

Universidade Federal da Grande Dourados

UFGD

Programa de Pós-Graduação em

Entomologia e Conservação da Biodiversidade

**MODELAGEM NA PREDIÇÃO DE RISCO DE INFESTAÇÃO DE *Aedes aegypti*
(Diptera, Culicidae) E SUBSÍDIOS GOVERNAMENTAIS NA TOMADA DE
DECISÃO PARA VIGILÂNCIA E MONITORAMENTO**

Thiago Augusto Dolacio Maia e Silva

Dourados–MS

Fevereiro – 2017

Universidade Federal da Grande Dourados
UFGD
Faculdade de Ciências Biológicas e Ambientais
FCBA
Programa de Pós-Graduação em Entomologia e Conservação da
Biodiversidade
PPGECD

Thiago Augusto Dolacio Maia e Silva

MODELAGEM NA PREDIÇÃO DE RISCO DE INFESTAÇÃO DE *Aedes aegypti* (Diptera, Culicidae) E SUBSÍDIOS GOVERNAMENTAIS NA TOMADA DE DECISÃO PARA VIGILÂNCIA E MONITORAMENTO

Dissertação apresentada ao Programa
de Pós-Graduação em Entomologia e
Conservação da Biodiversidade,
Universidade Federal da Grande Dourados
(UFGD), como parte dos requisitos exigidos
para obtenção do título de MESTRE em
ENTOMOLOGIA E CONSERVAÇÃO DA
BIODIVERSIDADE.

Área de Concentração: Biodiversidade e
Conservação

Orientador: Prof. Dr. Rhainer Guillermo Nascimento Ferreira

Dourados–MS

Fevereiro – 2017

Dados Internacionais de Catalogação na Publicação (CIP).

S586m	Silva, Thiago Augustho Dolacio Maia e. Modelagem na predição de risco de infestação de Aedes aegypti (Diptera, Culicidae) e subsídios governamentais na tomada de decisão para vigilância e monitoramento. / Thiago Augustho Dolacio Maia e Silva. – Dourados, MS : UFGD, 2017. 45f.
	Orientador: Prof. Dr. Rhainer Guillermo Nascimento Ferreira. Dissertação (Mestrado em Entomologia e Conservação da Biodiversidade) – Universidade Federal da Grande Dourados.
	1. LIRAA. 2. MaxEnt. 3. Monitoramento entomológico.4. Vetor.I. Título.

Ficha catalográfica elaborada pela Biblioteca Central – UFGD.

"MODELAGEM NA PREDIÇÃO DE RISCO DE INFESTAÇÃO DE *Aedes aegypti*
(DIPTERA, CULICIDAE) E SUBSÍDIOS GOVERNAMENTAIS NA TOMADA DE
DECISÃO PARA VIGILÂNCIA E MONITORAMENTO"

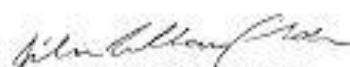
Por

THIAGO AUGUSTHO DOLACIO MAIA E SILVA

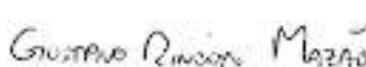
Dissertação apresentada à Universidade Federal da Grande Dourados (UFGD),
como parte dos requisitos exigidos para obtenção do título de
MESTRE EM ENTOMOLOGIA E CONSERVAÇÃO DA BIODIVERSIDADE
Área de Concentração: Biodiversidade e Conservação



Dr. Rhainer Guillermo Nascimento Ferreira
Orientador/Presidente - UFSCar



Dra. Júlia Calhau Almeida
Membro titular - UFGD



Dr. Gustavo Rincon Mazão
Membro titular - UFSCar

Aprovada em: 21 de fevereiro de 2017

DEDICATÓRIA

Dedico à minha família, minha grande família, consanguínea e espiritual da qual
nos encontramos mais uma vez aqui na Terra.

Dedico aos meus amigos, àqueles verdadeiros, os que mesmo sabendo da minha
imensa imperfeição ainda assim me auxiliaram e continuam a auxiliar.

AGRADECIMENTOS

Em primeiro lugar ao ETERNO. Pois que a cada passo me guia, me sonda e em sua Infinita Misericórdia tem me concedido incontáveis bênçãos em todos os dias em minha vida. E cada bênção está representada por situações e pessoas das quais em cada parágrafo desse agradecimento cito.

Aos meus pais. Sem eles não seria o que sou. Devo tudo, desde o meu nascimento até o presente dia, tendo em conta todos os auxílios, toda preocupação, todo cuidado, enfim, todo o imenso amor que eles tem por mim.

À ex-minha namorada, Tatiene Mendonça Zenni, pelo companheirismo em toda singular situação, aos perdões, às alegrias e a felicidade que foi tê-la fazendo parte da minha vida.

Ao meu orientador, Prof. Dr. Rhainer Guillermo Nascimento Ferreira, que, quando eu precisei, me auxiliou e me socorreu nas duas situações mais críticas do meu mestrado. Obrigado por ter me ensinado com seu exemplo como ser uma pessoa totalmente fora da mediocridade, um ser humano bom e um homem temente a Deus. Sem você nunca completaria esse mestrado.

Ao meu amigo e irmão Mauro Tonelli Souza Neto simplesmente por tudo.

À Lorena Froio e Amanda Crivelaro pela amizade e por terem me auxiliado imensamente no começo do meu mestrado.

Ao meu amigo e colega Gabriel Barbosa pela camaradagem e pela harmonia com a qual convivemos nesse período do mestrado, apesar da louça suja.

Ao meu sensei e tio Arnaldo Mendonça Junior, que em muitas situações foi como um pai pra mim.

Ao meu mestre Paulo Henrique Mendonça Candea, que hoje é como um grande avô na minha vida, obrigado por todo o conhecimento, pela amizade e por ter sido a ponte para que eu conhecesse o Aikido, essa arte da paz que me auxiliou e auxilia de tantas formas, além de ter sido a única coisa que sanou minha ansiedade.

Agradeço Universidade Federal da Grande Dourados (UFGD) por ter sido responsável pela minha formação superior.

Ao programa de Pós-Graduação em Entomologia e Conservação da Biodiversidade da Universidade Federal da Grande Dourados (UFGD), pela oportunidade de me aprimorar academicamente em um curso de pós-graduação.

Agradeço a CAPES pela concessão da bolsa de mestrado.

À FUNDECT e PROAP pelos recursos.

E a todos os meus colegas que de alguma forma contribuíram para a conclusão desse trabalho.

BIOGRAFIA

Thiago Augusto Dolacio Maia e Silva, nasceu em Uberaba, Minas Gerais no dia primeiro de fevereiro de 1988. Filho de José de Melo Silva, dentista e Auri Mary Dolacio Maia Silva, psicóloga.

Biólogo, pela UFGD desde 2014.

SUMÁRIO

RESUMO.....	vi
ABSTRACT.....	vii
I. INTRODUÇÃO.....	1
II. OBJETIVO E HIPÓTESE.....	5
III. MATERIAL E MÉTODOS.....	5
2.1. Espécie de estudo.....	6
2.2. Coletade dados.....	7
2.3. Aspectos funcionais e abrangências do LIRAA.....	8
2.4. Análise dos dados.....	9
III. RESULTADOS.....	11
IV. DISCUSSÃO.....	20
REFERÊNCIAS.....	24
APÊNDICES.....	32

RESUMO

Os processos de urbanização e globalização tem gerado um grande problema para a saúde pública em todo mundo. Os vírus relacionados a vetores como o *Aedes aegypti* reemergiram de forma violenta e vieram nos últimos anos, causando um grande aumento no número de pessoas infectadas, uma crescente disseminação e número de óbitos decorrentes dessas doenças. Por isso, ações que foquem o planejamento e controle de infestação de vetores a partir de modelos de prevenção de risco com resultados estatísticos confiáveis se tornaram necessários para que o controle prioritário possa ser desenvolvido. No presente estudo, foi utilizado um conjunto de dados do LIRAA e do investimento governamental para controle do *Ae. aegypti* referente a 281 municípios brasileiros. Os dados do LIRAA foram obtidos do Ministério da Saúde e todos os dados foram limitados a municípios que tiveram dados contínuos de 2011 a 2015 para que houvesse uma lógica temporal nas análises. O trabalho teve como objetivo fazer uma modelagem de predição de risco da infestação de *Ae. aegypti* juntamente com os dados obtidos do LIRAA dos anos de 2011 e 2015. Com isso, foram construídos modelos de risco potencial utilizando o software MaxEnt, a partir das coordenadas geográficas dos municípios e a partir de dados climáticos de todo o país para indicar os locais com os maiores níveis de risco infestação do vetor. Adicionalmente, os valores finais de investimento per capita por ano foram correlacionados com os valores do LIRAA de cada ano a fim de analisar se os investimentos realizados tiveram efeitos sobre os índices de infestação. Os resultados sugerem que não houve correlação entre os esforços governamentais e o LIRAA dos anos amostrados, com os modelos de risco epidemiológico indicando que a variação nos níveis de infestação provavelmente se devem a fatores ambientais e socioeconômicos.

PALAVRAS-CHAVE: LIRAA, MaxEnt, monitoramento entomológico, vetor.

ABSTRACT

The processes of urbanization and globalization have generated a major problem for public health worldwide, allowing viruses related to vectors such as *Aedes aegypti* to reemerge violently and become increasingly widespread, causing death. Therefore, actions that focus on the planning and control of vector infestation based on risk prevention models with reliable statistical results have become necessary so that priority control can be developed. In the present study, we used a dataset from the LIRAA and the government investment to control *Ae. Aegypti* referring to 281 Brazilian municipalities. The data from the LIRAA were obtained from the Ministry of Health and all data were limited to municipalities that had continuous data from 2011 to 2015 so that there was a temporal logic in the analyzes. The main goal of this study was to build prediction models for the risk of *Ae. aegypti* infestation levels together with data obtained from the LIRAA of the years 2011 and 2015. Hence, potential risk models were constructed using the MaxEnt software, based on the geographical coordinates of the municipalities and from climatic data from all over the country to indicate the locations with the highest levels of vector infestation risk. In addition, the final per capita investment values per year were correlated with the LIRAA values of each year in order to analyze whether the investments made had an effect on infestation levels. The results suggest that there was no correlation between the government efforts and the LIRAA of the years sampled, with epidemiological risk models indicating that the variation in infestation levels is probably due to environmental and socioeconomic factors.

KEY WORDS: LIRAA, MaxEnt, entomological monitoring , vector.

I. INTRODUÇÃO

As epidemias pelas arboviroses dengue, febre *chikungunya* e o Zika vírus têm crescido drasticamente a partir dos anos 90, devido principalmente à ampla capacidade de adaptação do seu principal vetor, o culicídeo *Aedes aegypti* (Linneaus, 1762) (Vasilakis & Weaver, 2008; Zanluca et al., 2015). Altos níveis de infestação do vetor têm sido notificados em vários países, devido principalmente à sua plasticidade genética e também pelas atividades humanas que favorecem a disseminação desse mosquito em áreas urbanas. Então, com as ações antrópicas e o processo de globalização, os mosquitos podem ser transportados rapidamente de um continente a outro, permitindo que as doenças relacionadas a esse vetor venham a ter uma dimensão global (Becker et al., 2012; Benelli & Mehlhorn, 2016). Deste modo, as doenças transmitidas por *Ae. aegypti* se tornaram uma preocupação geral de saúde pública, responsáveis por altos índices de hospitalizações, morbidade e mortalidade, principalmente em crianças (Gubler, 2011). Estudos recentes apontam que 3,6 bilhões de pessoas estão em risco, com mais de 230 milhões de casos reportados de infecção pela dengue (WHO, 2009; Gubler, 2011; Bhatt et al., 2013).

