como qualidade global e, o Erro Quadrático Relativo Percentual (RMSE%), como qualidade local. Além destes, também foi calculado o Erro Quadrático Médio (MAE).

O CC corresponde a uma medida da correlação estatística entre os valores esperados e os valores preditos, podendo este variar de (-1 a 1), onde (-1) representa uma péssima correlação entre os valores esperados e os valores preditos, (0) indica que não há correlação entre os resultados, e (1) representa uma correlação total dos resultados (WITTEN, FRANK, 2005).

O valor do CC serve como um avaliador geral do regressor. Portanto, é possível obter um alto valor para esse e, ao mesmo tempo, obter altos valores para os erros locais. Devido a isso, o CC não pode ser a única métrica utilizada para avaliar o desempenho dos modelos. No intuito de evitar uma avaliação superficial dos regressores, o MAE, o qual corresponde a uma métrica de erro local, também foi escolhido como métrica avaliativa onde, quanto mais próximo de 0% for o valor do RMSE%, melhor é o regressor. Assim, um regressor é dito como tendo um bom desempenho, quando o valor de CC é um valor considerado alto e o valor de RMSE% é considerado baixo. Neste estudo, considerou-se um alto valor de CC como sendo aquele acima de 0,9 e um baixo RMSE%, abaixo de 1%.

Os resultados detalhados dos valores de CC e RMSE% de cada método avaliado (Regressão Linear e SVM - *Kernel* polinomial 2) estão dispostos na tabela 1, onde os piores resultados estão destacados na cor vermelha.

Tabela 2 – Comparação dos resultados obtidos para regressão linear e SVM - *Kernel* polinomial 2

Ano	Bimestre	Regressão Linear		SVM - <i>Kernel</i> 2	
		CC	RMSE%	CC	RMSE%
2014	1	0,6963	17,942	0,9729	0,5838
	2	0,7061	19,969	0,9853	0,49
	3	0,6173	19,882	0,9768	0,5524
	4	0,7003	17,194	0,9934	0,2764
	5	0,7413	1,73	0,9867	0,4268
	6	0,7841	14,305	0,9848	0,4042
2015	1	0,7516	15,967	0,9849	0,4186
	2	0,6976	21,503	0,9814	0,5816
	3	0,7413	19,527	0,9761	0,6437
	4	0,6982	23,271	0,9616	0,9157

	5	0,6488	12,119	0,9889	0,2368
	6	0,6532	12,547	0,9595	0,4709
2016	1	0,7066	10,878	0,9557	0,4561
	2	0,7288	13,043	0,986	0,3187
	3	0,6582	13,772	0,9818	0,3514
	4	0,6739	12,141	0,9926	0,2031
	5	0,6722	10,859	0,9818	0,2824
	6	1	0	1	0,0128

Fonte: A Autora, 2020.

Além da regressão linear e SVM - *Kernel* polinomial 2, foram aplicados valores de CC e RMSE% para os regressores SVM - *Kernel* polinomial 1 e SVM- RBF (Radial Basis Function) (Tabela 2), onde ambos apresentaram resultados não satisfatórios.

Tabela 3 - Comparação dos resultados obtidos para SVM - *Kernel* polinomial 1 e SVM - *Kernel* RBF

Ano	Bimestre	SMV - <i>Kernel</i> 1		SVM - RBF	
		CC	RMSE%	CC	RMSE%
2014	1	0,8033	15,033	0,8102	14,652
	2	0,8000	17,014	0,8106	16,589
	3	0,8361	13,882	0,8257	14,358
	4	0,8723	11,802	0,8712	11,858
	5	0,8446	13,818	0,8383	14,106
	6	0,8448	1,233	0,8406	12,392
2015	1	0,8529	12,637	0,8565	12,524
	2	0,8306	16,711	0,8339	16,626
	3	0,8468	15,554	0,8559	15,068
	4	0,8061	1,948	0,8100	19,494
	5	0,8195	0,9174	0,8276	0,893
	6	0,8054	0,9826	0,8103	0,9779
2016	1	0,8069	0,9142	0,8157	0,8898
	2	0,8364	10,483	0,8412	10,305
	3	0,7914	1,121	0,8427	11,243
	4	0,8473	0,8781	0,8626	0,8326
	5	0,8455	0,7845	0,8493	0,7745
	6	1	0,0074	1	0,0161

Fonte: A Autora, 2020.

A partir da geração de imagens, foram obtidos os resultados qualitativos. Foram geradas as imagens das predições bimestrais dos anos de 2014 a 2016 para o regressor com melhor e pior desempenho.

Através do mapa de cores as regiões que apresentaram áreas avermelhadas correspondem às áreas com as maiores concentrações de criadouros de *Aedes aegypti*,

enquanto que as regiões que apresentaram coloração mais clara representam baixos índices dos criadouros. Os rótulos numéricos dos bairros são apresentados na tabela 4.

Tabela 4 - Rótulos numéricos dos bairros do Recife-PE

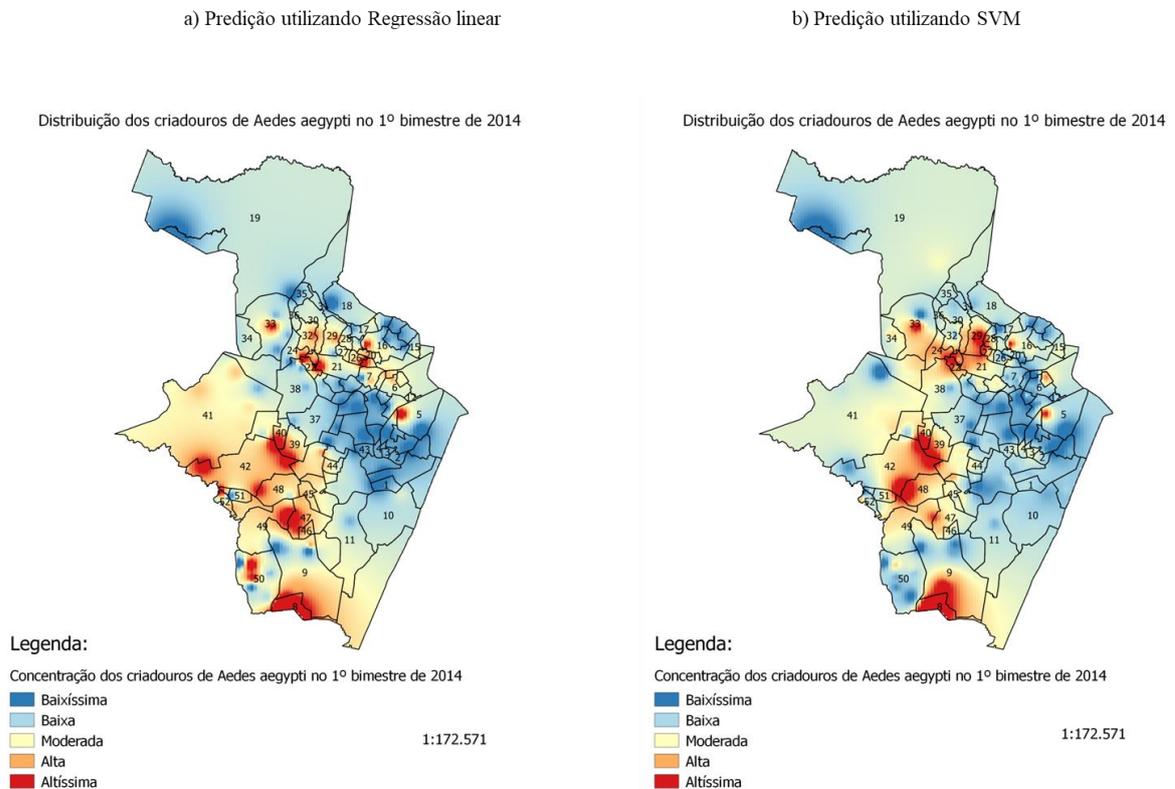
Bairro	Rótulo	Bairro	Rótulo
Cabanga	1	Morro da Conceição	27
Coelhos	2	Alto José Bonifácio	28
Ilha do Leite	3	Vasco da Gama	29
Paissandu	4	Nova Descoberta	30
Santo Amaro	5	Brejo do Beberibe	31
Encruzilhada	6	Macaxeira	32
Tamarineira	7	Dois Irmãos	33
Jordão	8	Sítio dos Pintos	34
Ibura	9	Brejo de Guabiraba	35
Pina	10	Córrego do Jenipapo	36
Imbiribeira	11	Cordeiro	37
Torreão	12	Iputinga	38
Peixinhos	13	Torrões	39
Hipódromo	14	Engenho do meio	40
Campina do Barreto	15	Várzea	41
Água Fria	16	Curado	42
Linha do Tiro	17	Ilha do Retiro	43
Dois Unidos	18	Mustardinha	44
Guabiraba	19	Estância	45
Bomba do Hemetério	20	Caçote	46
Casa Amarela	21	Areias	47
Monteiro	22	Jardim São Paulo	48
Alto do Mandu	23	Barro	49
Apipucos	24	Cohab	50
Mangabeira	25	Sancho	51
Alto José do Pinho	26	Coqueiral	52

Fonte: A Autora, 2019.

Para melhor elucidar a distribuição espacial destes criadouros dentro do mapa da cidade do Recife, foi adotada a divisão em regiões político-administrativas (RPA's), sendo esta utilizada pela gestão municipal para diagnóstico do território, implementação de políticas públicas e intervenção.

A figura 3 mostra as predições de criadouros de *Aedes aegypti* do primeiro bimestre de 2014, com regressão linear (figura 3a) e com *kernel 2* (figura 3b).

Figura 3 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do primeiro bimestre de 2014

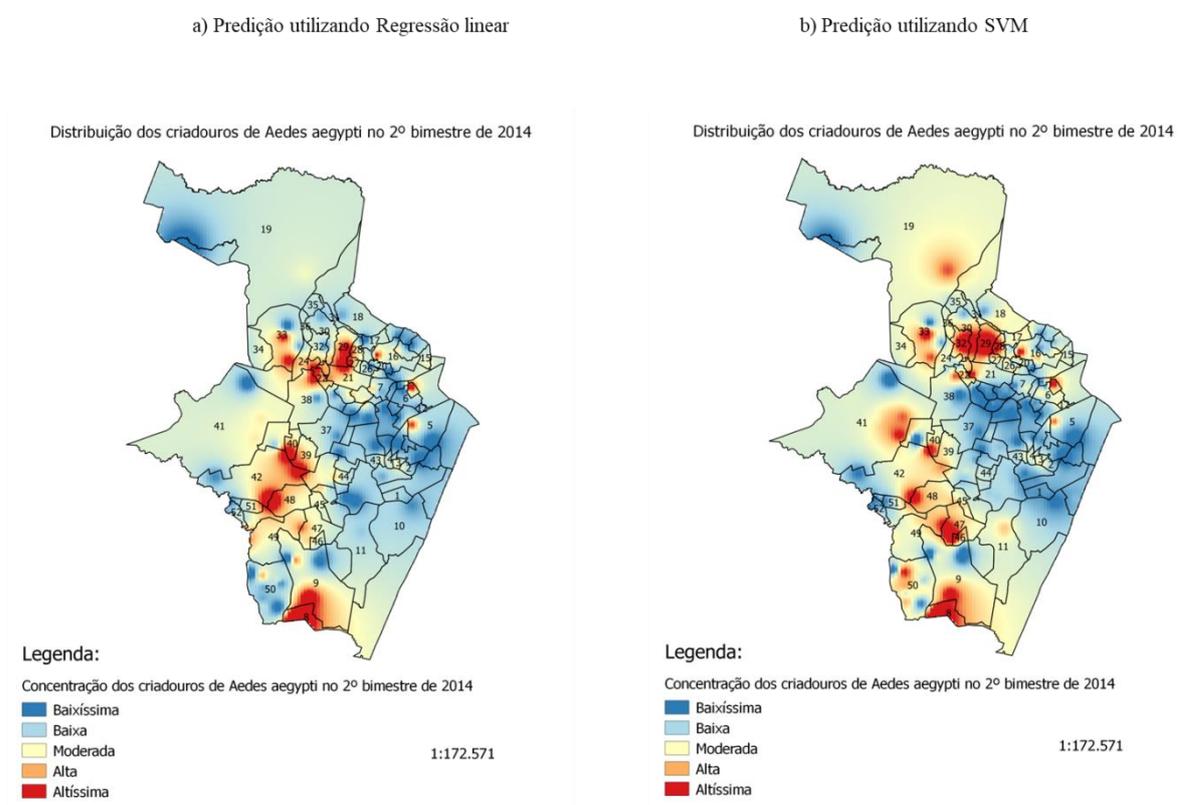


Fonte: A Autora, 2020.

De acordo com a figura 3a (Regressão linear 1º bimestre 2014), a predição obtida foi a seguinte: RPA 1: Santo Amaro; RPA 3: Alto do Mandu, Casa Amarela, Dois Irmãos, Mangabeira, Monteiro; RPA 4: Engenho do Meio, Torrões; RPA 5: Areias, Barro, Curado; RPA 6: Cohab, Jordão.

Com a utilização do regressor SVM *kernel* 2, para o 1º bimestre 2014 (figura 3b), foi obtida a seguinte predição: RPA 1: Santo Amaro; RPA 3: Alto do Mandu, Dois Irmãos, Monteiro, Vasco da Gama; RPA 4: Engenho do Meio, Torrões; RPA 5: Curado, Jardim São Paulo; RPA 6: Ibura, Jordão.

Figura 4 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do segundo bimestre de 2014



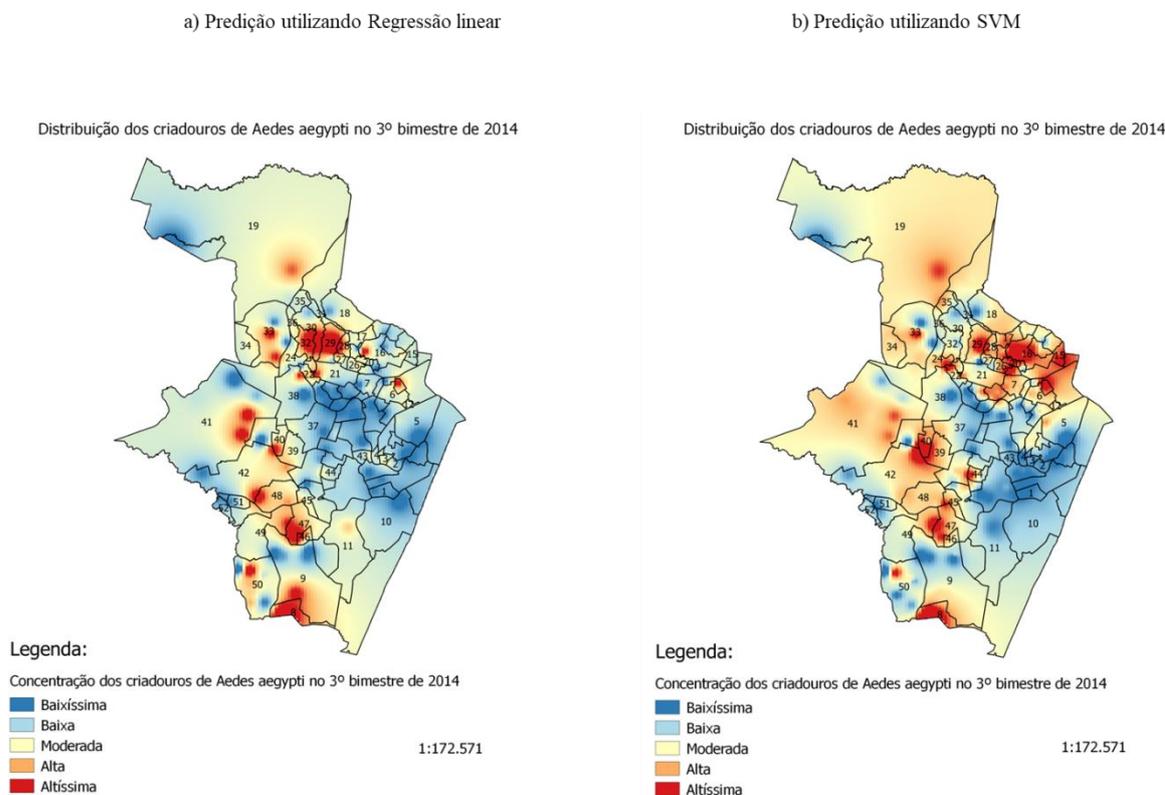
Fonte: A Autora, 2020.

Analisando os resultados do 2º bimestre do mesmo ano, a figura 4a apresenta a seguinte predição: RPA 1: Santo Amaro; RPA 2: Água Fria, Hipódromo; RPA 3: Casa Amarela, Dois Irmãos, Monteiro, Morro da Conceição, Vasco da Gama; RPA 4: Engenho do Meio, Torrões; RPA 5: Curado, Jardim São Paulo; RPA 6: Ibura, Jordão.

Enquanto que, para *kernel 2* (figura 4b), os resultados obtidos foram: RPA 2: Hipódromo; RPA 3: Alto José Bonifácio, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Areias, Caçote, Curado, Jardim São Paulo; RPA 6: Ibura, Jordão.

Fazendo uma análise comparativa entre os dois primeiros bimestres de 2014, verifica-se que no 2º bimestre, para ambos os regressores, houve a inclusão da RPA2, com aumento de criadouros em alguns bairros desta região: Água Fria e Hipódromo. Percebe-se igualmente a saída da RPA1 deste contexto, na predição realizada por *Kernel 2*.

Figura 5 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do terceiro bimestre de 2014



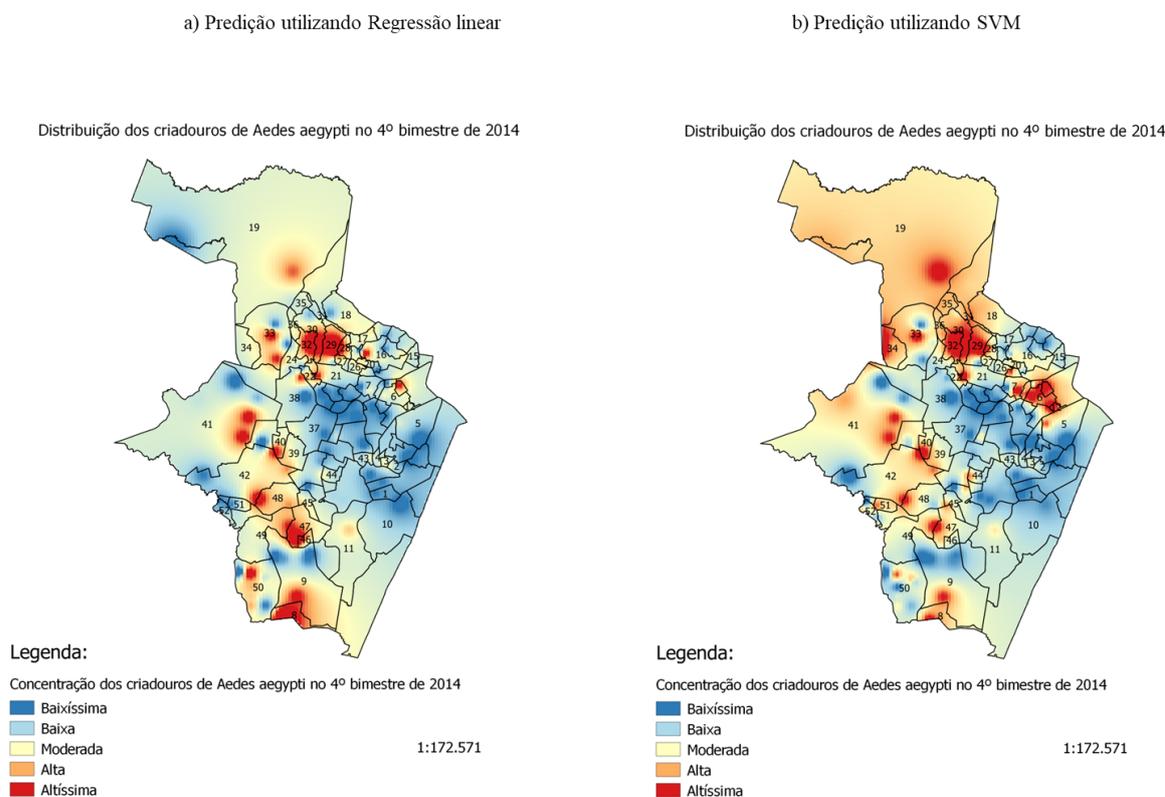
Fonte: A Autora, 2020.

De acordo com a figura 5a (Regressão linear 3º bimestre 2014), a predição obtida foi a seguinte: RPA 2: Hipódromo; RPA 3: Alto José Bonifácio, Casa Amarela, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Iputinga, Várzea; RPA 5: Areias, Caçote, Curado, Jardim São Paulo; RPA 6: Cohab, Ibura, Jordão.

Com a utilização do regressor SVM *kernel 2*, para o 3º bimestre 2014 (figura 5b), foi obtida a seguinte predição: RPA 2: Água Fria, Bomba do Hemetério, Campina do Barreto, Hipódromo, Peixinhos; RPA 3: Alto José Bonifácio, Alto do Mandu, Dois Irmãos, Mangabeira, Monteiro, Vasco da Gama; RPA 4: Engenho do Meio, Torrões; RPA 5: Areias, Caçote, Curado; RPA 6: Cohab, Jordão.

Após análise deste bimestre, verificou-se a exclusão da RPA1 para ambos os regressores.

Figura 6 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do quarto bimestre de 2014

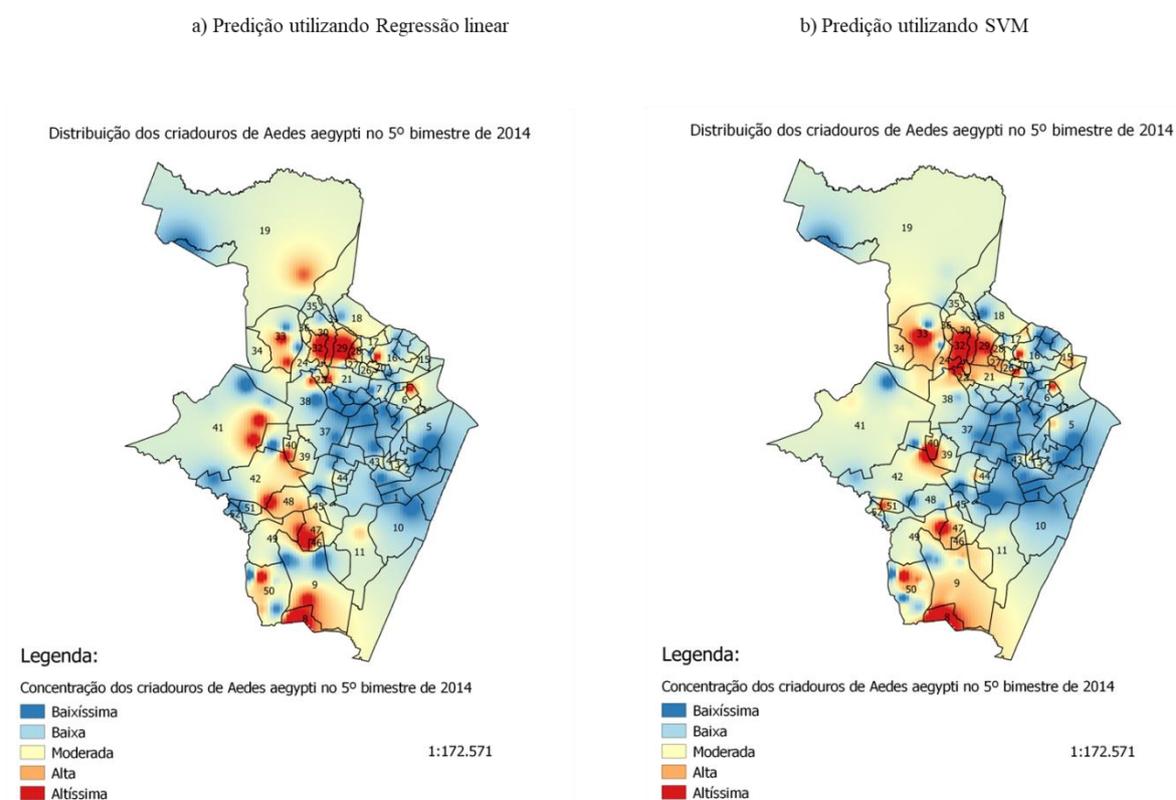


Fonte: A Autora, 2020.

A figura 6a apresenta como resultados de sua análise de predição, com regressão linear, a alta concentração de criadouros nas seguintes RPA's: RPA 2: Água Fria, Hipódromo; RPA 3: Alto José Bonifácio, Casa Amarela, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Iputinga, Várzea; RPA 5: Areias, Caçote, Curado, Jardim São Paulo; RPA 6: Cohab, Ibura, Jordão.

Já a figura 6b, a qual representa a predição dos criadouros por *kernel 2*, apresenta os seguintes resultados: RPA 2: Encruzilhada, Hipódromo, Torreão; RPA 3: Casa Amarela, Dois Irmãos, Guabiraba, Macaxeira, Nova Descoberta, Sítio dos Pintos, Tamarineira, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Areias, Curado, Jardim São Paulo; RPA 6: Ibura, Jordão.