Já é conhecido que o crescimento populacional associado à urbanização pouco planejada e o descaso das autoridades competentes para com programas de controle e prevenção de enfermidades infecciosas, aumentam as possibilidades que permitem que condições consideradas ótimas para a proliferação do *Ae. aegypti* ocorram. Esses fatores colaboram significativamente para a infestação a nível mundial desse vetor e consequentemente a disseminação do vírus responsável por causar a dengue (Bhatt et al., 2013). Consequentemente, as doenças relacionadas com este vetor reemergiram, sobretudo, nos países do hemisfério sul (Jupp & McIntosh, 1988). Estudos apontam que as epidemias do vírus da dengue precederam as da febre *chikungunya* e zika vírus (Powers, 2007; Halstead, 2015). Depois de um período de 200 anos com raros casos, a febre *chikungunya* teve sua reincidência no Quênia, alcançando a Índia, sudeste asiático e finalmente disseminada para as Américas, causando várias mortes em crianças, idosos e imuno-deprimidos, o que aumentou a preocupação de autoridades responsáveis pela saúde pública (Staples et al., 2009; Halstead, 2015). Por sua vez, o zika vírus era negligenciado até 2015, pelo aspecto benigno da doença (Heukelbach, 2016). Porém, a Organização Mundial de Saúde (OMS) declarou como Emergência de Saúde Pública de

Importância Internacional, por ser associada a um grande número de desordens neurológicas e casos congênitos (PAHO/WHO, 2016).

Esta situação gera custos financeiros tanto para aqueles que contraíram o vírus infeccioso, como também para os sistemas de saúde pública e privada que arcam com as despesas com medicação, consultas e campanhas para erradicação do vetor. Em virtude disso, ações que foquem o planejamento e estudos sobre o controle da infestação têm sido buscados a fim de promover a prevenção de risco e identificar *hot spots* epidemiológicos (e.g. Cardoso-Leite et al., 2014). Nesse sentido, existe uma grande necessidade de obtenção de dados de campo para auxiliar órgãos de saúde pública na identificação de áreas de alto risco para o monitoramento de infestações do vetor e controle adequado da doença (Rotela et al., 2007; Boyer et al., 2014). Entretanto, mesmo que o conhecimento sobre a biologia de *Ae. aegypti* e que diversas ferramentas de diagnóstico de níveis de infestação sejam amplamente utilizados, a detecção de locais de alto risco epidemiológico e o monitoramento destes riscos permanecem mal compreendidos (Espinosa et al., 2016).

Para solucionar estes problemas, a utilização de tecnologias digitais de sensoriamento remoto e de modelagem (e.g. Philips et al., 2006) para a obtenção de índices epidemiológicos cresce rapidamente como um novo paradigma para a pesquisa na área de entomologia de vetores de doenças negligenciadas (Eisen & Eisen, 2011). Em uma revisão recente, uma grande diversidade tanto de preditores quanto de abordagens de modelagem empregadas para criar mapas de risco foi levantada, sugerindo que o mapeamento preditivo do risco de epidemias ainda é uma área jovem e em evolução (Louis et al., 2014). Em um cenário onde há o risco crescente de novas patologias associadas a vetores, como *Aedes* spp., o emprego de mapas preditivos de risco têm transformado todo o processo de visualização de modelos estatísticos, tornando-o mais eficiente, simples e de qualidade. Portanto, nesse contexto, a modelagem da distribuição potencial de insetos vetores auxilia e aperfeiçoa o monitoramento destes no âmbito de programas de vigilância destinados a combater a sua infestação e proliferação (Koch et al., 2016).

A utilização de modelos matemáticos na entomo-epidemiologia se iniciou quando Sir Ronald Ross (1908) descobriu que a malária é transmitida por mosquitos e Kermack & McKendrik (1927) teorizaram o princípio do limiar, dizendo que a introdução de indivíduos infectados em uma comunidade não pode levar a um surto epidêmico a menos que a densidade de indivíduos suscetíveis esteja acima de certo

valor crítico (Bhatt et al., 2013). Levando em consideração que modelos matemáticos complexos têm a desvantagem de muitas vezes apresentar resultados também complexos, estudos que relacionam fatores climáticos com a incidência de vetores fornecem uma visualização mais comprehensível e dinâmica dos potenciais riscos epidemiológicos (Eisen & Eisen, 2011; Cardoso-Leite et al., 2014).

Dessa maneira, como o conhecimento da distribuição do risco potencial de infestação por *Aedes* é precário, a utilização de ferramentas que associam Sistemas de Informação Geográfica (SIG) e tecnologias de análise de risco potencial podem proporcionar dados sobre proliferação do mosquito e suas respectivas áreas de ocorrência, fazendo com que observações e estudos de controle prioritário possam ser desenvolvidos (Cardoso-Leite et al., 2014). Por isso, conhecer a distribuição geográfica do vetor pode proporcionar entendimento sobre como alocar recursos de modo que o controle do mosquito possa ser otimizado (Bhatt et al., 2013). Com base nisso metodologias de modelagem e previsão de risco estão se mostrando inovadoras em estudos que buscam conhecer mais sobre modelos de nichos de espécies vetores e o seu controle.

Para melhor compreender modelagem de risco, o valor das informações espaciais é bastante apreciado, ainda mais através de mapas modelados com auxílio da tecnologia digital, possibilitando informações sobre ambientes naturais em resolução espectral, espacial e temporal (Rogers, 2006). Por isso, na biologia, é requerido mapas para vários propósitos, como no caso de estudos de monitoramento vetorial, o uso dos mapas é indicado para aumentar o entendimento sobre processos que determinam a distribuição de espécies de interesse e também para direcionar a vigilância vetorial em locais com maior distribuição (Rogers, 2006; Larson et al., 2010). Para essa finalidade, mapas são confeccionados em *softwares* específicos que relatam dados de ocorrência de espécies em conjunto com condições ambientais de determinados sítios (Melaun et al., 2015). Esse método, quando a espécie de estudo é um vetor, é denominado de modelagem vetorial.

Assim, a modelagem vetorial de distribuição de espécies lança mão de modelos tanto tradicionais, como recentes. Os principais modelos tradicionais são baseados em algoritmos complexamente estabelecidos, consequentemente não são facilmente acessíveis, pois necessitam de dados tanto de presença como também de ausência, o que o torna um modelo não muito vantajoso logicamente (Sofizadeh et al, 2016), pois é necessário maior quantidade de informações. Já nos modelos mais recentes, utiliza-se

dados somente de presença e não de ausência, logo, esses tais modelos dispõe de resultados mais confiáveis (Elith et al., 2006). Um desses modelos utiliza-se de algoritmos de entropia máxima (MaxEnt), sendo amplamente utilizados na ecologia e conservação da biodiversidade, na predição de risco de ecologia vetorial e distribuição de espécies (Elith et al., 2006; Cardoso-Leite et al., 2014; Sofizadeh et al., 2016). Por isso a vantagem da utilização desse modelo em relação à modelagem tradicional é o uso bem-sucedido ao trabalhar com dados amostrados de presença e suas elevadas funções preditivas (Elith et al., 2006).

O Maxent é um método geral para fazer previsões ou inferências a partir de informações incompletas (Phillips et al., 2006). Logo, é conveniente que o desempenho preditivo do MaxEnt tenha sido utilizado para modelar a distribuição de espécies vetores em vários exemplos na literatura (Larson et al., 2010; Elith et al., 2011; Mealun et al., 2015; Ochieng et al., 2016; Sofizadeh et al., 2016), sendo uma ferramenta de amplo uso em pesquisas e também gerando informações que contribuam no trabalho de organizações sérias, visando o bem público, direta e indiretamente. Por isso, desde que se tornou acessível em 2004, organizações governamentais e não-governamentais têm adotado o MaxEnt para mapear a distribuição de espécies em áreas de larga escala (Elith et al., 2011). Desse modo, como um método estatístico flexível e geral, o modelo de entropia máxima pode ser usado para todas essas aplicações e em todas as escalas espaciais (Phillips et al., 2006).

Entretanto, metodologias de diagnóstico e monitoramento de infestações são irrelevantes se medidas de controle *in situ* não são realizadas, ou são conduzidas de formas inefficientes. Por exemplo, no Brasil, apesar de o número de casos de dengue ser notificado, muitos são informados incorretamente (Becker et al., 2012), e por isso o Ministério da Saúde desenvolveu um programa de índices para monitorar e controlar o vetor e a febre da dengue. Dentre estes, há índices relacionados à quantidade de pessoas que foram infectadas, quantos óbitos, entre outras variáveis para tomada de decisão, interligados por uma base de dados alimentada por todos os estados do país. Com relação ao vetor, existe um índice para monitoramento de taxas de infestação do mosquito. Trata-se, no Brasil, do Levantamento Rápido do Índice de Infestação por *Aedes aegypti* (LIRAA), que funciona como uma ferramenta para vigiar e informar o nível de infestação de larvas do vetor (Ministério da Saúde, 2015).

Consequentemente, os esforços governamentais devem se concentrar nas pesquisas sistemáticas que viabilizem monitorar o processo de proliferação de *Aedes* e

em ajustes permanentes nas táticas de manejo vetorial (Glasser et al., 2011). Uma vez que ocorre a dispersão do mosquito para novas áreas onde o controle é deficiente, expandindo sua distribuição e a proliferação de doenças (Prophiro et al., 2011), ações governamentais têm focado na mitigação destes processos com altos investimentos. Entretanto, em razão de suas características entomopatogênicas, o controle do *Aedes* tem gerado esforços e ao mesmo tempo tem sido um desafio para os órgãos de saúde pública e órgãos ambientais que lidam com o problema. Fatores referentes aos problemas de infra estrutura urbana, como a geração de resíduos sólidos e a falha gestão destes, podem tornar estes investimentos e esforços ineficazes, pois o manejo realizado ainda é um procedimento tradicional e rudimentar de controle do mosquito (Zara et al., 2016).

II. OBJETIVOS E HIPÓTESES

Portanto, o presente estudo teve como objetivo principal fornecer um diagnóstico preditivo de risco de infestação por *Ae. aegypti* no Brasil para suplementar esforços de manejo e controle do vetor. Como objetivos específicos, primeiramente, focou-se em construir modelos de previsão de risco a partir de dados climáticos de todo o país e dados sobre os níveis de infestação de *Ae. Aegypti* referentes aos anos de 2011 a 2015 no Brasil. Secundariamente, teve-se como objetivo específico avaliar a relação entre os esforços governamentais no controle do vetor e os níveis de infestação no Brasil.

Portanto, baseando-se nestes objetivos, testamos as seguintes hipóteses:

- a) A distribuição potencial do vetor no Brasil não difere nos anos analisados, mostrando a dependência do vetor aos fatores climáticos;
- b) As intervenções governamentais são insuficientes para o controle desejado do vetor e, consequentemente, a proliferação do vetor não tem sofrido significativa queda frente às influências destes investimentos.

III. MATERIAL E MÉTODOS

2.1. Espécie de estudo

Aedes aegypti é o principal vetor de arbovírus que causam enfermidades epidêmicas, sendo que sua espécie se desenvolve principalmente em recipientes artificiais, num período de desenvolvimento que varia em três a quinze dias, em áreas urbanas e zonas rurais próximas ao perímetro urbano. Entretanto, ao se dispersar, o mosquito pode encontrar novos criadouros e se alastrar para áreas onde o controle é deficiente, e ao expandir sua distribuição, a proliferação de doenças associadas ao vetor também aumenta (Prophiro et al., 2011).

O *Ae. aegypti* é encontrado, principalmente, nas regiões de clima tropical e subtropical, cujo ciclo de vida é influenciado pela precipitação e temperatura, sendo que não conseguem sobreviver nos polos nem em áreas desérticas (Shope, 1991). Medem em média meio centímetro, possuindo cor preta com manchas brancas no dorso, pernas e cabeça. Apenas as fêmeas são hematófagas podendo ser vetor de agentes infecciosos causadores de doenças, e o macho tem como dieta frutas e vegetais edulcorados (Lima et al., 2011).

Ao se alimentar de sangue humano, a fêmea do mosquito contaminada injeta o vírus através da picada, que também inocula um composto anestésico, sendo indolor o processo, sentido apenas depois de algum tempo um prurido com leve inchaço e vermelhidão no local da picada. Além disso, as fêmeas costumam agir mais durante o começo da manhã ou no final da tarde, buscando alcançar o sangue especialmente dos membros inferiores, com maior frequência nos tornozelos, pois durante o vôo costumam alcançar pouco mais de meio metro do solo (Nunes et al., 2011).

Um fator que favorece a área de ação do mosquito é que a fêmea deposita seus ovos em locais com água parada, dessa forma o controle rigoroso de criadouros urbanos e áreas com água corrente que possam criar lagoas durante a estiagem devem ser constantemente monitoradas, pois as larvas desenvolvem-se rapidamente em meio aquático até se metamorfosear em um mosquito adulto, sendo que milhares de larvas podem gerar centenas de mosquitos, exigindo um eficaz controle populacional por parte das autoridades competentes em cooperação com a população (Figueiredo et al., 2013).