Figura 7 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do quinto bimestre de 2014

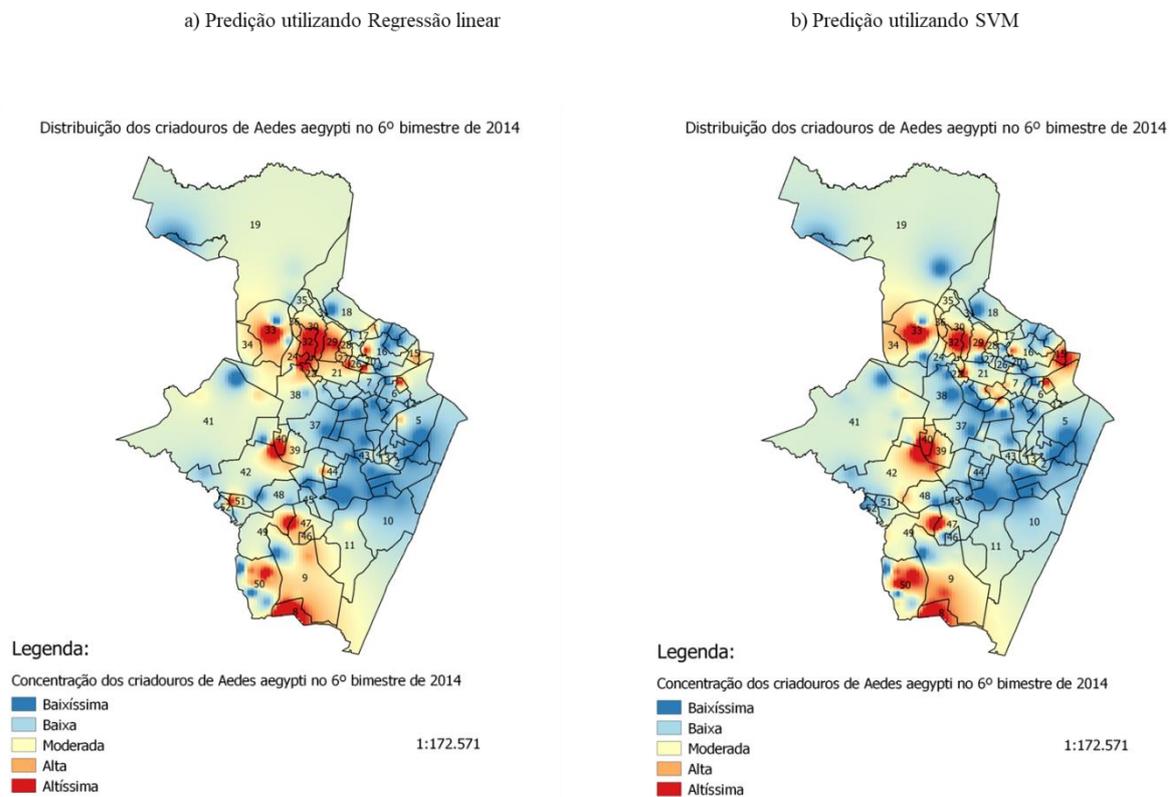


Fonte: A Autora, 2020.

Para a análise do 5º bimestre de 2014, a predição por regressão linear (figura 7a) apresenta os seguintes resultados: RPA 2: Água Fria, Hipódromo; RPA 3: Casa Amarela, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Iputinga, Várzea; RPA 5: Areias, Caçote, Curado, Jardim São Paulo; RPA 6: Cohab, Iburá, Jordão.

Para este mesmo bimestre, agora com a predição por *kernel 2* (figura 7b), os resultados apresentados foram: RPA 2: Água Fria, Hipódromo; RPA 3: Alto do Mandu, Apipucos, Dois Irmãos, Macaxeira, Mangabeira, Monteiro, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Areias, Barro, Curado; RPA 6: Cohab, Jordão.

Figura 8 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do sexto bimestre de 2014

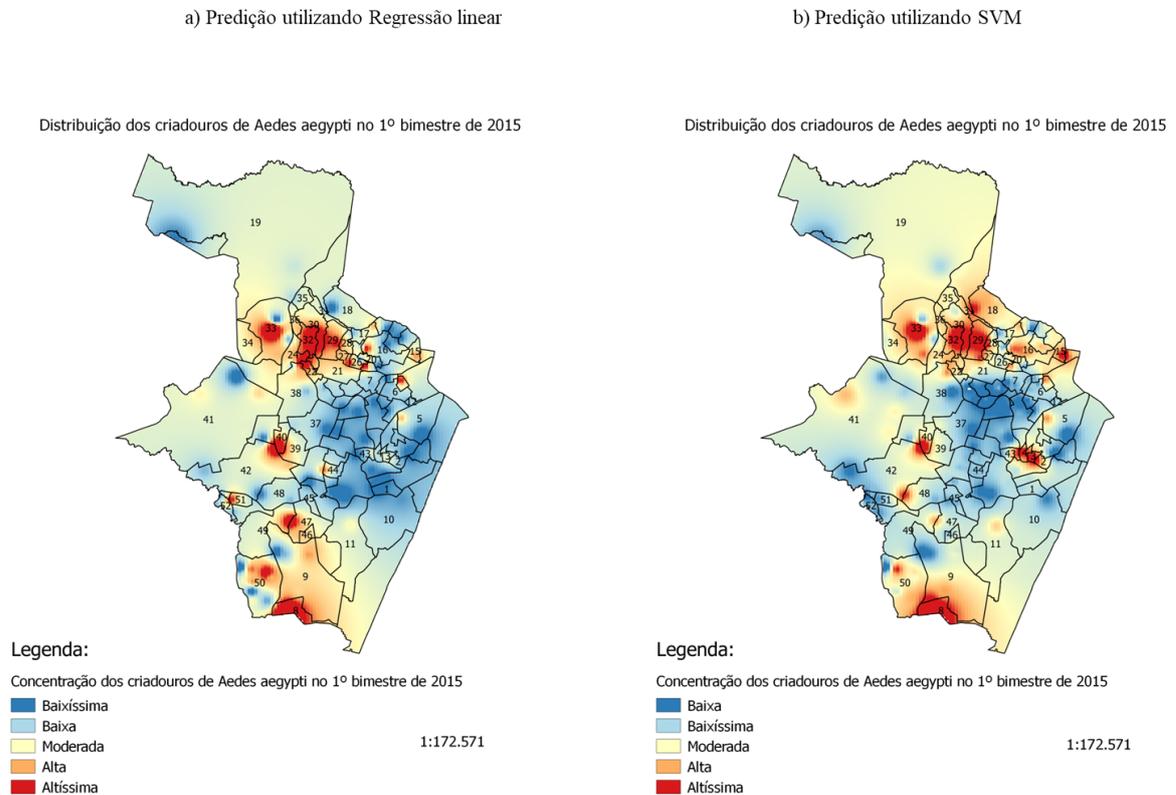


Fonte: A Autora, 2020.

Finalizando o ano de 2014, no 6º bimestre, verificou-se que a predição por regressão linear (figura 8a) foi a seguinte: RPA 2: Água Fria, Hipódromo; RPA 3: Alto do Mandu, Alto José do Pinho, Apipucos, Dois Irmãos, Macaxeira, Mangabeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Areias, Barro, Curado, Sancho; RPA 6: Cohab, Jordão.

Já com o regressor *kernel 2*, para o mesmo bimestre obtivemos: RPA 2: Campina do Barreto, Hipódromo, Peixinhos; RPA 3: Casa Amarela, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Torrões; RPA 5: Areias, Barro, Curado; RPA 6: Cohab, Jordão.

Figura 9 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do primeiro bimestre de 2015



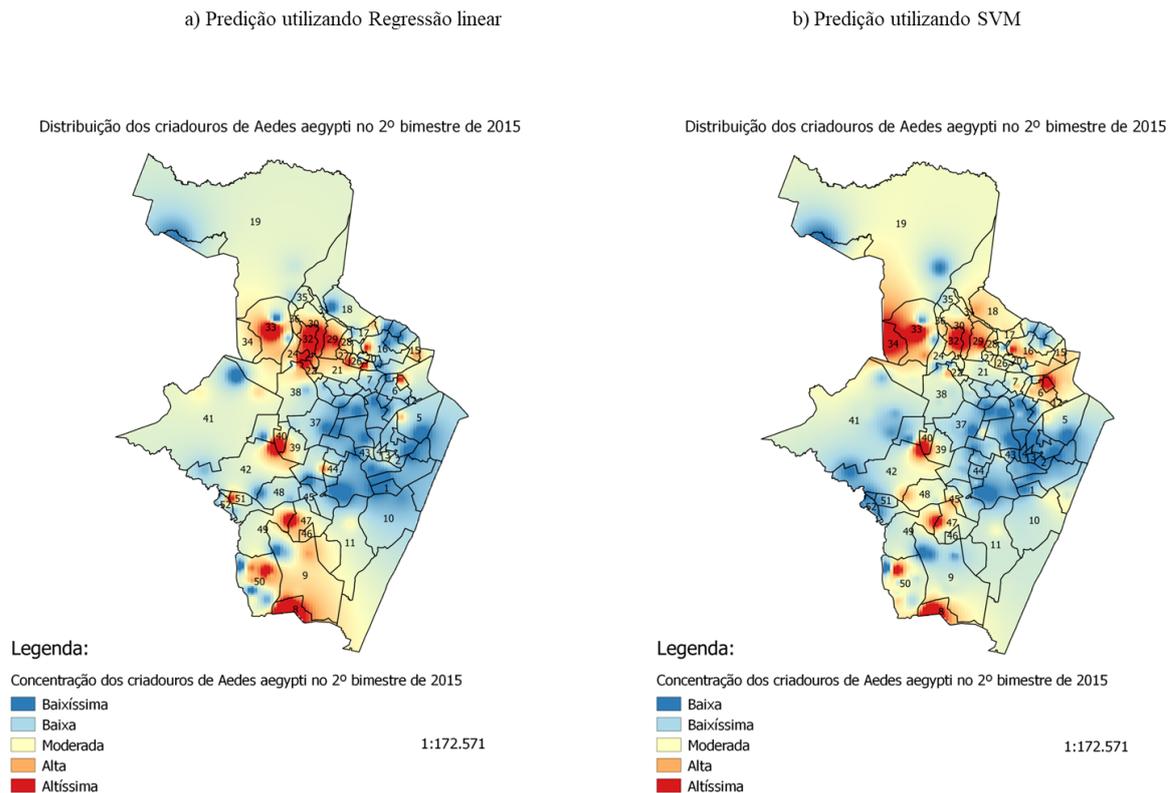
Fonte: A Autora, 2020.

Em análise ao 1º bimestre do ano de 2015, utilizando a regressão linear, verificou-se que os bairros, dentro do contexto das RPA's, que apresentaram maiores predições para criadouros do mosquito do gênero *Aedes*, como mostra a figura 9a, foram: RPA 2: Água Fria, Hipódromo; RPA 3: Alto do Mandu, Alto José do Pinho, Apipucos, Dois Irmãos, Macaxeira, Mangabeira, Monteiro, Morro da Conceição, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Areias, Barro, Curado, Sancho; RPA 6: Cohab, Jordão.

Para este mesmo bimestre, utilizando agora o preditor *kernel 2* (figura 9b), obtivemos os seguintes resultados: RPA 1: Coelhos, Ilha do Leite, Paissandu; RPA 2: Campina do Barreto, Dois Unidos, Peixinhos; RPA 3: Alto José Bonifácio, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Ilha do Retiro; RPA 5: Curado; RPA 6: Cohab, Jordão.

É possível verificar que utilizando *kernel 2*, houve uma maior predição entre os bairros, inclusive com o referenciamento da RPA1, a qual não foi observada com a utilização do preditor regressão linear.