Existe uma grande variação nos efeitos comportamentais das fêmeas após hospedarem o vírus. Embora ainda não exista estudo detalhado, foi observado que as fêmeas do *Aedes aegypti* têm maior atividade locomotora quando estão infectadas pelo

vírus da dengue (Lima-Camara et al., 2011). Alterações no comportamento vetorial causadas pela infecção podem ter implicações epidemiológicas potenciais, tendo um impacto na dinâmica de transmissão e epidemiologia das enfermidades associadas ao *Aedes aegypti* (Lima-Camara et al., 2011).

Outra informação importante sobre o comportamento desse vetor, é o fato de ser endofílico e antropofílico, pois usa o interior das residências para se esconder e buscar alimento, no caso sangue humano, o que explica uma maior presença do mosquito nas zonas urbanas. Um detalhe importante é que algumas plantas, como as Bromeliaceae, podem abrigar larvas do mosquito entre as folhas e o caule, principalmente na época das chuvas, caso não se tenha o cuidado devido de poda, pois sua flor é o principal atrativo ornamental, largamente comercializada pelas floriculturas (Camara et al., 2016).

Na proliferação do mosquito, a fêmea exerce outro papel preocupante, pois o número de ovos é suficiente para deflagrar uma epidemia, caso estejam infectados e se desenvolvam até a fase adulta do mosquito ou se infectem com o arbovírus, podendo transformar-se em potenciais vetores. Durante a fase chuvosa, as larvas sobrevivem em maior número, o que permite uma emergência de mais mosquitos, pois a soma dos recipientes com água parada em determinado município e prováveis imóveis rurais das redondezas também se torna maior. Por isso os esforços do Governo devem se concentrar nas pesquisas sistemáticas que viabilizem monitorar o processo de proliferação de *Aedes* e em ajustes permanentes nas táticas de manejo vetorial (Glasser et al., 2011).

Convém destacar que a fêmea pode transmitir vários tipos de vírus, como chickungunya, zika vírus e quatro sorotipos conhecidos de vírus da dengue (DENV1, DENV2, DENV3, DENV4) (Pessanha et al., 2011). Em razão dessas características entomopatogênicas, o controle do *Aedes* tem gerado esforços e ao mesmo tempo tem sido um desafio para os órgãos de saúde pública e ambientais que lidam com o problema. Fatores referentes aos problemas de infra-estrutura urbana, como a falha na coleta de lixos de terrenos baldios, ruas, praças e avenidas, entre outros locais públicos que possam acumular água e facilitar a sobrevivência das larvas em todo seu processo de desenvolvimento necessitam de cuidado mais intenso, pois esse manejo é um procedimento de controle do mosquito com grande taxa de eficácia (Zara et al., 2016).

2.2. Coleta de dados

Uma vez que a previsão de criadouros de mosquitos pode indicar o risco epidemiológico, dados referentes aos níveis de infestação de 281 municípios foram obtidos do Levantamento Rápido do Índice de Infestação por *Aedes aegypti* (LIRAA) para 2011-2015. O LIRAA tem três critérios de inclusão para avaliação epidemiológica do município: capitais e cidades metropolitanas; municípios com mais de 100.000 habitantes; e municípios dentro de áreas fronteiriças do país e com alto fluxo turístico. Cada cidade é dividida em grupos de 8.100 a 12.000 casas e, desse total, 450 casas são amostradas em cada grupo, avaliando o número de casas infestadas com larvas do vetor. O LIRAA, em seguida, classifica os municípios de acordo com o nível do índice de infestação predial (IIP), calculado como:

$$(Ni/N)100$$

onde N é o número de casas pesquisadas e Ni é o número de casas onde o vetor foi encontrado. Os municípios são classificados com condição satisfatória, quando IIP < 1; em alerta, quando IIP se encontra entre 1 e 3,9; de risco de surto, quando IIP ≥ 4 . O nome de municípios com IIP ≥ 4 foram inseridos no Earth Explorer (earthexplorer.usgs.gov), junto com as coordenadas para cada ponto de interesse. Essa metodologia mostra o contexto da infestação do município identificando os criadouros predominantes, o que permite direcionar a atuação nas áreas críticas (Pereira et al., 2013; Barth, 2014).

Dados de investimento para o controle do vetor *Ae. aegypti* dos anos de 2011-2015 provenientes do Ministério da Saúde foram utilizados para avaliar a eficiência da aplicação desses recursos no controle do vetor. Dados do IBGE de habitantes por município foram utilizados então para se criar uma variável representada pelo valor investido no município por habitante, gerando um valor per capita. Todos os dados foram limitados a municípios que tiveram dados contínuos de 2011 a 2015 para que houvesse uma lógica temporal nas análises.

2.3. Aspectos funcionais e abrangências do LIRAA

O LIRAA é um processo realizado por amostragem, desenvolvido e utilizado pelo Programa Nacional de Controle de Dengue (PNCD), instituído pelo Ministério da Saúde em 2003, que visa o monitoramento e controle do número de larvas. Esse levantamento atende às demandas dos prefeitos, agentes e servidores que lidam com o monitoramento da dengue em nível municipal.

Vale destacar que o LIRAA demonstra, nos ambientes urbanos, as regiões com maior densidade de larvas, subsidiando a tomada de decisão, podendo contribuir para a consolidação e eficiência das ações de eliminação dos focos do vetor. Outra função do LIRAA é possibilitar o reconhecimento dos criadouros dominantes e as circunstâncias em torno da infestação do município, além da velocidade e a direção das intervenções quanto à uma atuação mais efetiva nas regiões mais críticas dos municípios (de Paula Freitas et al., 2016).

Para o acompanhamento dos indicadores de infestação, o PNCD padronizou a utilização de um método por amostragem (descrito na coleta de dados), para realizar o levantamento da infestação, a fim de produzir informações consistentes, não apenas durante a atuação de rotina, mas essencialmente em momentos críticos. O manejo em conjunto desses indicadores oferece uma análise aceitável da densidade do vetor, oferecendo índices admissíveis no risco de epidemia de dengue, considerando que os indicadores sejam avaliados para decisões imediatas (Passos et al., 2012).

Com o lançamento do LIRAA, começou um processo de atendimento às necessidades, por meio de formas coerentes e adequadas de descrição epidemiológica das doenças transmitidas pelo *Ae. aegypti*. Os parâmetros integrados do LIRAA fornecem subsídios para visualizar por mapas o crescimento e expansão dos focos do *Aedes*, conforme informes técnicos institucionais do Ministério da Saúde (Brasil, 2011).

2.4. Análise dos dados

Foram construídos mapas de zonas de risco potencial usando o *software* MaxEnt, que tem um forte desempenho e estabilidade na previsão (Philips et al., 2006). MaxEnt é um *software* gratuito para modelagem de distribuição de espécies a partir de um espaço geográfico utilizando dados climáticos (Booth et al., 2014). Construiu-se modelos de distribuição com as coordenadas geográficas de todos os municípios, e

depois dos municípios com IIP ≥ 4 de cada ano, para poder visualizar no mapa as áreas com maior índice de infestação de acordo com o ano. De acordo com Eisen & Eisen (2011) modelos de risco espaciais podem ser definidos como modelos estatísticos baseados em sensoriamento remoto utilizados para estimar doenças transmitidas por vetores com dados de presença ou incidência, dentro de uma determinada área geográfica. Uma vez que os dados de ausência do vetor são raros e pouco confiáveis, o uso de algoritmos só de presença e dados de presença é indicado para a construção de modelos de nicho, distribuição e risco.

As variáveis utilizadas para construir os modelos foram camadas ambientais de dados bioclimáticos e de altitude com resolução de 5arc minutos, ou seja, um quilômetro quadrado aproximadamente. O BioClim, de onde foram extraídos os dados ambientais, é um agregado de camadas climáticas de abrangência global (Booth et al., 2014). Foram usadas todas as camadas 19 BIO, e depois foram retiradas as variáveis que apresentaram altos níveis de colinearidade (r de Pearson > 0.80). Essas camadas conferem a possibilidade do programa MaxEnt dispor de dados climáticos para calcular as previsões e realizar a modelagem dos mapas gerados (Tabela 1).

Tabela 1: Variáveis ambientais utilizadas no *software* Maxent e seus significados.

Variável	Significado
BIO 1	Média anual de temperatura
BIO 2	Alcance da média diurna (média mensal temp. (temp. máx. –temp. min.))
BIO 3	Isotermalidade (BIO 2/BIO 7) (*100)
BIO 4	Sazonalidade da temperatura (Desvio padrão *100)
BIO 5	Temperatura máxima do mês mais quente
BIO 6	Temperatura mínima do mês mais frio
BIO 7	Faixa de temperatura anual (BIO 5 –BIO 6)
BIO 8	Temperatura média do trimestre mais chuvoso
BIO 9	Temperatura média do trimestre mais seco
BIO 10	Temperatura média do trimestre mais quente
BIO 11	Temperatura média do trimestre mais frio
BIO 12	Precipitação anual
BIO 13	Precipitação do mês mais chuvoso
BIO 14	Precipitação do mês mais seco
BIO 15	Sazonalidade da precipitação (coeficiente de variação)
BIO 16	Precipitação do trimestre mais chuvoso
BIO 17	Precipitação do trimestre mais seco
BIO 18	Precipitação do trimestre mais quente
BIO 19	Precipitação do trimestre mais frio

Assim, para evitar a ocorrência de falsos positivos no modelo, foi utilizado 10% (T10) no teste de porcentagem randômica como limite de sensibilidade máxima de presença, utilizado para construir os mapas de distribuição, de modo a identificar áreas com maior probabilidade de ocorrência do vetor. O T10 assume que 10% dos registros são errôneos devido a fatores como dados ambientais de baixa resolução e, portanto, exclui todos os valores de probabilidade abaixo de 10% (Pearson et al., 2007). Considerando o grande número de pontos de ocorrência, um modelo de distribuição com um limiar de presença daria resultados mais próximos do real em relação à determinação de risco, uma vez que também são analisadas áreas com níveis satisfatórios de infecção (Cardoso-Leite et al., 2014).

Também pelo MaxEnt, os modelos foram avaliados por uma variável que quantifica a área abaixo da curva de resposta, ou AUC (*area under curve*), indicando que quanto mais houver uma proximidade da linha em relação ao valor 1, melhor será o desempenho do modelo (Araújo et al., 2005). No presente estudo, foi utilizado um ranking que categoriza o AUC de acordo com sua acuidade: Excelente AUC 0,90; Bom AUC 0,80 a $\leq 0,90$; Aceitável AUC 0,70 a $\leq 0,80$; Ruim AUC 0,60 a $\leq 0,70$; Inválido AUC 0,50 a $\leq 0,60$ (Araújo et al., 2005). Adicionalmente os modelos passaram pela análise Jackknife utilizando as variáveis: altitude, bio1, bio2, bio3, bio12, bio14, bio15, bio17, bio18 e bio19. Para determinar a contribuição de cada variável para a construção dos modelos, em cada interação do algoritmo de treinamento, o aumento do ganho regularizado foi adicionado à contribuição da variável correspondente. Em uma segunda estimativa, os valores de presença de treinamento e dados de fundo são permutados aleatoriamente para cada variável ambiental. O modelo é reavaliado de acordo com os dados permutados, e as resultantes quedas na AUC de treinamento são apresentados nos resultados, normalizados como porcentagens. Os valores apresentados são médias sobre execuções repetidas (N=10).

Por fim, para investigar a eficiência dos esforços de controle do vetor, os valores de investimento per capita por ano foram correlacionados com os valores do LIRAA de cada ano utilizando-se coeficientes de correlação de Spearman no software Statistica 10®.

IV. RESULTADOS

Os resultados de predição de risco com dados $IIP \geq 1$ mostram as áreas com alerta de surto epidemiológico, referentes a todos os municípios amostrados (Figura 1 a.) e o desempenho de predição de risco de infestação pelo vetor *Ae. aegypti* para todos os municípios com $IIP \geq 1$ que foi de 0.94, ou seja, o resultado da avaliação AUC foi excelente (Figura 1 b.). Já no teste Jackknife (Figura 1 c.), a variável ambiental com maior ganho quando utilizada isoladamente é bio2, o que, portanto, parece ter a informação mais útil por si só. A variável ambiental que mais diminui o ganho quando é omitida é bio2, o que, portanto, parece ter a maior quantidade de informação que não está presente nas outras variáveis.