Figura 10 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do segundo bimestre de 2015



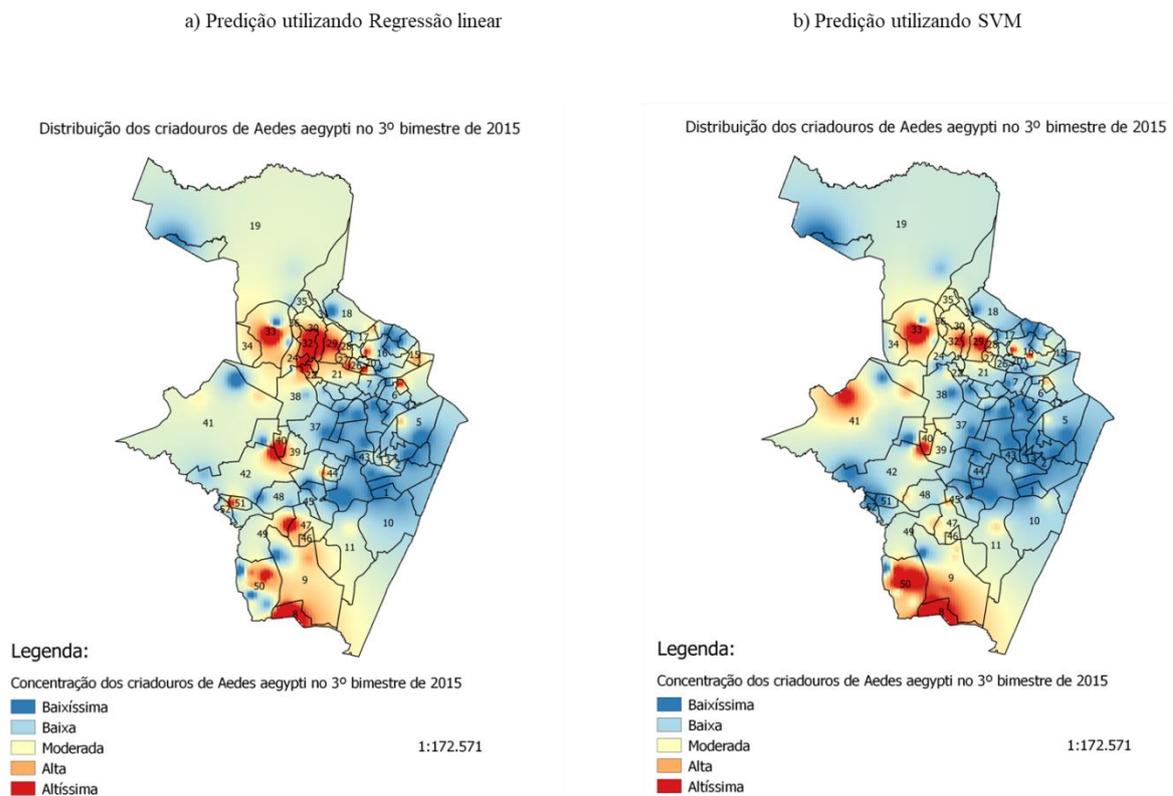
Fonte: A Autora, 2020.

Em continuidade, agora para o 2º bimestre de 2015, após predição por regressão linear (figura 10a), obteve-se os seguintes dados: RPA 2: Água Fria, Hipódromo; RPA 3: Alto do Mandu, Alto José do Pinho, Apipucos, Dois Irmãos, Macaxeira, Mangabeira, Monteiro, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Areias, Barro, Curado, Sancho; RPA 6: Cohab, Jordão.

Realizando a mesma predição, agora com a utilização de *kernel 2* (figura 10b), os resultados encontrados foram os seguintes: RPA 2: Água Fria, Hipódromo; RPA 3: Dois Irmãos, Macaxeira, Nova Descoberta, Sítio dos Pintos, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Areias, Barro, Curado; RPA 6: Cohab, Jordão.

Analisando comparativamente tais dados, pelos preditores utilizados, verifica-se que apenas a RPA 3 apresentou diferença numérica entre a quantidade de bairros acometidos, onde uma maior predição foi verificada pela utilização da regressão linear quando comparada a *kernel 2*.

Figura 11 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do terceiro bimestre de 2015

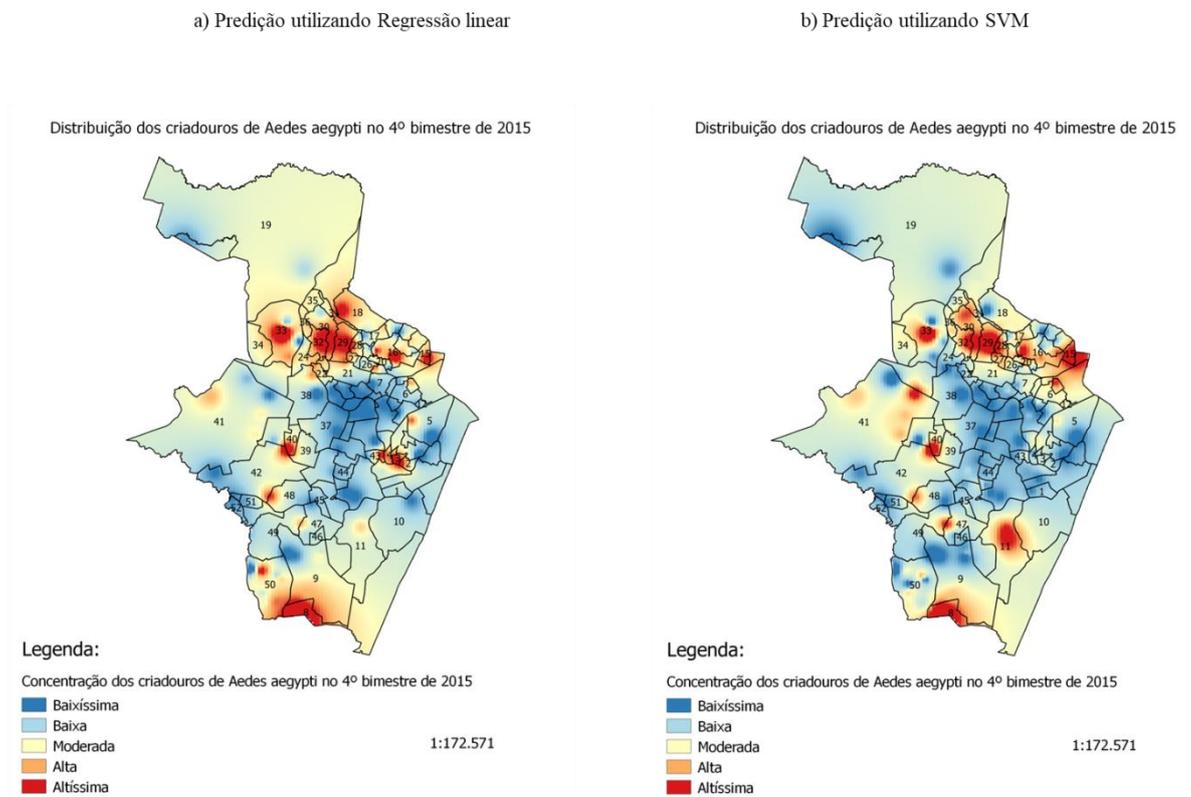


Fonte: A Autora, 2020.

Passando para as análises no 3º bimestre de 2015, pela utilização da regressão linear (figura 11a), os resultados encontrados dos bairros com maior predição para a presença de criadouros foram: RPA 2: Água Fria, Hipódromo; RPA 3: Alto do Mandu, Alto José do Pinho, Apipucos, Dois Irmãos, Macaxeira, Mangabeira, Monteiro, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Areias, Barro, Curado, Sancho; RPA 6: Cohab, Jordão.

No mesmo bimestre, agora utilizando *kernel 2*, os resultados obtidos, os quais estão apresentados na figura 11b, foram: RPA 2: Água Fria; RPA 3: Dois Irmãos, Macaxeira, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Curado; RPA 6: Cohab, Jordão.

Figura 12 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do quarto bimestre de 2015

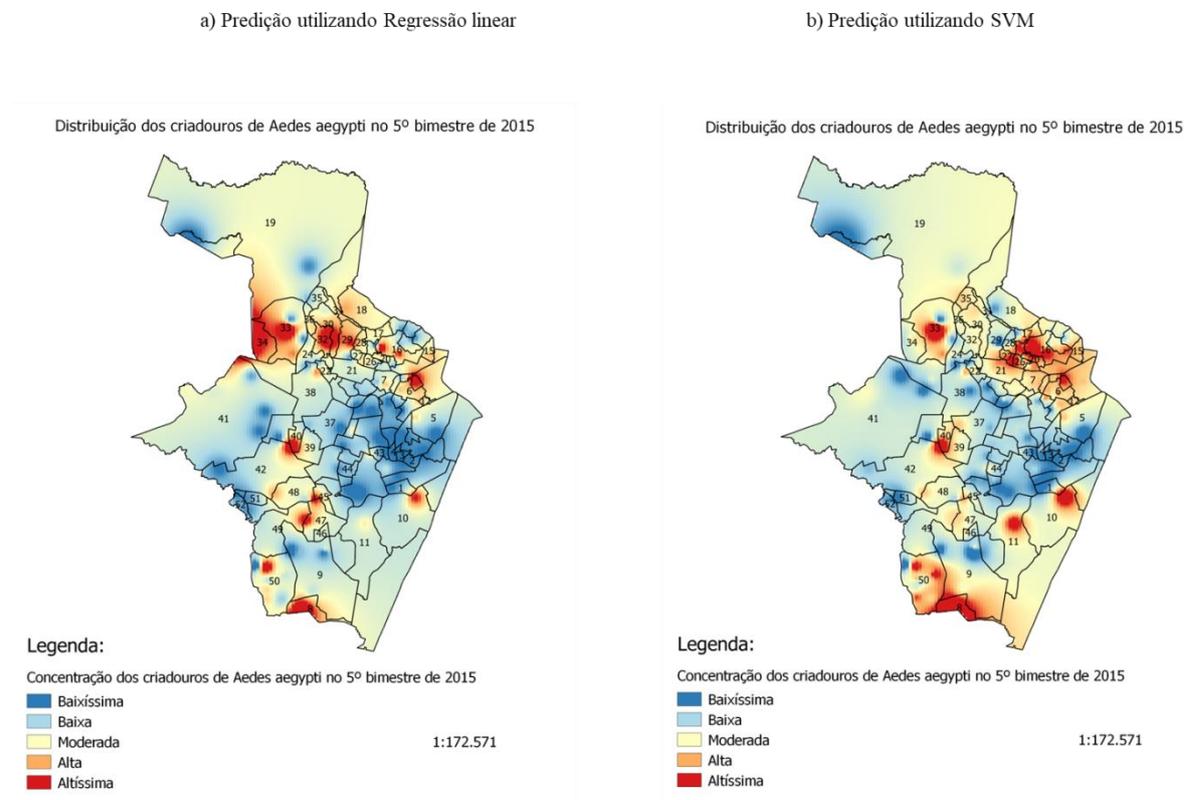


Fonte: A Autora, 2020.

Analisando os resultados referentes ao 4º bimestre do ano de 2015, através da regressão linear (figura 12a), verificou-se a seguinte predição: RPA 1: Ilha do Leite; RPA 2: Água Fria, Coelhos, Campina do Barreto, Dois Unidos; RPA 3: Apipucos, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Ilha do Retiro; RPA 5: Curado; RPA 6: Cohab, Jordão.

Utilizando agora *kernel 2*, a predição obtida foi a seguinte (figura 12b): RPA 2: Água Fria, Campina do Barreto, Hipódromo, Peixinhos; RPA 3: Alto José Bonifácio, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Areias, Barro, Curado; RPA 6: Imbiribeira, Jordão.

Figura 13 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do quinto bimestre de 2015

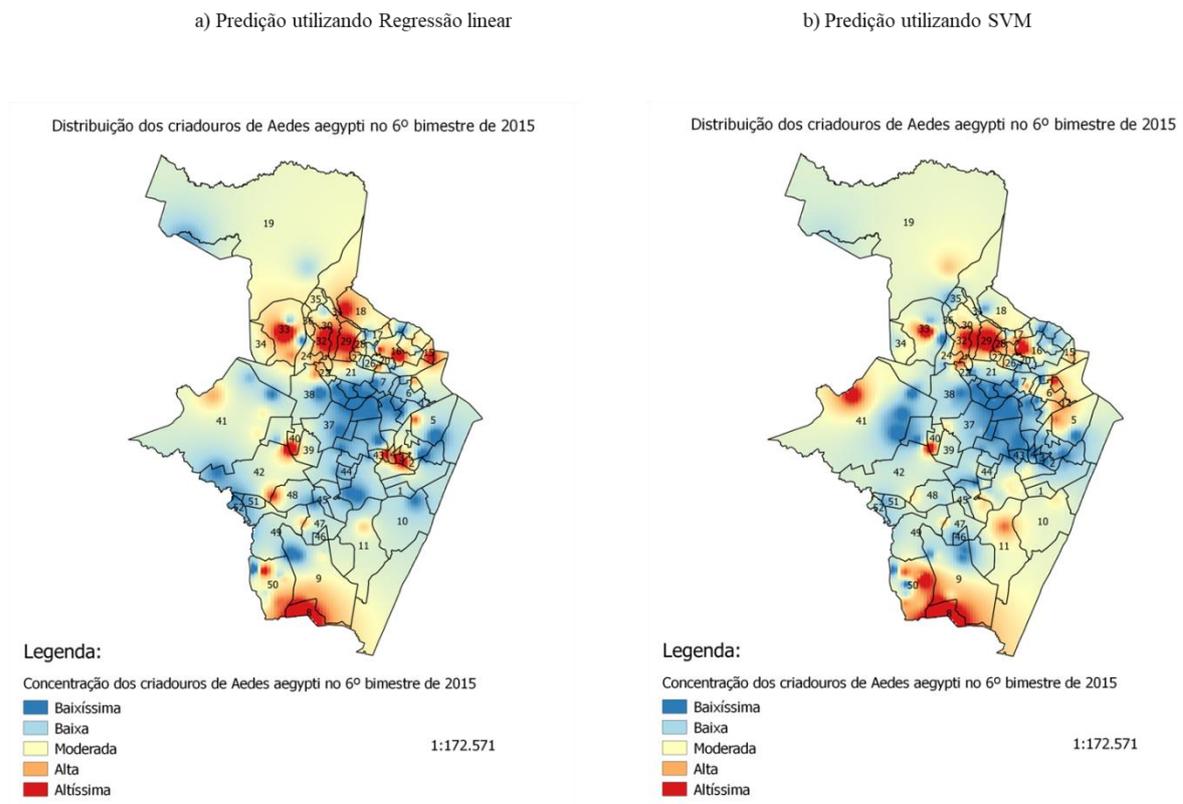


Fonte: A Autora, 2020.

Passando para o 5º bimestre de 2015, as análises preditivas através da regressão linear (figura 13a), apresentaram a seguinte distribuição: RPA 2: Água Fria, Hipódromo; RPA 3: Dois Irmãos, Macaxeira, Nova Descoberta, Sítio dos Pintos, Vasco da Gama; RPA 4: Caxangá, Engenho do Meio; RPA 5: Areias, Barro, Curado, Estância, Jardim São Paulo; RPA 6: Cohab, Jordão, Pina.

Com *kernel 2* (figura 13b), no mesmo bimestre, a análise preditiva apresentou os seguintes dados: RPA 2: Água Fria, Alto Santa Terezinha, Hipódromo; RPA 3: Alto José do Pinho, Dois Irmãos, Morro da Conceição; RPA 4: Engenho do Meio; RPA 5: Curado; RPA 6: Cohab, Imbiribeira, Jordão, Pina.

Figura 14 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do sexto bimestre de 2015

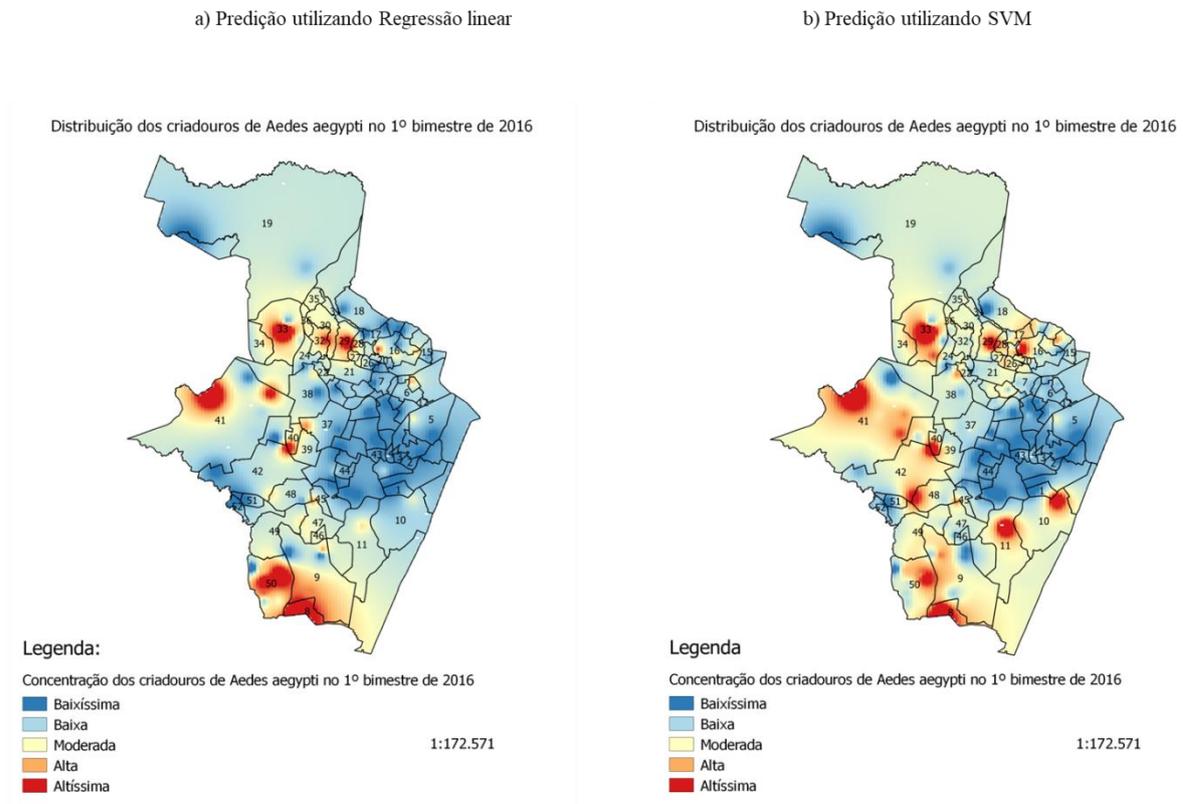


Fonte: A Autora, 2020.

Finalizando o ano de 2015, em seu 6º bimestre, após análise preditiva dos focos de criadouros de *Aedes*, por regressão linear (figura 14a), a distribuição desses focos dentre os bairros distribuídos nas respectivas RPA's as quais estão inseridos, foi a seguinte: RPA 1: Coelhos, Ilha do Leite; RPA 2: Água Fria, Campina do Barreto, Dois Unidos; RPA 3: Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Ilha do Retiro; RPA 5: Curado; RPA 6: Cohab, Jordão.

A mesma análise preditiva, agora utilizando o preditor *kernel 2* (figura 14b), apresentou a distribuição a seguir: RPA 2: Água Fria, Hipódromo; RPA 3: Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Curado; RPA 6: Cohab, Jordão.

Figura 15 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do primeiro bimestre de 2016

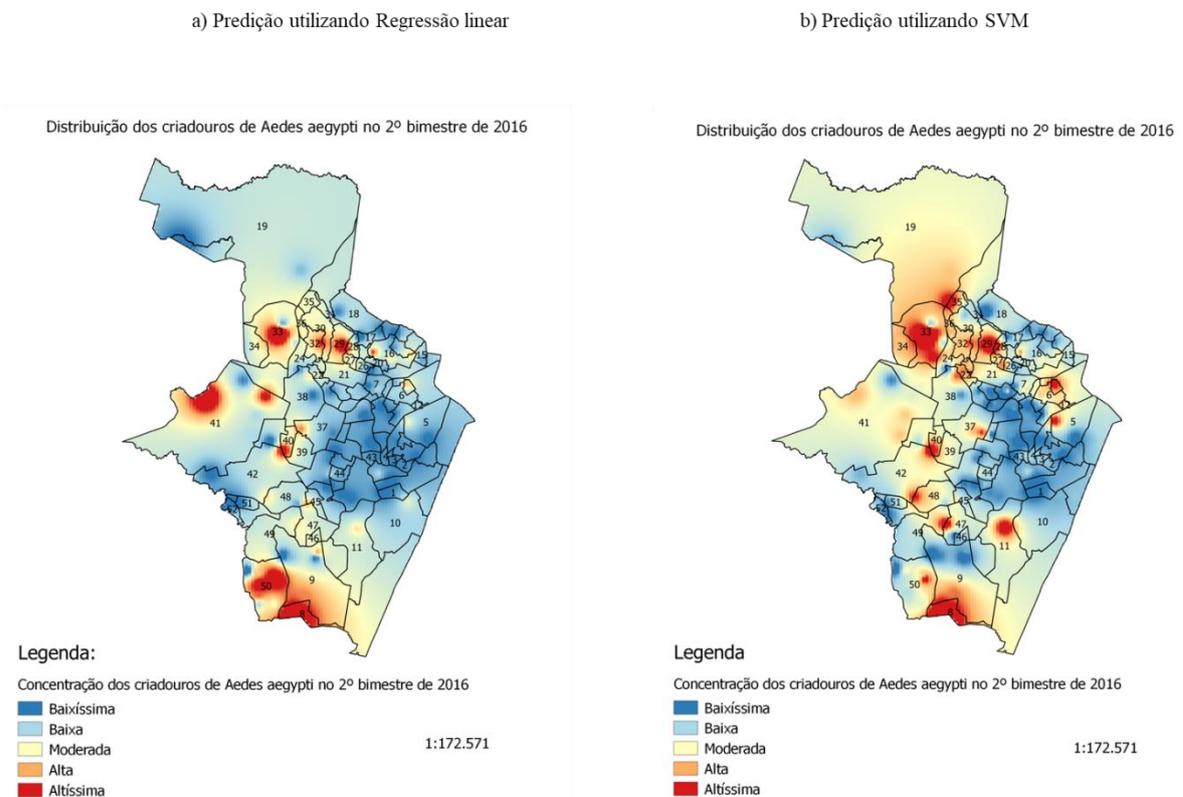


Fonte: A Autora, 2020.

Para o 1º bimestre de 2016, a predição dos criadouros utilizando regressão linear (figura 15a), mostrou a seguinte distribuição: RPA 2: Água Fria; RPA 3: Dois Irmãos, Macaxeira, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Curado; RPA 6: Cohab, Jordão.

Com *kernel 2* (figura 15b), a predição obtida foi: RPA 2: Água Fria; RPA 3: Dois Irmãos, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Curado, Jardim São Paulo; RPA 6: Cohab, Jordão, Imbiribeira, Pina.

Figura 16 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do segundo bimestre de 2016

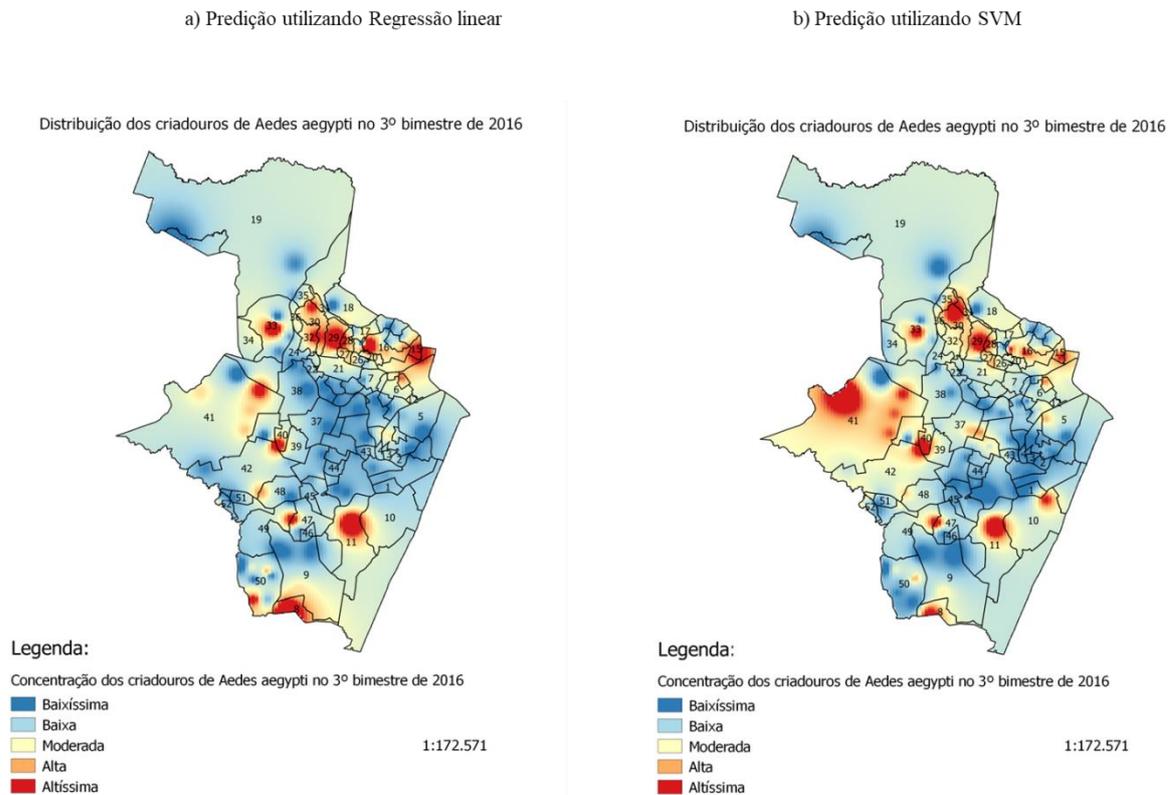


Fonte: A Autora, 2020.

Em seguida, após a utilização da regressão linear para predição dos criadouros no 2º bimestre de 2016 (figura 16a), os resultados obtidos entre os bairros dentro das RPA's foram: RPA 2: Água Fria; RPA 3: Dois Irmãos, Macaxeira, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Curado; RPA 6: Cohab, Jordão.

Realizando a predição com *kernel 2* (figura 16b), a distribuição dos criadouros preditos foi a seguinte: RPA 1: Santo Amaro; RPA 2: Hipódromo; RPA 3: Brejo de Guabiraba, Dois Irmãos, Guabiraba, Vasco da Gama; RPA 4: Cordeiro, Engenho do Meio; RPA 5: Areias, Barro, Curado, Jardim São Paulo; RPA 6: Cohab, Imbiribeira, Jordão.