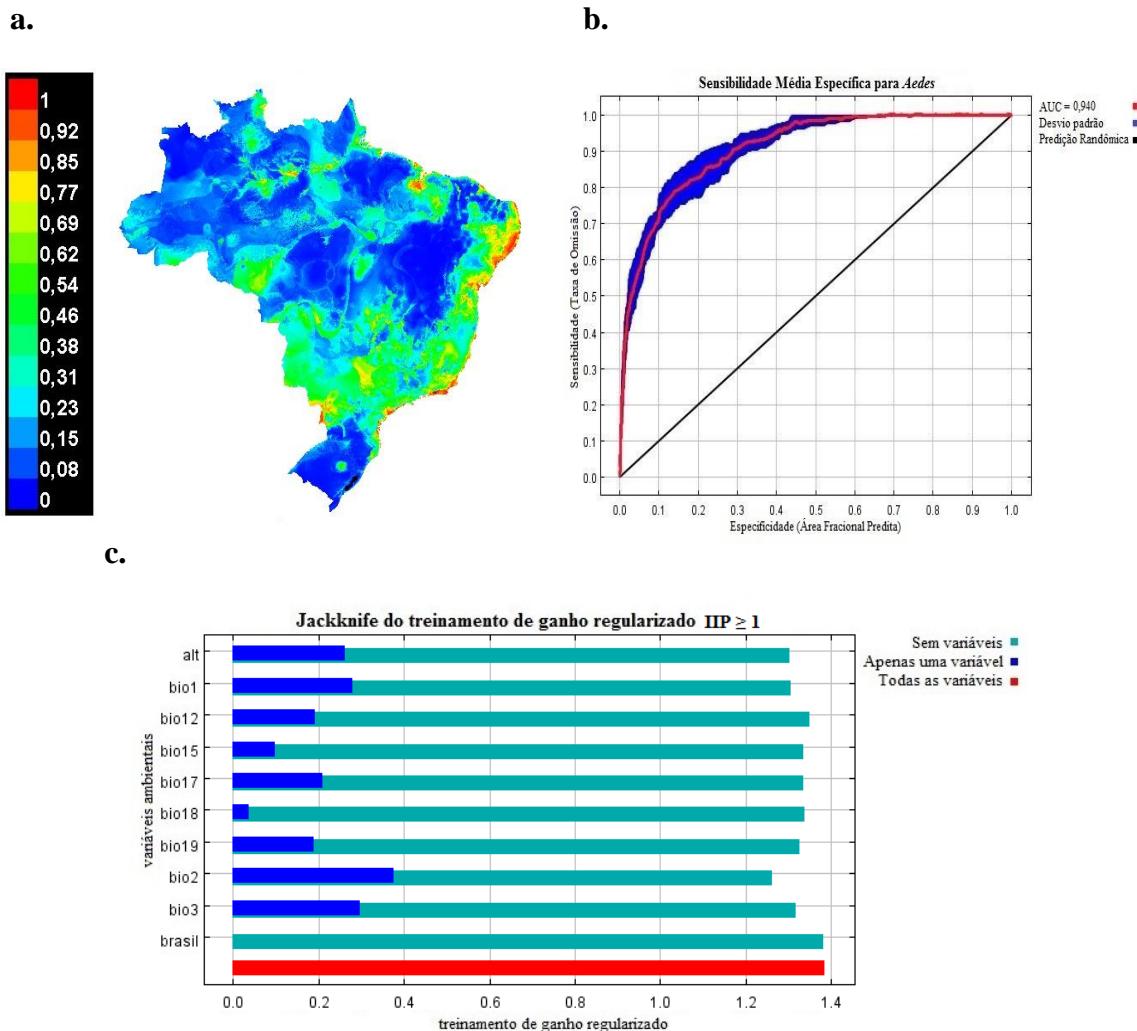


Figura 1: a. Modelo de predição de risco para os anos de 2011 a 2015 e todos os municípios $IIP \geq 1$ utilizando dados do LIRAA em áreas de presença do vetor *Ae. aegypti* e b. desempenho do modelo controle de *Ae. aegypti* para todos os municípios

$IIP \geq 1$, onde no eixo y é representado a sensibilidade (taxa de omissão) e no eixo x a especificidade (área fracionada predita). E c. representa o jackknife do treinamento de ganho para as variáveis ambientais testadas pelo treinamento de ganho regularizado de todos os municípios com $IIP \geq 1$.

Os resultados de estimativas das contribuições relativas das variáveis ambientais para os modelos construídos sugerem que bio2 (2011 e 2015), altitude (2012), bio17 (2013) e bio3 (2014) tiveram a maior contribuição (Tabela 2-6).

Tabela 2. Estimativas da contribuição percentual e importância da permutação de cada variável ambiental para o modelo de predição de risco de 2011.

Variável	Contribuição percentual	Importância da permutação
bio2	43,5	40,2
bio17	22,5	36,1
bio12	19,7	8,7
bio3	4,5	2,8
bio19	3,5	0,1
bio18	2,4	5,9
alt	2,2	5,2
bio1	1,1	0,6
bio15	0,6	0,3

Tabela 3. Estimativas da contribuição percentual e importância da permutação de cada variável ambiental para o modelo de predição de risco de 2012.

Variável	Contribuição percentual	Importância da permutação
alt	51,5	59,7
bio19	16,9	12
bio3	15,3	8,4
bio17	9,1	10,2
bio12	3,6	2,8
bio2	1,5	1,5
bio18	1,3	2,9
bio15	0,8	2,3
bio1	0,1	0,3

Tabela 4. Estimativas da contribuição percentual e importância da permutação de cada variável ambiental para o modelo de predição de risco de 2013.

Variável	Contribuição percentual	Importância da permutação
bio17	30,3	45,4
bio2	29,5	22,8
bio3	28,1	20,9
alt	7,7	8,5
bio12	1,4	0,1
bio18	1,1	0,4
bio1	0,9	1,8
bio15	0,8	0,1
bio19	0,4	0

Tabela 5. Estimativas da contribuição percentual e importância da permutação de cada variável ambiental para o modelo de predição de risco de 2014.

Variável	Contribuição percentual	Importância da permutação
bio3	30,7	23,1
bio2	24,2	6,6
bio17	8,5	15,6
alt	8,1	20,8
bio12	7,5	11,2
bio18	6,9	4,4
bio15	6,4	6,8
bio19	5,9	9,9
bio1	1,7	1,5

Tabela 6. Estimativas da contribuição percentual e importância da permutação de cada variável ambiental para o modelo de predição de risco de 2015.

Variável	Contribuição percentual	Importância da permutação
bio2	31,2	5,5
bio12	18,9	15
bio3	15,6	20,3
alt	14,4	22,2
bio17	8,4	17,5
bio15	5,6	6,9
bio1	3,2	4,9
bio19	1,7	5,1
bio18	1	2,5

Os resultados dos testes de Jackknife de importância das variáveis para a construção dos modelos de predição (Figura 2-6) indicam que as variáveis ambientais com maior ganho quando utilizadas isoladamente são bio2 (2011, 2013-2015) e altitude (2012), o que, portanto, parecem ter a informação mais útil por si só. As variáveis ambientais que mais diminuem o ganho quando são omitidas são bio2 (2011, 2013 e 2014) e altitude (2012 e 2015), as quais, portanto, parecem ter a maior quantidade de informação que não está presente nas outras variáveis.

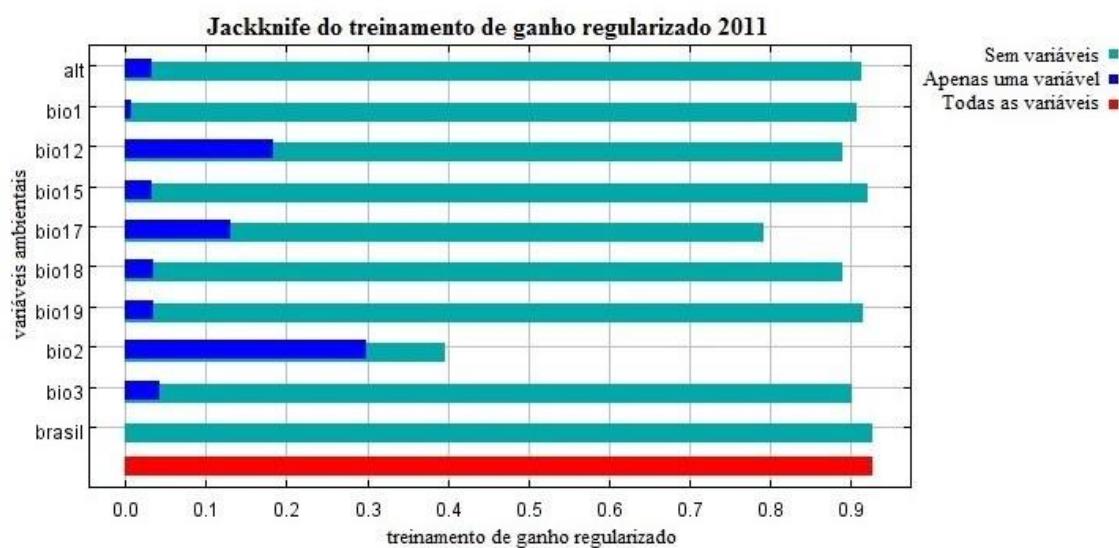


Figura 2. Resultados do teste de Jackknife do ano de 2011 para variáveis ambientais testadas pelo treinamento de ganho regularizado na construção de modelos de risco de infestação de *Ae. aegypti*.

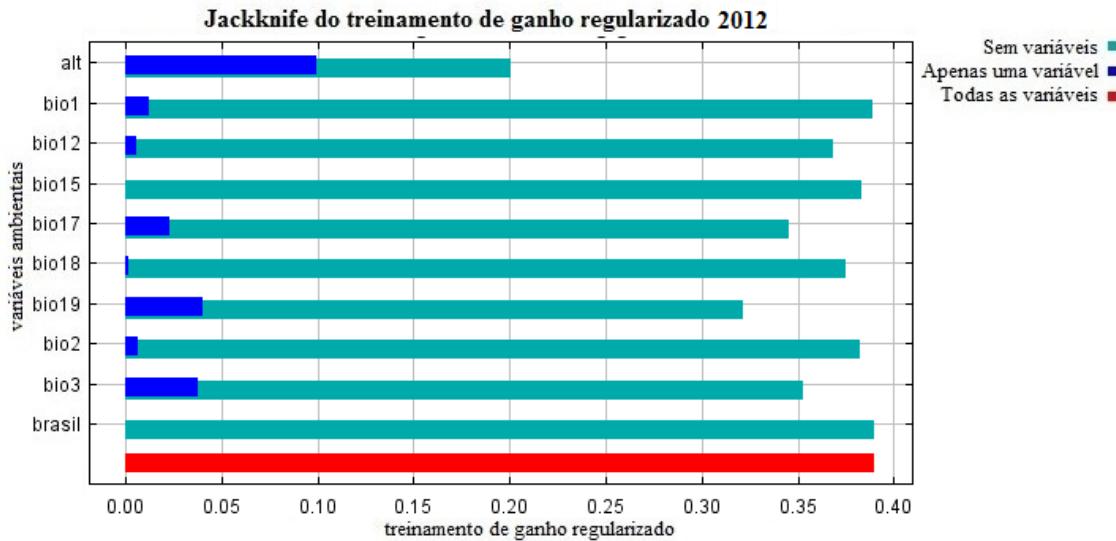


Figura 3. Resultados do teste de Jackknife do ano de 2012 para variáveis ambientais testadas pelo treinamento de ganho regularizado na construção de modelos de risco de infestação de *Ae. aegypti*.