Figura 17 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do terceiro bimestre de 2016

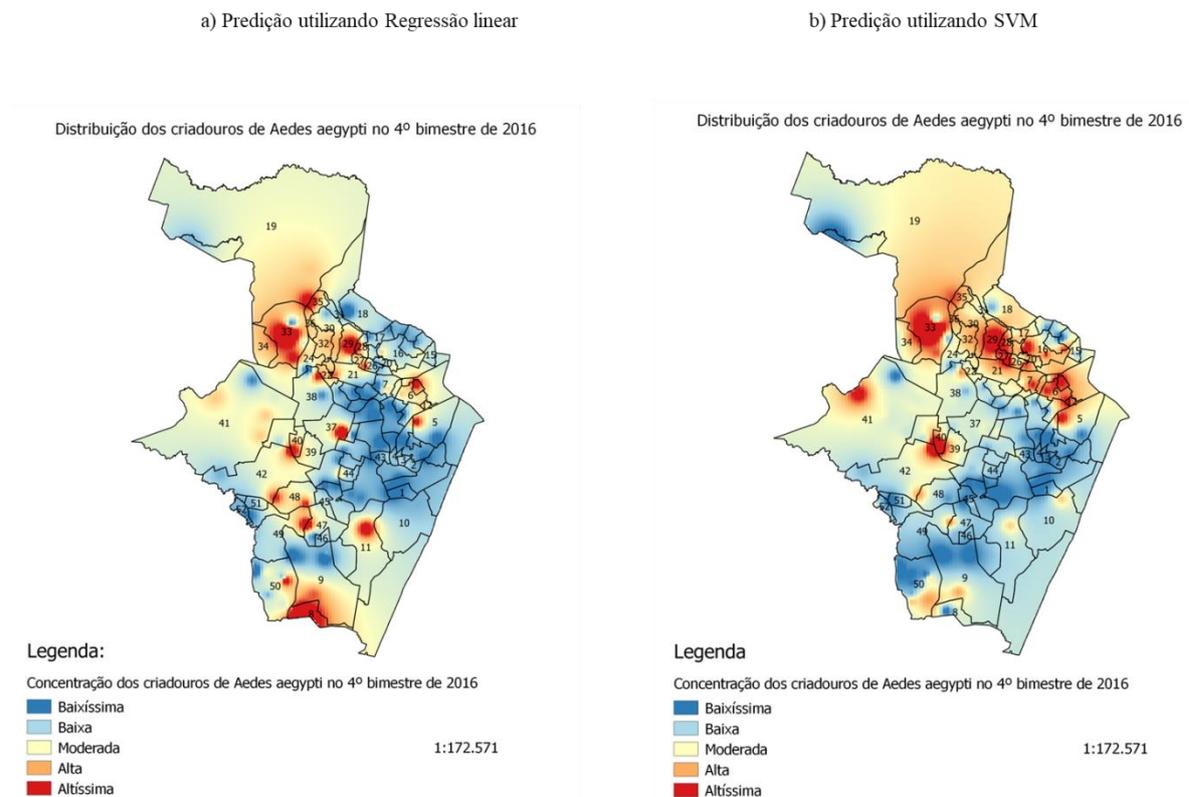


Fonte: A Autora, 2020.

A predição no 3º bimestre de 2016, pela utilização da regressão linear (figura 17a), apresentou os bairros e RPA's a seguir, com focos aumentados para criadouros de *Aedes sp.*: RPA 2: Água Fria, Campina do Barreto, Peixinhos; RPA 3: Alto José Bonifácio, Dois Irmãos, Macaxeira, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Areias, Barro, Curado; RPA 6: Cohab, Imbiribeira, Jordão.

Com a utilização de *kernel 2* como preditor (figura 17b), os dados obtidos foram: RPA 2: Água Fria, Campina do Barreto; RPA 3: Alto José Bonifácio, Brejo de Beberibe, Dois Irmãos, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Areias, Barro, Curado; RPA 6: Imbiribeira, Jordão, Pina.

Figura 18 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do quarto bimestre de 2016

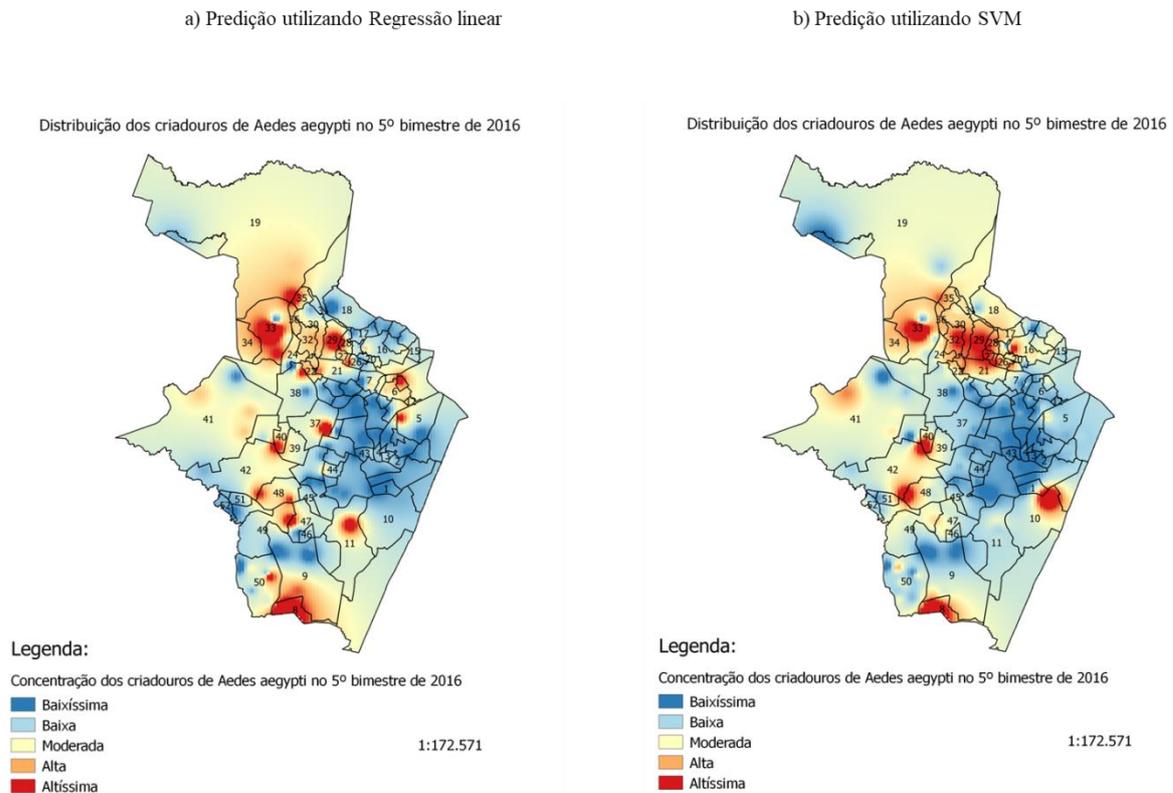


Fonte: A Autora, 2020.

Realizando as análises preditivas para o 4º bimestre de 2016, utilizando a regressão linear (figura 18a), os dados obtidos foram os seguintes: RPA 1: Santo Amaro; RPA 2: Hipódromo; RPA 3: Alto José Bonifácio, Alto José do Pinho, Brejo de Guabiraba, Dois Irmãos, Guabiraba, Vasco da Gama; RPA 4: Cordeiro, Engenho do Meio, Iputinga; RPA 5: Areias, Barro, Curado, Jardim São Paulo; RPA 6: Cohab, Imbiribeira, Jordão.

Com *kernel 2* (figura 18b), os resultados preditivos para os focos de criadouros do mosquito *Aedes*, com distribuição entre os bairros e RPA's foram: RPA 1: Santo Amaro; RPA 2: Água Fria, Encruzilhada, Hipódromo, Torreão; RPA 3: Alto José Bonifácio, Dois Irmãos, Morro da Conceição, Tamarineira, Vasco da Gama; RPA 4: Engenho do Meio, Várzea; RPA 5: Curado.

Figura 19 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do quinto bimestre de 2016

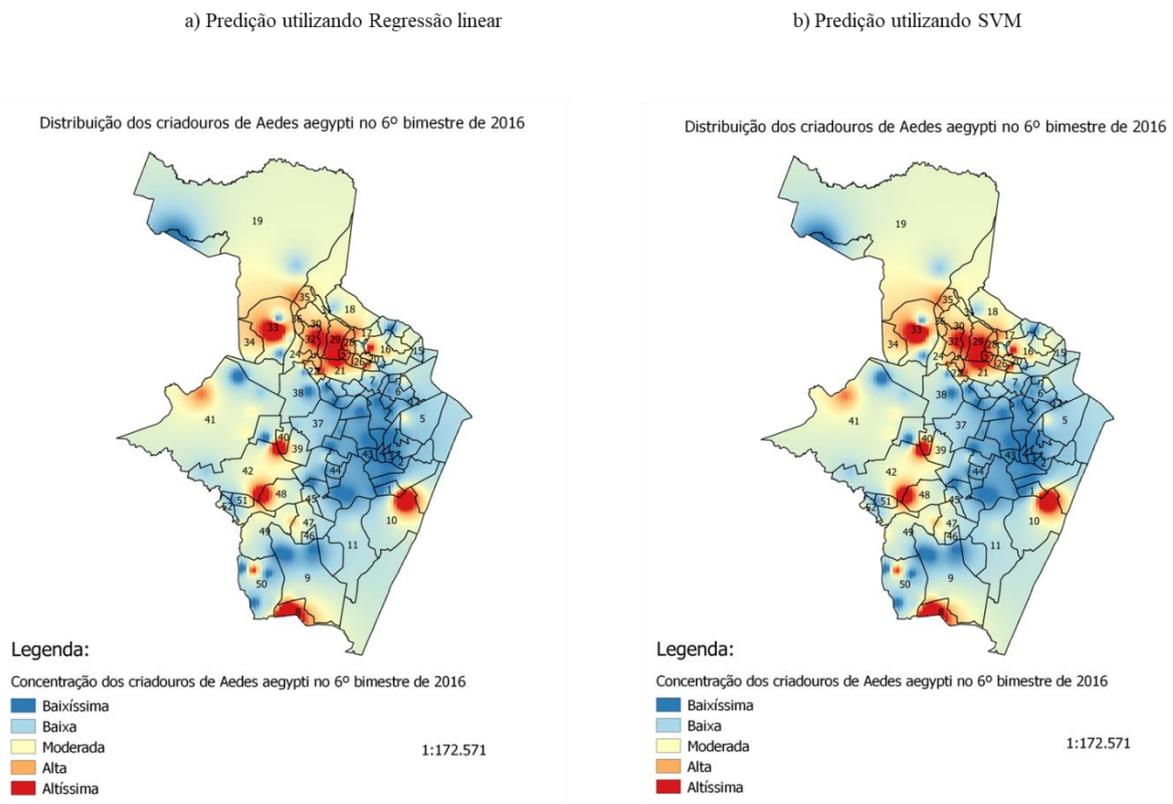


Fonte: A Autora, 2020.

Para o 5º bimestre de 2016, a predição dos criadouros pela regressão linear (figura 19a), apresentou os seguintes resultados: RPA 1: Santo Amaro; RPA 2: Hipódromo; RPA 3: Alto José do Pinho, Brejo de Guabiraba, Dois Irmãos, Guabiraba, Morro da Conceição, Vasco da Gama; RPA 4: Cordeiro, Engenho do Meio, Iputinga; RPA 5: Areias, Barro, Curado, Jardim São Paulo; RPA 6: Cohab, Imbiribeira, Jordão.

Pela predição por *kernel 2* (figura 19b), a distribuição dos dados apresentou-se da seguinte maneira: RPA 2: Água Fria; RPA 3: Alto José Bonifácio, Casa Amarela, Dois Irmãos, Macaxeira, Morro da Conceição, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Curado, Jardim São Paulo; RPA 6: Jordão, Pina.

Figura 20 – Resultados da predição da distribuição dos criadouros de *Aedes aegypti* do sexto bimestre de 2016



Fonte: A Autora, 2020.

Por fim, a predição realizada no 6º bimestre de 2016, através da regressão linear (figura 20a), os dados apresentados sobre a possível distribuição dos criadouros do mosquito do gênero *Aedes* fora, os seguintes: RPA 1: Cabanga; RPA 2: Água Fria; RPA 3: Casa Amarela, Dois Irmãos, Macaxeira, Mangabeira, Morro da Conceição, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Curado, Jardim São Paulo; RPA 6: Cohab, Jordão, Pina.

Através de *kernel 2* (figura 20b), a predição observada foi a seguinte: RPA 2: Água Fria; RPA 3: Casa Amarela, Dois Irmãos, Macaxeira, Morro da Conceição, Nova Descoberta, Vasco da Gama; RPA 4: Engenho do Meio; RPA 5: Curado, Jardim São Paulo; RPA 6: Jordão, Pina.

7 CONCLUSÃO E TRABALHOS FUTUROS

Este capítulo tem como objetivo apresentar as conclusões dos resultados obtidos e, como continuidade, também estão elencadas as dificuldades apresentadas, contribuições e sugestões para trabalhos futuros.

7.1 Conclusão geral

O controle da distribuição e disseminação do mosquito *Aedes aegypti* demonstra um verdadeiro desafio, principalmente nos países em desenvolvimento e subdesenvolvidos. Apesar de serem consideradas as situações em que os recursos destinados ao combate desse vetor sejam apropriados para a implementação de políticas públicas para enfrentamento desse, em sua maioria não se tem alcançado êxito. Problemas relacionados à infraestrutura das cidades, como por exemplo, a falta de saneamento básico, as baixas coberturas na coleta de lixo e a intermitência no abastecimento de água, constituem fatores que comprometem a efetividade dos métodos de controle do mosquito.

Tendo em vista os resultados obtidos, conclui-se que o uso de preditores baseados em algoritmos de aprendizado de máquina apresenta-se eficaz para predição de criadouros de *Aedes aegypti*. Outrossim, a abordagem utilizando análise espaço-temporal foi capaz de fornecer uma avaliação ampla das regiões onde ocorrem mais ou menos focos de criadouros, sendo assim possível diferenciar através de mapas de distribuição as localidades com maior índice de focos de criadouros daquelas com baixa concentração, além das áreas estabelecidas dentro de um intervalo de transição.

Portanto, ações integradas de educação em saúde, comunicação e mobilização social em associação com a Inteligência artificial e o aprendizado de máquinas, tornam-se imprescindíveis na criação e implementação de mecanismos que propiciem a intensificação das políticas de saúde, saneamento e meio ambiente, visando contribuir para a redução dos potenciais criadouros do mosquito, além de apoiar gestores e cientistas da saúde no planejamento de ações e desenvolvimento de políticas públicas neste sentido.

7.2 Dificuldades apresentadas

Neste estudo, as dificuldades apresentadas foram relacionadas à organização da base de dados usada para a elaboração dos conjuntos de treinamento e teste.

7.3 Contribuições

Como contribuições deste estudo, foram gerados mapas históricos da distribuição dos criadouros de *Aedes aegypti* utilizando além da base LIRAA, as variáveis climáticas (temperatura, pluviometria e velocidade dos ventos) para predição dos criadouros desse mosquito.

A partir desta pesquisa, será extraído um artigo para publicação na comunidade científica, ficando assim o mesmo disponível para ampliar o conhecimento a cerca deste tema.

7.4 Trabalhos Futuros

Como trabalhos futuros, pode-se sugerir novas pesquisas utilizando dados como Índice de Desenvolvimento Humano (IDH), da população de mosquitos *Aedes aegypti*, entre outros, para a criação de novos modelos de estudo.

Além disso, tantos outros eventos em saúde igualmente proporcionados por outras espécies de mosquitos-vetores poderiam ser investigados a partir do uso das técnicas de aprendizagem de máquina, as quais se mostraram eficientes neste estudo para a predição de criadouros do *Aedes aegypti* no município do Recife-PE.

REFERÊNCIAS

- ARAÚJO, F.; NOGUEIRA, R.; ARAÚJO, M.S.; PERDIGÃO, A.; CAVALCANTI, L.; BRILHANTE, R.; ROCHA, M.; VILAR, D.F.; HOLANDA, S.S.; BRAGA, D.M.; SIDRIM, J. Dengue in Patients with Central Nervous System Manifestations, Brazil. **Emerging Infectious Diseases**, v. 18, n. 4, p. 677–679, 2012.
- BATISTA, P.M.; ANDREOTTI, R.; CHIANG, J.O.; FERREIRA, M.S.; VASCONCELOS, P.F.C. Seroepidemiological monitoring in sentinel animals and vectors aspart of arbovirus surveillance in the state of Mato Grosso do Sul, Brazil. **Revista da Sociedade Brasileira de Medicina Tropical**, v. 45, n. 2, p. 168-173, 2012.
- BELTRÁN, J.D.; BOSCOR, A.; SANTOS, W.P.; MASSONI, T.; KOSTKOVA, P. Zika: A new system to empower health workers and local communities to improve surveillance protocols by e-learning and to forecast zika virus in real time in brazil. **Proceedings of the 2018 International Conference on Digital Health**, p. 90–94, 2018.
- BRASIL. Ministério da Saúde. Fundação Nacional de Saúde. **Dengue instruções para pessoal de combate ao vetor**: manual de normas técnicas. 3. ed. rev. Brasília, 2001. 84 p. (a)
- BRASIL. Ministério da Saúde. Secretaria de Vigilância em Saúde. Departamento de Vigilância das Doenças Transmissíveis. **Levantamento rápido de índices para *Aedes aegypti* – LIRAA para vigilância entomológica do *Aedes aegypti* no Brasil** : metodologia para avaliação dos índices de Breteau e Predial e tipo de recipientes. Brasília, 2012. 84 p. (Série A. Normas e Manuais Técnicos) (b)
- BRASIL. Ministério da Saúde. Secretária em Vigilância em Saúde. **Inventário nacional de vigilância em saúde ambiental**. Brasília, 2015. (c)
- BRASIL. Ministério da Saúde. Secretaria de Vigilância em Saúde. Departamento de Vigilância das Doenças Transmissíveis. **Dengue**: diagnóstico e manejo clínico: adulto e criança. 5 ed. Brasília, 2016. (d)
- BRASIL. Ministério da Saúde. Secretaria de Vigilância em Saúde. **Chikungunya**: Manual de manejo clínico. Brasília, 2017. (e)
- CAMPION, E. W.; WEAVER, S. C.; LECUIT, M. Chikungunya Virus and the Global Spread of a Mosquito-Borne Disease. **New England Journal of Medicine**, v. 372, n. 13, p. 1231–1239, 2015.
- CAO, T.H.; NGUYEN, A.D.; DINH, T.Q.; LUONG, Q.C.; DIEP, H.T. Forecasting dengue incidence: Statistical and dynamic models. **Oxford Journal of Intelligent Decision and Data Science**, v. 2018, p. 1–13, 2018.
- CAUCHEMEZ, S.; LEDRANS, M.; POLETO, C.; QUENEL, P.; VALK, H.; COLIZZA, V.; BOËLLE, P.Y. Local and regional spread of chikungunya fever in the Americas. **Eurosurveillance**, v.19, e-20854, 2014.
- CAVALCANTI, L.P.G.; TAUIL, P.L.; ALENCAR, C.H.; OLIVEIRA, W.; TEIXEIRA, M.M.; HEUKELBACH, J. Zika virus infection, associated microcephaly, and low yellow

fever vaccination coverage in Brazil: is there any casual link? **Journal of Infection in Developing Countries**, v.10, n.6, p.563-566, 2016.

CAVALLI, F. S.; SEBEN, J. T.; BUSATO, M. A.; LUTINSKI, J. A.; ANDRIOLI, D. C. Controle do Vetor *Aedes Aegypti* e Manejo dos Pacientes com Dengue. **Revista Online de Pesquisa Cuidado é Fundamental**, v.11, n.5, p.1333-1339, 2019.

DONALISIO, M. R.; FREITAS, A. R. R.; VON ZUBEN, A. P. B. Arboviroses emergentes no Brasil: desafios para a clínica e implicações para a saúde pública. **Revista de Saúde Pública**, v. 51, n. 30, 2017.

DONALISIO, M. R.; FREITAS, A. R. Chikungunya no Brasil: um desafio emergente. **Revista Brasileira de Epidemiologia**, v. 18, n. 1, p. 283-285, 2015.

DONATELI, C. P.; AVELAR, P. S.; EINLOFT, A. B. N; COTTA, R. M. M.; COSTA, G. D. Evaluation of Health Surveillance in the Zona da Mata Mineira: from standards to practice. **Ciência & Saúde Coletiva**, v.22, n.10, p.3439-3455, 2017.

ESPINOSA, M.; GERMAN, A.; ABRIL, M.; SCAVUZZO, C. M. Satellite Based temporal forecast modeling for Chikungunya, Dengue and Zika diseases through *Aedes aegypti* oviposition with a operational perspective. **Sent to IPRS**, 2017.

ESPINOSA, M.; WEINBERG, D.; ROTELA, C.H.; POLOP, F.; ABRIL, M.; SCAVUZZO, C.M. Temporal Dynamics and Spatial Patterns of *Aedes aegypti* Breeding Sites, in the Context of a Dengue Control Program in Tartagal (Salta Province,Argentina). **PLoS Neglected Tropical Diseases**, v.10, n.5, 2016.

ESTALLO E. L.; CARBAJO, A. E.; GRECH, M. G.; FRÍAS-CÉSPEDES, M.; LÓPEZ, L.; LANFRI, M.; LUDUEÑA-ALMEIDA, F.F.; ALMIRÓN, W.R. Spatio-temporal dynamics of dengue 2009 outbreak in Córdoba City, Argentina. **Acta Trópica**, v.136, n.1, p.129-136, 2014.

ESTALLO, E.L.; BENITEZ, E.M.; LANFRI, M.; SCAVUZZO, C.M.; ALMIRÓN, W.R. MODIS Environmental Data to Assess Chikungunya, Dengue, and Zika Diseases Through *Aedes (Stegomia) aegypti* Oviposition Activity Estimation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 2016.

ESTALLO, E.L.; LUDUEÑA-ALMEIDA, F.; VISINTIN, A.M.; SCAVUZZO, C.M.; LANFRI, M.A.; INTROINI, M.V.; ZAIDENBERG, M.; ALMIRÓN, W.R. Effectiveness of normalized difference water index in modelling *Aedes aegypti* house index. **International Journal of Remote Sensing**, v.33, n.13, p.4254-4265, 2012.

FARES, R.C.G.; SOUZA, K.P.R.; AÑES, G.; RIOS, M. Epidemiological Scenario of Dengue in Brazil. **BioMed Research International**, v. 2015, p. 1–13, 2015.

FREITAS, J.R.; SANTOS, A.L.P.; PISCOYA, V.C.; CUNHA, A.L.X.; FILHO, M.C. **Modelagem em Séries Temporais Aplicados a Números de Notificações Mensais de Dengue em Pernambuco**. Comunicação oral. Apresentado no III Congresso internacional das ciências agrárias, 2018. Disponível em: <https://doi.org/10.31692/2526-7701.IIICOINTERPDVAGRO.2018.00166> COINTERPDVAGRO.2018.00166

GERARDIN, P.; BARAU, G.; MICHAULT, A.; BINTNER, M.; RANDRIANAIVO, H.; CHOKER, G.; *et al.* Multidisciplinary prospective study of mother-to-child chikungunya virus infections on the island of La Reunion. **PLoS Med**, 2008.

HAMLET, A.; JEAN, K.; PEREA, W.; YACTAYO, S.; BIEY, J.; VAN KERKHOVE, M.; FERGUSON, N.; GARSKE, T. The seasonal influence of climate and environment on yellow fever transmission across Africa. **PLoS Neglected Tropical Diseases**, v.12, n.3, p.1-17, 2018.

JAENISCH, T.; ROSENBERGER, K.D.; BRITO, C.; BRADY, O.; BRASIL, P.; ERNESTO, T.A.; MARQUES, E.T.A. Risk of microcephaly after Zika virus infection in Brazil, 2015 to 2016. **Bull World Health Organization**, v.95, p.191–198, 2017.

KOHLER, L.I.A.; AZEVEDO, J.; LIMA, M.A.; MARINHO, R.A.; SOUZA, L.J. Perfil epidemiológico dos pacientes com evolução subaguda e crônica de infecção por Chikungunya. **Revista da Sociedade Brasileira de Clínica Médica**, v.16, n.1, p.13-17, 2018.

LI, Z.; LIU, T.; ZHU, G.; LIN, H.; ZHANG, Y.; HE, J. *et al.* Dengue baidu search index data can improve the prediction of local dengue epidemic: A case study in guangzhou, china. **PLOS Neglected Tropical Diseases**, v. 11, n. 3, p. 1–13, 2017.

LIU, G.; HU, X.; WANG, E.; ZHOU, G.; CAI, J.; ZHANG, S. Svr-eemd: An improved eemd method based on support vector regression extension in ppg signal denoising. **Computational and Mathematical Methods in Medicine**, 2019.

LINDSEY, N.P.; STAPLES, J.E.; POWELL, K.; RABE, I.B.; FISCHER, M.; POWERS, A.M.; KOSOY, O.I.; MOSSEL, E.C.; MUNOZ-JORDAN, J.L.; BELTRAN, M.; HANCOCK, W.T.; TOEWS, K.A.E.; ELLIS, E.M.; ELLIS, B.R.; PANELLA, A.J.; BASILE, A.J.; CALVERT, A.E.; LAVEN, J.; GOODMAN, C.H.; GOULD, C.V.; MARTIN, S.W.; THOMAS, J.D.; VILLANUEVA, J.; MATAIA, M.L.; SCIULLI, R.; GOSE, R.; WHELEN, A.C.; HILLS, S.L. Ability to serologically 1 confirm recent Zika virus infection in areas with varying past incidence of dengue virus infection — United States and territories, 2016. **Journal of Clinical Microbiology**, p.1-17, 2017.