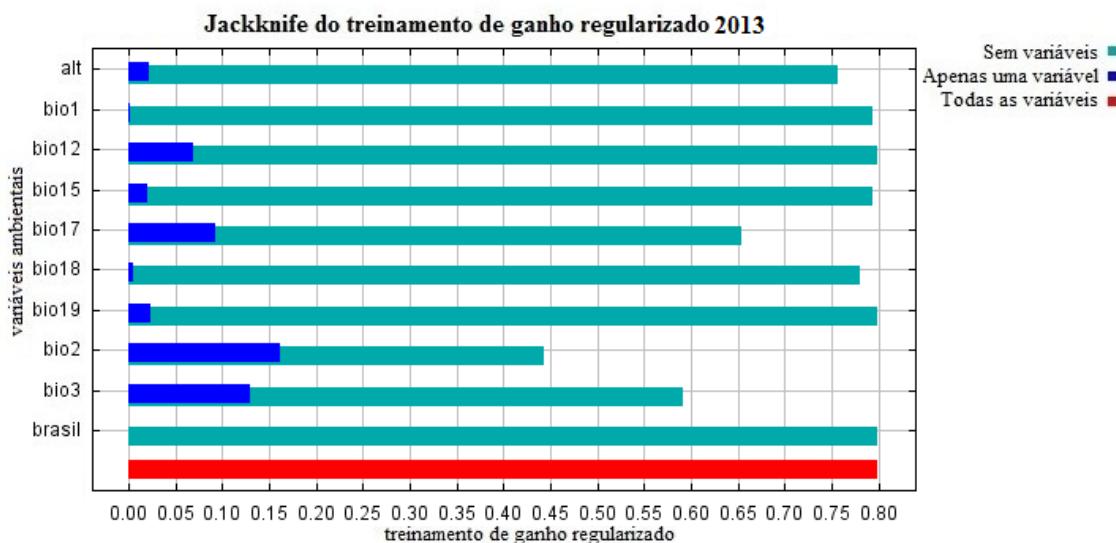


Figura 4. Resultados do teste de Jackknife do ano de 2013 para variáveis ambientais testadas pelo treinamento de ganho regularizado na construção de modelos de risco de infestação de *Ae. aegypti*.



Figura 5. Resultados do teste de Jackknife do ano de 2014 para variáveis ambientais testadas pelo treinamento de ganho regularizado na construção de modelos de risco de infestação de *Ae. aegypti*.

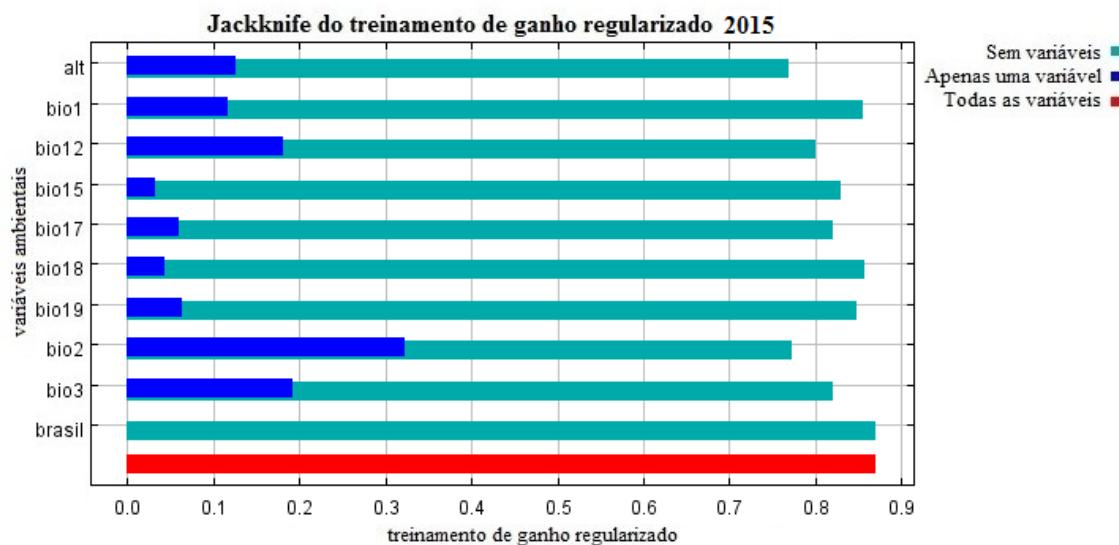


Figura 6. Resultados do teste de Jackknife do ano de 2015 para variáveis ambientais testadas pelo treinamento de ganho regularizado na construção de modelos de risco de infestação de *Ae. aegypti*.

Os resultados dos modelos de predição de risco mostram uma oscilação na taxa de infestação entre 2011 e 2015, com aumento da área infestada no ano de 2015 (Figura 7). Os modelos apresentam AUC de 0,869 para 2011; 0,859 para 2012; 0,926 para 2013; 0,894 para 2014 e 0,882 para 2015.

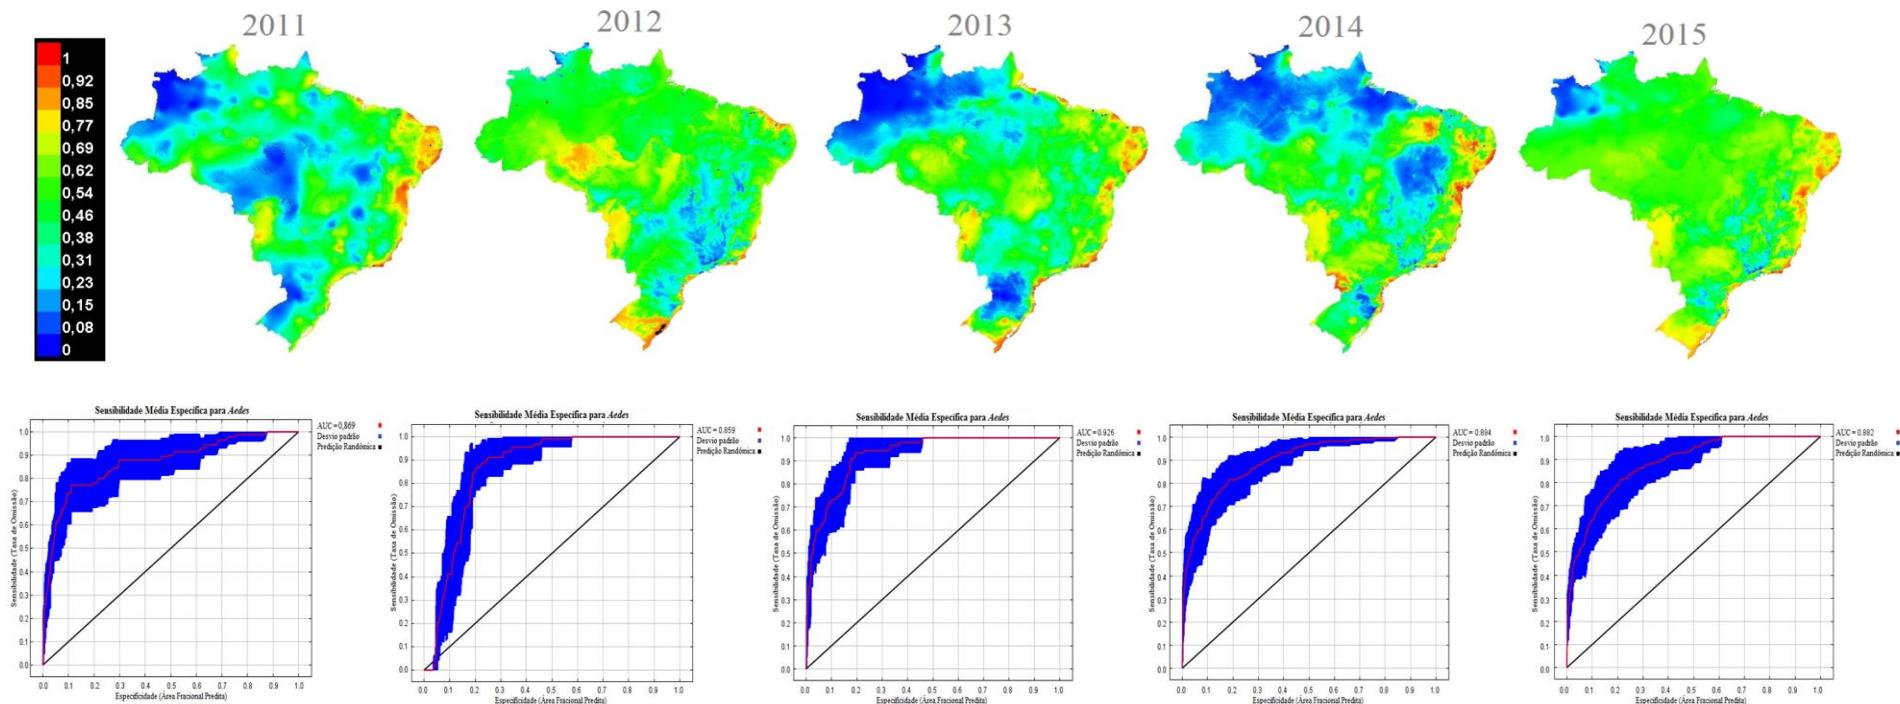


Figura 7. Modelo de predição de risco para os anos de 2011 a 2015 para os municípios em risco de surto epidêmico ($IR \geq 4$) utilizando dados do LIRAA de áreas com surtos epidemiológicos do vetor *Ae. aegypti*. A escala representa a distribuição potencial do vetor, o que indica o potencial de risco epidemiológico. Logo abaixo de cada mapa de predição de risco, são mostrados os desempenhos dos modelos, onde no eixo y é representada a sensibilidade (taxa de omissão) e no eixo x a especificidade (área fracionada predita). A linha vermelha representa os valores médios de AUC, e as áreas azuis o desvio padrão.

Os resultados mostram que não houve correlação entre o investimento realizado e o LIRAA em nenhum dos anos amostrados (Tabela 7).

Tabela 7. Coeficientes de correlação de Spearman entre os valores de investimento per capita e o LIRAA de cada ano. Não houve resultados significativos.

	LIRAA 2011	LIRAA 2012	LIRAA 2013	LIRAA 2014	LIRAA 2015
Investimento 2011	0.097	0.102	0.086	0.008	0.046
Investimento 2012	0.097	0.102	0.086	0.008	0.046
Investimento 2013	0.092	0.095	0.078	0.005	0.041
Investimento 2014	0.089	0.093	0.076	0.003	0.040

Também não houve correlação entre o investimento per capita e uma possível redução nos valores do LIRAA no ano seguinte (Tabela 8).

Tabela 8. Coeficientes de correlação de Spearman entre os valores de investimento per capita e a diferença do LIRAA de cada ano em relação ao ano anterior.

	LIRAA 2012-2011	LIRAA 2013-2012	LIRAA 2014-2013	LIRAA 2015-2014
Investimento 2011	-0.034	0.005	-0.030	0.022
Investimento 2012	-0.034	0.005	-0.030	0.022
Investimento 2013	-0.033	0.003	-0.030	0.022
Investimento 2014	-0.031	0.002	-0.031	0.023

IV. DISCUSSÃO

Como o controle de *Ae. aegypti* tem sido o principal, se não o único modo para reduzir a incidência de arbovírus tropicais, muito se tem lançado mão da modelagem preditiva para mapear riscos de infestação (Eisen & Eisen, 2011), auxiliando, deste modo, na prevenção e manejo desse vetor e indicando os melhores locais para intensificação do combate ao mosquito. No presente estudo, foram construídos mapas de predição de risco que mostram a distribuição potencial do vetor entre 2011 e 2015. Os resultados mostram que há uma oscilação na ocorrência do vetor e no risco associado, provavelmente devido à dinâmica natural das populações do vetor e de variações no clima. Adicionalmente, o investimento anual não possui relação com o índice de infestação, sugerindo que os recursos públicos investidos na redução dos níveis de infestação do vetor possivelmente não têm impactado a distribuição do vetor. Estes resultados adicionam evidências à problemática relacionada ao atual estado de alerta de saúde pública em que uma epidemia arboviral é registrada desde o ano de 2010 (Donalísio & Glasser, 2002; Khatchikian et al., 2011).

Já que o Brasil é detentor de um território de proporções continentais, os dados são limitados devido às restrições que o sistema brasileiro de levantamento de dados utiliza, apresentando informações tendenciosas ou ausentes. Também é indispensável destacar que a maioria das infecções pelo vírus da dengue não acarreta em sintomas clínicos. Consequentemente, não são todos os infectados que procuram assistência médica e que o exordial sistema de coleta e armazenamento de informações epidemiológicas no país coopera para que o número notificado dos casos seja menor que os valores dos dados reais (Lucena et al., 2011). Esses fatores podem tornar instável a predição de risco, pois o presente modelo se baseia em informações de amplo nível. Ainda assim, o *software* MaxEnt nos assegura um desempenho preditivo melhor que qualquer outro método de análise de risco (Khatchikian et al., 2011; Cardoso-Leite et al., 2014). Portanto, com a modelagem de risco através de algoritmos de *machine-learning*, é possível gerar modelos estatísticos altamente confiáveis e juntamente com *softwares* de SIG, há a possibilidade de visualizar novos padrões de dispersão entomopediognóstica, criando modelos de predição de risco para a infestação do vetor (Eisen & Lozano-Fuentes, 2009; Eisen & Eisen, 2011; Colón-González et al., 2013; Cardoso-Leite et al., 2014).

Concomitantemente, levando em consideração os mapas de predição de risco baseados nos LIRAA com IIP ≥ 4 dos anos de 2011 a 2015, houve uma flutuação da taxa de incidência da infestação com leve acréscimo no último ano. Estudos recentes mostram que a mudança climática influencia significativamente os índices de incidência da dengue com uma relação não linear (Cardoso-Leite et al., 2014), como está claro nos cinco mapas preditivos dos anos analisados. Assim como o clima influencia na distribuição do vetor, a mudança sazonal de temperatura e pluviosidade pode contribuir para o aumento do índice de dengue, zika e chikungunya, além de influenciar a efetividade ou falha em futuros esforços no controle do mosquito e consequentemente a erradicação das doenças transmitidas (Colón-González et al., 2013). Portanto, estes resultados podem sugerir que os esforços de controle por parte de órgãos governamentais podem ser mais bem aplicados, considerando modelos de predição de risco que considerem variáveis ambientais e climáticas para a tomada de decisão. Isto porque o modo como esses recursos são utilizados desconsideram fatores climáticos que flutuam entre estações e anos consecutivos.

Na mesma linha de raciocínio, em vários países tropicais, o El Niño pode ter sido a causa de epidemia da dengue, pois a interação atmosférica/oceânica que causa um desequilíbrio no clima na época do verão no hemisfério sul, engendra anomalias intensas na temperatura ocorrendo variações sazonais na chuva. Estas variações permitem condições favoráveis para o aumento na disponibilidade dos criadouros e a consequente reprodução do mosquito vetor (Aiken et al., 1980; Gagnon et al., 2011). Nesse contexto, o clima é uma variável que desempenha um papel determinante para distribuição, dispersão e reprodução dos vetores, o que afeta diretamente seus processos físicos, químicos e biológicos e a dispersão de doenças zoonóticas (Estrada-Peña et al., 2014). Portanto, locais onde as taxas pluviométricas são altas podem ter um aumento no número de criadouros naturais de mosquitos (Dallacort et al., 2015).

Os resultados aqui apresentados sugerem um acréscimo da taxa de incidência no ano de 2015, o que pode estar relacionado com o crescimento populacional sem um planejamento estrutural adequado das cidades amostradas (Gubler, 2011). Assim como o aumento de viagens e transporte de mercadorias ao longo do país também contribui para que as taxas de incidência continuem elevadas (Bogoch et al., 2016). Além de poucas cidades crescerem estruturalmente a partir de um modelo arquitetônico previamente estudado, o aumento de acessibilidade, através da pavimentação de mais rodovias, para o livre comércio interno de mercadorias colabora, junto com os fatores

anteriores, para o aumento das taxas de infestação (Al-Muhandis & Hunter, 2011; Valadares et al., 2013). Outro fator que tem contribuído para que a taxa de infestação não diminuisse é a falta de cuidado da população frente todas as medidas educativas e informes sobre como eliminar a proliferação do *Aedes*. E como não há antiviral atualmente para a população, como tratamento com medicamentos específicos e vacinas preventivas, a única maneira de prevenir a doença é através do controle populacional do vetor (Al-Muhandis & Hunter, 2011).

Também é imprescindível o empenho dos governantes em incentivar e investir recursos no combate à infestação do mosquito, pois tal medida torna-se inquestionável perante os surtos de infestação que o Brasil tem sofrido. Concomitantemente em algumas regiões, as perdas econômicas causadas pela dengue são similares a aquelas atribuídas a malária e a tuberculose (Torres & Castro, 2007; Eisen & Lozano-Fuentes, 2009). Sendo assim, muito tem se investido em ações de vigilância e controle. O Governo Federal faz o repasse para os estados e municípios, entretanto, cada gestão decide como serão gastos tais recursos, de modo que não há um controle rígido ou padronização das ações de controle do vetor. Nesse contexto, uma vez que os resultados não mostraram correlação entre o investimento e os índices de infestação por *Ae. aegypti* em nenhum dos anos amostrados, o alto investimento feito para o controle foi realizado desconsiderando-se a biologia, ecologia e distribuição do vetor (e.g. Hartemink et al., 2015).

De fato, os resultados sugerem que fatores ambientais como a altitude e a temperatura podem predizer a ocorrência do vetor. O ciclo de vida do *Ae. aegypti* é diretamente influenciado pela temperatura ambiente e pelas chuvas, assim como sua distribuição global (Brady et al., 2014). Além disso, as taxas de replicação da maioria dos vírus transmitidos por vetores são dependentes da temperatura, sendo altas em locais mais quentes e praticamente nulas em baixas temperaturas (Carpenter et al., 2011). Portanto, o aumento da temperatura pode aumentar os riscos de transmissão devido ao aceleração do desenvolvimento do vetor e redução do período de incubação do vírus (Brady et al. 2014). O vetor exibe uma sobrevivência e distribuição limitadas a isotermas maiores do que 10°C (Halstead, 2008), e habita principalmente uma faixa ótima tanto para o desenvolvimento das larvas, de 21 a 29°C, quanto para fecundidade dos adultos, 22 a 30°C (Fernandes et al., 2006). Além dos fatores climáticos e ambientais, os resultados sugerem que há maior potencial de risco em áreas litorâneas e grandes centros urbanos, onde há maior população humana. De fato, tanto o

vetor quanto a doença são obviamente dependentes da presença humana para sua distribuição (Gubler, 2011).

Mais de cinco bilhões de Reais foram gastos em vigilância e no controle do vetor, custeando compra de equipamentos e inseticidas (90% dos recursos), manutenção e capacitação de pessoal e ações de comunicação social (Braga & Valle, 2007). A cada ano o montante de recurso tem crescido, porém não houve visualização de decréscimo significativo da infestação. Mesmo que o combate do mosquito vetor tenha sido institucionalizado no país depois da metade do século XX, seria de se esperar que o resultado fosse inverso, porém o aumento da taxa de infestação do último ano comparado com o primeiro (2011-2015) mostram que os esforços não alcançaram o êxito esperado (e.g. Braga & Valle, 2007). Portanto, mesmo com o aumento de recursos públicos para custear as campanhas de monitoramento e controle do vetor, estas ações tem baixo potencial de erradicação. Entretanto, não se pode descartar que os índices e surtos epidemiológicos poderiam ser piores se não houvesse tal investimento.

Em conclusão, a análise de risco epidemiológico e de eficiência dos investimentos governamentais sugere que os principais fatores responsáveis pela distribuição do vetor *Ae. aegypti* são potencialmente a altitude e a temperatura, além de fatores socioeconômicos. Os resultados aqui apresentados podem fornecer subsídios em escala nacional para revelar tendências espaço-temporais que se repetem em surtos sucessivos. Desse modo, é oferecido uma alternativa para que o PNCD explore a implementação de planos de alocação de recursos que considerem metodologias de predição de risco que agem em locais pré-sugeridos para ações intensas de erradicação (Eisen & Lozano-Fuentes, 2009; WHO, 2009). Nessas condições, o país pode caminhar para um controle com melhor planejamento para fins de erradicação do vetor, da dengue, chikungunya e zika.

REFERÊNCIAS

- Aiken, S. R., Frost, D. B., & Leigh, C. H. (1980) Dengue haemorrhagic fever and rainfall in Peninsular Malaysia: some suggested relationships. *Social Science & Medicine*, 14D, 307–316.
- Al-Muhandis N. & Hunter P. R. (2011) The Value of Educational Messages Embedded in a Community-Based Approach to Combat Dengue Fever: A Systematic Review and Meta Regression Analysis. *PLoS Neglected Tropical Diseases*, 5, e1278.
- Araújo, M. B., Pearson, R. G., Thuiller, W., & Erhard, M. (2005). Validation of species-climate impact models under climate change. *Global Change Biology*, 11(9), 1504-1513.
- Barth, N. B. (2014). *Levantamento rápido de infestação do Aedes aegypti*. Dissertação de mestrado em gestão ambiental de municípios. Curitiba: UTFPR.
- Becker N., Pluskota B., Kaiser A., & Schaffner F. (2012). Exotic mosquitoes conquer the world. In: Mehlhorn H (ed) (2012) Arthropods as Vectors of Emerging diseases. *Parasitology Research Monographs*, 3, 31–60.
- Benelli, G., & Mehlhorn, H. (2016). Declining malaria, rising of dengue and Zika virus: insights for mosquito vector control. *Parasitology Research*, 115(5), 1747-1754.
- Bhatt, S., Gething, P. W., Brady, O. J., Messina, J. P., Farlow, A. W., Moyes, C. L., Drake, J. M., Brownstaein, J. S., Hoen, A. G., Sankoh, O., Myers, M. F., George, D. B., Jaenisch, T., William Wint, G. R., Simmons C. P., Scott, T. W., Ferrar, J. J. & Hay, S. I. (2013). The global distribution and burden of dengue. *Nature*, 496(7446), 504-507.
- Bogoch, I. I., Brady, O. J., Kraemer, M. U., German, M., Creatore, M. I., Kulkarni, M. A. & Watts, A. (2016). Anticipating the international spread of Zika virus from Brazil. *Lancet (London, England)*, 387(10016), 335-336.

- Booth, T. H., Nix, H. A., Busby, J. R., & Hutchinson, M. F. (2014). BIOCLIM: the first species distribution modelling package, its early applications and relevance to most current MAXENT studies. *Diversity and Distributions*, 20(1), 1-9.
- Boyer, S., Foray, C., & Dehecq, J. S. (2014). Spatial and temporal heterogeneities of *Aedes albopictus* density in La Reunion Island: rise and weakness of entomological indices. *PLoS One*, 9(3), e91170.
- Brady, O. J., Golding, N., Pigott, D. M., Kraemer, M. U., Messina, J. P., Reiner, R. C. Jr, Scott, T. W., Smith, D. L., Gething, P. W., & Hay, S. I. (2014). Global temperature constraints on *Aedes aegypti* and *Ae. albopictus* persistence and competence for dengue virus transmission. *Parasites & Vectors*, 7, 338.
- Braga, I. A., & Valle, D. (2007). *Aedes aegypti*: histórico do controle no Brasil. *Epidemiologia e Serviços de Saúde*, 16(2), 113-118.
- Brasil. Ministério da Saúde. (2011). Rede dengue: inovação da abordagem e da gestão em pesquisa à saúde. *Revista de Saúde Pública*, 44(6), 1159-63.
- Camara, T. N., Urbinatti, P. R., Chiaravalloti Neto, F. (2016). Encontro de *Aedes aegypti* em criadouro natural de área urbana, São Paulo, SP, Brasil *Revista de Saúde Pública*, 50(1), 1-4.
- Cardoso-Leite, R., Vilarinho, A. C., Novaes, M. C., Tonetto, A. F., Vilardi, G. C., & Guillermo-Ferreira, R. (2014). Recent and future environmental suitability to dengue fever in Brazil using species distribution model. *Transactions of the Royal Society of Tropical Medicine and Hygiene*, 108(2), 99-104.
- Carpenter, S., Wilson, A., Barber, J., Veronesi, E., Mellor, P., Venter, G. & Gubbins, S. (2011). Temperature dependence of the extrinsic incubation period for viruses in culicoides biting midges. *PLoS ONE* 6, e27987.
- Colón-González, F. J., Fezzi, C., Lake, I. R., & Hunter, P. R. (2013). The effects of weather and climate change on dengue. *PLoS Neglected Tropical Disease*, 7(11), e2503.

Dallacort, R., da Silva Neves, S. M. A., & Nunes, M. C. M. (2015). Variabilidade da Temperatura e das Chuvas de Cáceres/Pantanal Mato-Grossense-Brasil. *Geografia (Londrina)*, 23(1), 21-33.

de Paula Freitas, B., de Oliveira Dias, J. R., Prazeres, J., Sacramento, G. A., Ko, A. I., Maia, M., & Belfort, R. (2016). Ocular findings in infants with microcephaly associated with presumed Zika virus congenital infection in Salvador, Brazil. *JAMA ophthalmology*, 134(5), 529-535.