LORENZO, M.G.; VIDAL, D.M.; ZARBIN, P.H.G. Control of neglected disease insect vectors: future prospects for the use of tools based on behavior manipulation-interference. **Jounal of Brazilian Chemistry Society**, v.25, n.10, p.1799–1809, 2014.

MARQUES-TOLEDO, C.A.; DEGENER, C.M.; VINHAL, L.; COELHO, G.; MEIRA, W.; CODEÇO, C.T.; TEIXEIRA, M.M. Dengue prediction by the web: Tweets are a useful tool for estimating and forecasting dengue at country and city level. **PLOS Neglected Tropical Diseases**, v. 11, n. 7, p. 1–20, 2017.

MATTIOLI, F.E.R.; ANDRADE, R.B.; ESTEVEZ, E.T. Predição De Casos De Dengue Utilizando Redes Neurais Artificiais. **Jornal de Engenharia, Tecnologia e Meio Ambiente**, v.1, n.2, 2017.

MEDLOCK, J.M.; HANSFORD, K.M.; SCHAFFNER, F.; VERSTEIRT, V.; HENDRICKX, G.; ZELLER, H.; VAN BORTEL, W. A review of the invasive mosquitoes in Europe: ecology, public health risks, and control options. **Vector Borne Zoonotic Diseases**, v.12, n.6, p.435–447, 2012.

MEHTA, R.; SOARES, C.N.; CARRERA, R.M.; ELLUL, M. *et al.* The spectrum of neurological disease associated with Zika and chikungunya viruses in adults in Rio de Janeiro, Brazil: A case series. **PLOS Neglected Tropical Diseases**, v.12, n.2, p.1-19, 2018.

MELO, J.C.S.; MORAES, R.M. Sistema Espacial de Suporte à decisão para gestão do combate ao dengue usando lógica fuzzy. **Tendências em Matemática aplicada e computacional**, v.19, n.3, p. 405-421, 2018.

MITTELMANN, M.; SOARES, D.G. Previsão de Casos de Dengue no Município de Guarulhos com Redes Neurais Artificiais Multicamadas e Recorrentes. **Revista de Informática Aplicada**, v.13, n.2, 2017.

MORENS, D.M.; FAUCI, A.S. Chikungunya at the door – Déjà Vu all over again? **New England Journal of Medicine**, v.371, p.885–887, 2014.

MORSY, S.; DANG, T.N.; KAMEL, M.G.; ZAYAN, A.H.; MAKRAM, O.M.; ELHADY, M.; HIRAYAMA, K.; HUY, N.T. Prediction of zika-confirmed cases in brazil and colombia using google trends. **Epidemiology and Infection**, v. 146, n. 13, p. 1625–1627, 2018.

MUSAH, A.; RUBIO-SOLIS, A.; BIRJOVANU, G.; SANTOS, W.P.; MASSONI, T.; KOSTKOVA, P. Assessing the relationship between various climatic risk factors & mosquito abundance in recife, brazil. In: **Proceedings of the 9th International Conference on Digital Public Health**. [S.l.: s.n.], p. 97–100, 2019.

MUSSO, D.; CAO-LORMEAU, V.M.; GUBLER, D.J. Zika virus: following the path of dengue and chikungunya? **The Lancet**, v. 386, n. 9990, p. 243–244, 2015.

UNIVERSIDADE DE BRASÍLIA. Núcleo de Estudos em Saúde Pública. **Perfil do município de Recife/PE - análise do acesso e da qualidade da atenção integral à saúde da população LGBT no Sistema Único de Saúde**. Brasília: NESP, 2016. Disponível em: <http://www.nesp.unb.br> Acesso em: 20 nov. 2019.

NOGUEIRA, R.M.R.; SANTOS, C.C.; TURTLE, L.; SEQUEIRA, P.C.; BROWN, D.W.; GRIFFITHS, M.J.; FILIPPIS, A.M.B.; SOLOMON, T.O.M. **The spectrum of neurological disease associated with Zika and chikungunya viruses in adults in Rio de Janeiro, Brazil: a case series**. June 2016, 2018. Disponível em: <https://www.arca.fiocruz.br/handle/icict/25269>.

NUNES, M.R.T.; FARIA, N.R.; VASCONCELOS, J.M.; GOLDING, N.; KRAEMER, M.U.G.; OLIVEIRA, L.F.; AZEVEDO, R.S.S.; SILVA, D.E.A.; SILVA, E.V.P.; SILVA, S.P.; CARVALHO, V.L.; COELHO, G.E.; CRUZ, A.C.R.; RODRIGUES, S.G.R.; VIANEZ JÚNIOR, J.L.S.G.; NUNES, B.T.D.; CARDOSO, J.F.; TESH, R.B.; HAY, S.I.; PYBUS, O.G.; VASCONCELOS, P.F.C. Emergence and potential for spread of Chikungunya virus in Brazil. **BMC Medicine**, v.13, n.1, 2015.

ORGANIZAÇÃO PAN-AMERICANA DA SAÚDE. Centro de Prevenção e Controle de Doenças dos Estados Unidos. **Preparativos e resposta para o vírus de Chikungunya nas Américas**. Washington, D.C.: OPAS/CDC, 2011. Disponível em http://www.paho.org/hq/index.php?option=com_docman&task=doc_download&gid=16984&Itemid=&lang=en. Acesso em: 26 nov. 2019.

PIMENTA, F.G.; ALVIM, A.L.; MEIRELLES, P. Machine learning techniques applied to the identification of patients with sepsis. **Journal of Infection Control**, v. 9, n. 1, p. 32-36, 2020.

PORSE, C.C.; KRAMER, V.; YOSHIMIZU, M.H.; METZGER, M.; HU, R.; PADGETT, K.; VUGIA, D.J. Public health response to *Aedes aegypti* and *A. albopictus* mosquitoes invading California, USA. **Emerging Infectious Diseases**, v. 21, n. 10, p. 1827–1829, 2015.

POSSAS, C.; BRASIL, P.; MARZOCHI, M.C.A.; TANURI, A.; MARTINS, R.M.; MARQUES, E.T.A.; BONALDO, M.C.; FERREIRA, A.G.P.; LOURENÇO-DE-OLIVEIRA, R.; NOGUEIRA, R.M.R.; SEQUEIRA, P.C.; MARZOCHI, K.B.F.; HOMMA, A. Zika puzzle in Brazil: peculiar conditions of viral introduction and dissemination – A Review. **Memórias do Instituto Oswaldo Cruz**, v. 112, n. 5, p. 319-327, 2017.

PRADIER, S.; LECOLLINET, S.; LEBLOND, A. West Nile virus epidemiology and factors triggering change in its distribution in Europe. **Revue Scientifique et Technique**, v. 31, n. 3, p. 829–844, 2012.

PROGRAMA DAS NAÇÕES UNIDAS PARA O DESENVOLVIMENTO. **Atlas do desenvolvimento humano no Brasil 2013**: IDHM renda. Disponível em: <http://www.pnud.org.br/arquivos/idhm-renda.pdf>. Acesso em: 20 nov. 2019.

PYTHON SOFTWARE FOUNDATION. *Python Language Reference*. Fredericksburg, VA, 2020. Disponível em: <https://www.python.org/downloads/>. Acesso em: 3 mar. 2020.

QGIS Development Team. *QGIS Geographic Information System*. [S.l.], 2020. Disponível em: <http://qgis.org>. Acesso em: 3 mar. 2020.

ROTH, A.; MERCIER, A.; LEPERS, C.; HOY, D.; DUITUTURAGA, S.; BENYON, E.; GUILLAUMOT, L.; SOUARÈS, Y. Concurrent outbreaks of dengue, chikungunya and Zika virus infections – an unprecedented epidemic wave of mosquito-borne viruses in the Pacific 2012–2014. **Eurosurveillance**, v. 19, e-20929, 2014.

RUBIO-SOLIS, A.; MUSAH, A.; SANTOS, W.P.; MASSONI, T.; BIRJOVANU, G.; KOSTKOVA, P. Zika virus: Prediction of aedes mosquito larvae occurrence in Recife (Brazil) using online extreme learning machine and neural networks. *In: INTERNATIONAL CONFERENCE ON DIGITAL PUBLIC HEALTH, 9., 2019, Marselha, FR. Proceedings* [...]. Marselha, FR: DPH, 2019. p. 101–110.

SALAMI, D.; SOUSA, C.A.; MARTINS, M.R.O.; CAPINHA, C. Predicting dengue importation into Europe, using machine learning and model-agnostic methods. **Scientific Reports**, v.10, p.1-13, 2020.

SANTOS, V.S. Ciclo de vida do *Aedes aegypti*. **Brasil Escola**. Disponível em <https://brasilestola.uol.com.br/animais/ciclo-vida-aedes-aegypti.htm>.

SCAVUZZO, J.M.; TRUCCO, F.C.; TAURO, C.B.; GERMAN, A.; ESPINOSA, M.; ABRIL, M. Modeling the temporal pattern of Dengue, Chikungunya and Zika vector using satellite data and neural networks. **XVII Workshop on Information Processing and Control (RPIC)**, 2017.

SHARMA, V.; KUMAR, A.; PANAT, L.; KARAJKHEDE, D.G.; LELE, A. Malaria outbreak prediction model using machine learning. **International Journal of Advanced Research in Computer Engineering and Technology**, v. 4, p. 4415–4419, 2015.

SHEPARD, D.S.; COUDEVILLE, L.; HALASA, Y.A.; ZAMBRANO, B.; DAYAN, G.H. Economic impact of dengue illness in the Americas. **American Journal of Tropical Medicine and Hygiene**, v. 84, n. 2, p.200-207, 2011.

SIRIYASATIEN, P.; CHADSUTHI, S.; JAMPACHAISRI, K.; KESORN, K. Dengue epidemics prediction: A survey of the state-of-the-art based on data science processes. **IEEE Access**, v. 6, p. 53757–53795, 2018.

SLAVOV, S.N.; OTAGUIRI, K.K.; KASHIMA, S.; COVAS, D.T. Overview of Zika virus (ZIKV) infection in regards to the Brazilian epidemic. **Brazilian Journal of Medical Biology Research**, v. 49, e-5420, 2016.

TOSEPU, R.; TANTRAKARNAPA, K.; WORAKHUNPISET, S.; NAKHAPAKORN, K. **Environment and Natural Resources Journal**, v. 16, n. 2, p. 1-10, 2018.

VERÍSSIMO, F.S.; BARSANTE, L.S.; ACEBAL, J.L.; CARDOSO, R.T.N. Modelagem e controle do *Aedes aegypti* durante as estações do ano através do Algoritmo Genético. **Proceeding Series of the Brazilian Society of Applied and Computational Mathematics**, v. 4, n. 1, 2016.

VILLARDI, J.W.R. A vigilância em saúde ambiental no Brasil – uma reflexão sobre seu modelo de atuação: necessidades e perspectivas. Tese (Doutorado) – **Escola Nacional de Saúde Pública Sergio Arouca**, Rio de Janeiro, 2015. 74 f.

WEKA. *Weka 3: Data Mining Software in Java*. 2020. Hamilton, NZ: University of Waikato, 2020. Disponível em: <https://www.cs.waikato.ac.nz/ml/weka/>. Acesso em: 3 mar. 2020.

WORLD HEALTH ORGANIZATION. **Global Strategy for Dengue Prevention and Control, 2012–2020**. Washington, DC: WHO, 2015. Disponível em: <http://www.who.int/denguecontrol/9789241504034/en/>. Acesso em: 4 mai. 2019.

WILDER-SMITH, .A; GUBLER, D.J.; WEAVER, S.C.; MONATH, T.P.; HEYMANN, D.L.; SCOTT, T.W. Epidemic arboviral diseases: priorities for research and public health. **The Lancet of Infection Diseases**, v.17, p.101–106, 2017.

WITTEN, I.H.; FRANK, E. **Data mining: practical machine learning tools and technique**. San Francisco, CA: Morgan Kaufmann Publishers, 2005.

ZANLUCA, C.; MELO, V.C.; MOSIMANN, A.L.; SANTOS, G.I.; SANTOS, C.N.; LUZ, K. First report of autochthonous transmission of Zika virus in Brazil. **Memórias do Instituto Oswaldo Cruz**, v.110, n.4, p.569–572, 2015.

ZARA, A.L.S.A.; SANTOS, S.M.; OLIVEIRA, E.S.F.; CARVALHO, R.G.; COELHO, G.E. Estratégias de controle do *Aedes aegypti*: uma revisão. **Revista Epidemiologia e Serviços de Saúde**, v. 25, n. 2, p. 391-404, 2016