Donalísio, M. R. & Glasser, C. M. (2002). Entomological surveillance and control of dengue fever vectors. *Revista Brasileira de Epidemiologia*, 5(3), 259-279.

Eisen, L. & Eisen, R. J. (2011) Using geographic information systems and decision support systems for the prediction, prevention, and control of vector-borne diseases. *Annual Review of Entomology*, 56, 41-61.

Eisen, L. & Lozano-Fuentes, S. (2009). Use of mapping and spatial and space-time modeling approaches in operational control of *Aedes aegypti* and dengue. *PLoS Neglected Tropical Diseases*, 3(4), e411.

Elith, J., C. H. Graham, R. P. Anderson, M. Dudík, S. Ferrier, A. Guisan, R. J. Hijmans, F. Huettmann, J. R. Leathwick, A. & Zimmermann, N. E. (2006.) Novel methods improve prediction of species' distributions from occurrence data. *Ecography* 29: 129–151.

Elith, J., Phillips, S. J., Hastie, T., Dudík, M., Chee, Y. E., & Yates, C. J. (2011). A statistical explanation of MaxEnt for ecologists. *Diversity and distributions*, 17(1), 43-57.

Espinosa, M., Weinberg, D., Rotela, C. H., Polop, F., Abril, M., & Scavuzzo, C. M. (2016). 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*, 10(5), e0004621.

Estrada-Peña, A., Ostfeld, R. S., Peterson, A. T., Poulin, R., & de la Fuente, J. (2014). Effects of environmental change on zoonotic disease risk: an ecological primer. *Trends in Parasitology*, 30(4), 205-214.

- Fernandes, C., Beserra, E. B., Castro Jr, F. P., Santos, J. W., & Santos, T. S. (2006). Biologia e exigências térmicas de *Aedes aegypti* (Diptera: Culicidae) provenientes de quatro regiões bioclimáticas da Paraíba. *Neotropical Entomology*, 35, 853-860.
- Figueiredo, R. M. P. D., Mourão, M. P. G., Abi-Abib, Y. E. C., Oliveira, C. M. D., Roque, R., Azara, T. D., Ohly, J., Degener, C., Geier, M. & Eiras, Á. E. (2013). Identification of dengue viruses in naturally infected *Aedes aegypti* females captured with Bio Gents (BG)-Sentinel traps in Manaus, Amazonas, Brazil. *Revista da Sociedade Brasileira de Medicina Tropical*, 46(2), 221-222.
- Gagnon, A. S., Bush, A. B., & Smoyer-Tomic, K. E. (2001). Dengue epidemics and the El Niño southern oscillation. *Climate Research*, 19(1), 35-43.
- Glasser, C. M., Arduino, M. D. B., Barbosa, G. L., Ciaravolo, R. M. D. C., Domingos, M. D. F., Oliveira, C. D., Pereira, M., Silva, M. & Trevisan, A. M. Y. (2011). Comportamento de formas imaturas de *Aedes aegypti*, no litoral do Estado de São Paulo. *Revista da Sociedade Brasileira de Medicina Tropical*, 44(3), 349-55.
- Gubler, D. J. (2011). Dengue, urbanization and globalization: the unholy trinity of the 21st century. *Tropical medicine and health*, 39, S3-S11.
- Halstead, S. B. (2008) *Dengue*. London: Imperial College Press.
- Halstead, S. B. (2015). Reappearance of chikungunya, formerly called dengue, in the Americas. *Emerging Infectious Disease Journal*, 21(4), 557-61.
- Hartemink, N., Vanwambeke, S. O., Purse, B. V., Gilbert, M., & Van Dyck, H. (2015). Towards a resource-based habitat approach for spatial modelling of vector-borne disease risks. *Biological Reviews*, 90(4), 1151-1162.
- Heukelbach, J., Alencar, C. H., Kelvin, A. A., de Oliveira, W. K., & de Góes-Cavalcanti, L. P. (2016). Zika virus outbreak in Brazil. *The Journal of Infection in Developing Countries*, 10(02), 116-120.
- Jupp, P.G., & McIntosh, B.M. (1988) Chikungunya vírus disease. In: Monath TP, ed. *The arboviruses: epidemiology and ecology*, Boca Raton, FL: CRC Press, 2:137-57.

Khatchikian, C., Sangermano, F., Kendell, D., & Livdahl, T. (2011). Evaluation of species distribution model algorithms for fine-scale container-breeding mosquito risk prediction. *Medical and Veterinary Entomology*, 25(3), 268-275.

Koch, L. K., Cunze, S., Werblow, A., Kochmann, J., Dörge, D. D., Mehlhorn, H., & Klimpel, S. (2016). Modeling the habitat suitability for the arbovirus vector *Aedes albopictus* (Diptera: Culicidae) in Germany. *Parasitology Research*, 115(3), 957-964.

Larson, S. R., Degroot, J. P., Bartholomay, L. C., & Sugumaran, R. (2010). Ecological niche modeling of potential West Nile virus vector mosquito species in Iowa. *Journal of Insect Science*, 10(1), 110.

Lima, E. P., Paiva, M. H. S., de Araújo, A. P., da Silva, É. V. G., da Silva, U. M., de Oliveira, L. N., Santana, A. E. G., Barbosa, C. N., Paiva Neto, C. C., Goulart, M. O. F., Wilding, C. S., Ayres, C. F. J. & de Melo Santos, M. A. V. (2011). Insecticideresistance in *Aedes aegypti* populations from Ceará, Brazil. *Parasites & Vectors*, 4(1), 5.

Lima-Camara, T. N., Bruno, R. V., Luz, P. M., Castro, M. G., Lourenço-de-Oliveira, R., Sorgine, M. H., & Peixoto, A. A. (2011). Dengue infection increases the locomotor activity of *Aedes aegypti* females. *PLoS One*, 6(3), e17690.

Louis, V. R., Phalkey, R., Horstick, O., Ratanawong, P., Wilder-Smith, A., Tozan, Y., & Dambach, P. (2014). Modeling tools for dengue risk mapping-a systematic review. *International Journal of Health Geographics*, 13(1), 50.

Lucena, L. T. D., Aguiar, L. O., Bogoevich, A. C. A., Azevedo, F. S. D., Santos, A. C. P. D., Vale, D. B. A. P. D., Pereira, D. B., & Villalobos-Salcedo, J. M. (2011). Dengue na Amazônia: aspectos epidemiológicos no Estado de Rondônia, Brasil, de 1999 a 2010. *Revista Pan-Amazônica de Saúde*, 2(3), 19-25.

Melaun, C., Werblow, A., Cunze, S., Zotzmann, S., Koch, L. K., Mehlhorn, H., Dörge, D. D., Huber, K., Tackenberg, O. & Klimpel, S. (2015). Modeling of the putative distribution of the arbovirus vector *Ochlerotatus japonicus japonicus* (Diptera: Culicidae) in Germany. *Parasitology research*, 114(3), 1051-1061.

Nunes, L.S., Trindade, R. B. R. & Souto, R. N. P. (2011). Avaliação da atratividade de ovitrampas a *Aedes (Stegomyia) aegypti*Linneus (Diptera: Culicidae) no bairro Hospitalidade, Santana, Amapá. *Biota Amazônica*, 1(1), 26-31.

Ochieng, A. O., Nanyangi, M., Kipruto, E., Ondiba, I. M., Amimo, F. A., Oludhe, C., Olago, O., Nyamongo, I. K., & Estambale, B. B. (2016). Ecological niche modelling of Rift Valley fever virus vectors in Baringo, Kenya. *Infection Ecology & Epidemiology*, 6.

PAHO/WHO. Pan American Health Organization/World Health Organization. (2016). *Zika Epidemiological Update*: 14 April 2016. Washington, D.C.: PAHO/WHO; 2016b. Disponível em: http://www.paho.org/hq/index.php?option=com_docman&task=doc_view&Itemid=270&gid=34183&lang=en. Acesso em: Nov 2016.

Passos, S. A., Mustafá, L. M., Casta Pinto, R., Albuquerque, B. C. (2012). Monitoring indexes entomological surveillance and control indicators to dengue vector *Aedes aegypti*in Brazil Manaus-AM, real-time system using the nokia data gathering (NDG). *Anais de Memorias y Convención Internacional de Salud Pública*. Cuba, Havana.

Pearson, R.G., Raxworthy, C.J., Nakamura, M., Peterson, A.T. (2007). Predicting species distributions from a small number of occurrence records: a test case using cryptic geckos in Madagascar. *Journal of Biogeography*, 34, 102–117.

Pereira, C. F., Ferreira, T.G., Borges, J. L. (2013). Política de saúde e controle da dengue em Uberaba-MG. *Revista da Univar*, 9(1), 90-95.

Pessanha, J. E. M., Caiaffa, W. T., Cecilio, A. B., Iani, F. C. D. M., Araujo, S. C., Nascimento, J. C., Kroon, E. G., Projetti, F. A. & Arias, J. R. (2011). Cocirculation of two dengue virus serotypes in individual and pooled samples of *Aedes aegypti* and *Aedes albopictus* larvae. *Revista da Sociedade Brasileira de Medicina Tropical*, 44(1), 103-105.

Philips, Z., Bojke, L., Sculpher, M., Claxton, K., & Golder, S. (2006). Good practice guidelines for decision-analytic modelling in health technology assessment. *Pharmaco Economics*, 24(4), 355-371.

- Phillips, S. J., Anderson, R. P., & Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological modelling*, 190(3), 231-259.
- Powers, A. M., & Logue, C.H. (2007) Changing patterns of chikungunya virus: reemergence of a zoonotic arbovirus. *Journal of General Virology*, 88, 2363–77.
- Prophiro, J. S., Silva, O. S., Luna, J. E. D., Piccoli, C. F., Kanis, L. A., & Silva, M. A. N. D. (2011). *Aedes aegypti* and *Aedes albopictus* (Diptera: Culicidae): coexistence and susceptibility to temephos, in municipalities with occurrence of dengue and differentiated characteristics of urbanization. *Revista da Sociedade Brasileira de Medicina Tropical*, 44(3), 300-305.
- Rogers, D. J. (2006). Models for vectors and vector-borne diseases. *Advances in parasitology*, 62, 1-35.
- Rotela, C., Fouque, F., Lamfri, M., Sabatier, P., Introini, V., Zaidenberg, M., & Scavuzzo, C. (2007). Space–time analysis of the dengue spreading dynamics in the 2004 Tartagal outbreak, Northern Argentina. *Acta Tropica*, 103(1), 1-13.
- Shope, R. (1991). Global climate change and infectious diseases. *Environmental health perspectives*, 96, 171.
- Sofizadeh, A., Rassi, Y., Vatandoost, H., Hanafi-Bojd, A. A., Mollalo, A., Rafizadeh, S., & Akhavan, A. A. (2016). Predicting the Distribution of Phlebotomus papatasii (Diptera: Psychodidae), the Primary Vector of Zoonotic Cutaneous Leishmaniasis, in Golestan Province of Iran Using Ecological Niche Modeling: Comparison of MaxEnt and GARP Models. *Journal of Medical Entomology*, tzw178.
- Staples J. E., Breiman R. F., Powers A. M. (2009). Chikungunya fever: an epidemiological review of a re-emerging infectious disease. *Clinical Infectious Diseases*, 49(6), 942-8.
- Torres J. R., Castro J. (2007). The health and economic impact of dengue in Latin America. *Caderno de Saúde Pública*, 23, 23–31.

- Valadares, A. F., Rodrigues Filho, C., & Peluzio, J. M. (2013). Impacto da dengue em duas principais cidades do Estado do Tocantins: infestação e fator ambiental (2000 a 2010). *Epidemiologia e Serviços de Saúde*, 22(1), 59-66.
- Vasilakis, N., & Weaver, S. C. (2008). The history and evolution of human dengue emergence. *Advances in Virusresearch*, 72, 1-76.
- WHO. *World Health Organization*. (2009). Dengue: guidelines for diagnosis, treatment, prevention and control. Disponível em: <http://www.who.int/tdr/publications/documents/dengue-diagnosis.pdf?ua=1>. Acessoem: Nov de 2016.
- Zanluca, C., Melo, V. C. A. D., Mosimann, A. L. P., Santos, G. I. V. D., Santos, C. N. D. D., & Luz, K. (2015). First report of autochthonous transmission of Zika virus in Brazil. *Memórias do Instituto Oswaldo Cruz*, 110(4), 569-572.
- Zara, A. L. D. S. A., Santos, S. M. D., Fernandes-Oliveira, E. S., Carvalho, R. G., & Coelho, G. E. (2016). Estratégias de controle do *Aedes aegypti*: uma revisão. *Epidemiologia e Serviços de Saúde*, 25(2), 391-404.

APÊNDICES

Apêndice 1. Tabela das informações sobre localidade (latitude e longitude) e LIRAA dos anos de 2011 a 2015 dos respectivos municípios (valores não informados pelos municípios estão representados com “*”).

Município	Localidade	UF	2011	2012	2013	2014	2015
Acrelândia	-66.8865,-9.8254	AC	3	6,7	1,7	6,2	4,2
Brasiléia	-68.7426,-11.0069	AC	5,7	7,7	7,6	12,2	10,1
Bujari	-67.9475,-9.8227	AC	1,3	1,3	0,9	0,5	1,5
Xapuri	-68.4946,-10.6360	AC	2	2,1	1,1	2,8	2
Apuí	-7.196944, -59.890833	AM	0	0	0,2	0	0
Boca do Acre	-8.751944, -67.397778	AM	0,6	0,5	2,3	2,4	1
Coari	-4.085, -63.140833	AM	*	0,7	1,1	2,2	2
Codajás	-3.836944, -62.056944	AM	1,4	0,9	0,5	18	0,8
Humaitá	-7.506111, -63.020833	AM	1,2	0,9	1,6	4	*
Iranduba	-3.285, -60.185833	AM	0	0,1	0,2	0,8	*
Labrea	-64.7993,-7.2600	AM	1,1	1,4	1,1	4,3	6,1
Manacapuru	-3.299722, -60.620556	AM	1,5	0,8	1,2	3,1	4
Manaus	-60.0264,-3.1064	AM	1,3	1,9	1,2	3,9	4
Nhamundá	-2.185833, -56.712778	AM	0	0	0	0,3	0,3
Nova Olinda do Norte	-59.0945,-3.8884	AM	1,7	2,9	1,4	2,2	8
Novo Airão	-60.9435,-2.6259	AM	1,7	1	0,9	1,9	4,8
Parintins	-2.627778, -56.735833	AM	0	0,2	0,1	0,8	1,1
Rio Preto da Eva	-2.698889, -59.7	AM	0	0	0	0	0
São Gabriel da Cachoeira	0.13, -67.088889	AM	*	0,2	1,6	2,9	3,6
Tapauá	-5.627778, -63.182778	AM	0	0	0,7	4,4	1,1
Tefé	-64.7236,-3.3207	AM	1	3,7	2,7	3,5	2,8
Itaituba	-55.9897,-4.2691	PA	2,3	2,9	2,5	3,5	*
Parauapebas	-49.9043,-6.0707	PA	5,2	2,2	3,5	6,8	3,8
Salinópolis	-0.628889, -47.355833	PA	2,1	0,9	0,5	2,2	0,8
Salvaterra	-0.752778, -48.516944	PA	*	0,4	1,1	0,4	0,8
Soure	-48.5075,-0.6674	PA	1,3	1	0,3	1,5	1,7
Ariquemes	-9.916111, -63.040833	RO	0,9	1,1	2	4	3
Buritis	-10.211944, -63.828889	RO	7,4	2	3,4	7,2	16
Cacoal	-11.438611, -61.447222	RO	0,9	0,1	2,2	1,9	7
Espigão D'Oeste	-61.0116,-11.5257	RO	4	6,3	9,1	7,9	9
Guajará-Mirim	-10.782778, -65.339444	RO	1,3	1,7	1,6	16,8	5
Ji-Paraná	-10.885278, -61.951667	RO	2,5	1,8	2,5	2,8	7
Ouro Preto do Oeste	-62.2550,-10.7117	RO	11,3	4,5	3,8	4,2	4
Porto Velho	-63.9020,-8.7618	RO	5,5	5,1	4,3	4,8	3
Boa Vista	-60.6714,2.8195	RR	2,6	1,4	2,4	1,8	*

Pacaraima	-61.1408,4.4170	RR	6,6	3	1,3	2,5	0,9
Araguaína	-48.2078,-7.1921	TO	1,4	4,5	1,7	8,5	6,9
Palmas	-10.184444,-48.333611	TO	3,2	0,7	1	6,8	2,5
Barra de Santo Antônio	-9.405, -35.506944	AL	1,1	0,5	1,3	1,3	1,7
Barra de São Miguel	-9.84, -35.907778	AL	0	0,3	0,2	0	0,2
Delmiro Gouveia	-37.9968,-9.3864	AL	3,1	1,2	3,1	3,4	2
Maragogi	-9.012222, -35.2225	AL	1,8	0,6	1,2	1,4	0,9
Marechal Deodoro	-9.71, -35.895	AL	0,6	0	0,9	39	0,5
Messias	-35.8336,-9.3781	AL	3,5	2,4	4,1	2,5	1,6
Palmeira dos Índios	-9.406944, -36.627778	AL	5,2	2,5	5,6	3,8	2,1
Paripueira	-9.465, -35.551944	AL	0,7	0,8	0,3	1	0,8
Pilar	-35.9507,-9.5896	AL	0,8	1,1	1,6	1,1	2,3
Rio Largo	-9.494722, -35.853333	AL	1,1	0,8	2	1,7	1,6
Santana do Ipanema	-9.377778, -37.245	AL	2,5	0,6	2,8	6,5	3,6
Satuba	-9.562778, -35.823889	AL	1,1	0,8	1,7	2,5	6,7
Teotônio Vilela	-9.906111, 36.352222	AL	0,5	0,6	1	1	1
União dos Palmares	-36.0212,-9.1715	AL	0,9	1,3	2,3	1,1	2,4
Alagoinhas	-38.4227,-12.1352	BA	1,4	1,6	1,6	2,9	*
Camaçari	-38.3229,-12.6939	BA	2,7	4,2	3,5	5,5	4,5
Feira de Santana	-38.9543,-12.2555	BA	1	1,1	1	1,1	1,5
Ilhéus	-39.0344,-14.7972	BA	7,9	6,7	11,6	9,8	*
Jequié	-40.0812,-13.8510	BA	4,4	2,5	5,6	7,9	6,3
Lauro de Freitas	-38.3275,-12.8938	BA	1,8	1,2	1,8	1,9	2
Porto Seguro	-39.0647,-16.4511	BA	1,3	1,4	0,8	1,8	1,1
Simões Filho	-38.4001,-12.7870	BA	7,6	1,4	1,6	2,8	*
Vitória da Conquista	-14.865833, -40.838889	BA	1	0,7	2,1	3,9	*
Água Branca	-5.89, -42.637778	PI	4,9	0,7	0,2	2	0
Barras	-4.246944, -42.295833	PI	0	0	0	0	0
Campo Maior	-4.827778, -42.168889	PI	0,1	0	0,1	0	0,3
Canto do Buriti	-8.11, -42.943889	PI	2	0,4	0,4	0,9	0,6
Castelo do Piauí	-5.321944, -41.552778	PI	0,9	0,2	1,1	1,2	0,6
Elesbão Veloso	-6.201944, -42.14	PI	1	0,8	0,4	0	*
Esperantina	-3.901944, -42.233889	PI	0	0,2	0	0	0,2
Ilha Grande	-2.857778, -41.820833	PI	0,3	0	0	0	*
José de Freitas	-4.755833, -42.575833	PI	3,1	0	0,6	1,2	0,4
Luís Correia	-2.884000, -41.660115	PI	0,3	0,2	0,2	0,2	0,5
Parnaíba	-2.905, -41.776944	PI	0,6	0,5	0,3	0,7	0,3
São Pedro do Piauí	-5.928889, -42.718889	PI	0,6	0,2	0	3	*
Teresina	-5.088889, -42.801944	PI	0,2	0,2	0,1	0,5	0,8
Bayeux	-34.9321,-7.1250	PB	1,6	2,3	1,2	1,2	2,1
Cabedelo	-6.980833, -34.833889	PB	0,6	0,2	0,8	0,3	0,8
Campina Grande	-7.230556, -35.881111	PB	1,9	0,8	2,2	1,7	4,4
Guarabira	-6.855, -35.49	PB	1,2	0,3	0,7	0,7	0,5
Monteiro	-7.888889, -37.12	PB	7,6	1,8	2,9	7,2	6,1
Santa Rita	-34.9812,-7.1163	PB	1,6	1,2	1,4	1,6	1,3

Sousa	-6.760833, -38.230833	PB	2,9	0,7	3	3,6	4,3
Caicó	-6.457778, -37.097778	RN	2,2	1,6	4,1	9,9	5,8
Ceará-Mirim	-5.633889, -35.425833	RN	3	2,7	3,3	3,9	*
Mossoró	-5.187778, -37.343889	RN	4,6	4,9	4,3	7	6,2
Pau dos Ferros	-6.110833, -38.208889	RN	0,5	4,1	2,8	5,4	*
Caxias	-43.3469, -4.8747	MA	1,4	2,4	2,1	4,3	2,2
Codó	-4.455, -43.885833	MA	0,1	0,3	0,4	1,2	0,3
Imperatriz	-47.4770, -5.5255	MA	1,9	2,3	1,8	3,5	3,1
Itapecuru Mirim	-44.3591, -3.3951	MA	0,5	1	0,8	1,5	1,2
Miranda do Norte	-44.5827, -3.5693	MA	2,9	2,3	2	3,5	0
Paço do Lumiar	-44.1052, -2.5305	MA	0,8	1,4	2,1	2,4	2,1
São José de Ribamar	-44.0626, -2.5632	MA	1,8	2,1	1	1,7	1,1
São Luís	-2.53, -44.302778	MA	1,6	0,9	1,1	1,6	1
Timon	-5.093889, -42.836944	MA	1,4	0,9	1,8	2,8	2,5
Abreu e Lima	-34.9033, -7.9101	PE	1,6	2,1	2,5	2,6	1,7
Afogados da Ingazeira	-37.6317, -7.7423	PE	5,7	1,8	5,3	7,2	2,6
Araripina	-40.4968, -7.5781	PE	5,2	2,2	3,3	6,8	10,7
Belo Jardim	-8.335833, -36.423889	PE	0,9	0,3	1,5	2,6	0,8
Bezerros	-35.7852, -8.2426	PE	3,2	1,7	1,4	3,2	3,4
Cabo de Santo Agostinho	-8.286944, -35.035	PE	1	0,9	1,9	2,1	2,8
Camaragibe	-34.9817, -8.0204	PE	4,1	2,3	5,6	8,8	9,9
Carpina	-7.850833, -35.254722	PE	0,7	0,3	0,8	3,2	1,9
Caruaru	-35.9754, -8.2808	PE	2,1	1,4	2,3	3,8	3,5
Floresta	-38.5638, -8.6124	PE	6,6	2,9	2,1	3,7	4,8
Gravatá	-35.5695, -8.2096	PE	1,3	1,2	2,2	3,3	6
Limoeiro	-35.4398, -7.8723	PE	2	3,1	1,4	2	*
Moreno	-8.118611, -35.092222	PE	0,2	0,7	1,3	1,1	*
Paudalho	-35.1769, -7.8919	PE	0,6	1,5	0,5	1,4	*
Petrolina	-9.392778, -40.507778	PE	0,9	0,2	0,6	1,2	1,8
Santa Cruz do Capibaribe	-36.2317, -7.9422	PE	4,1	2,1	1,9	3,6	2,9
Serra Talhada	-38.2933, -7.9841	PE	3,4	1,8	4	11,8	3,5
Timbaúba	-7.505, -35.317778	PE	1,8	0,8	1,1	4,6	1,8
Toritama	-7.998889, -36.050833	PE	0	0,3	1,2	0,4	1,2
Aquidabã	-37.0199, -10.2828	SE	3,9	2,5	1,8	3,7	4,2
Aracaju	-37.0745, -10.9092	SE	1,5	1,4	1	2,4	1,3
Barra dos Coqueiros	-37.0296, -10.9114	SE	1,5	1,8	1,8	2,4	1,3
Estância	-11.267778, -37.437778	SE	1	0,4	0,7	0,8	0,9
Itabaiana	-10.685, -37.425	SE	3,3	0,9	2,5	2,5	1,6
Itaporanga d'Ajuda	-10.997778, -37.310833	SE	1,7	2,2	0,9	1,8	0,7
Lagarto	-37.6639, -10.9145	SE	2,5	1,3	3,2	4,4	2,8
Laranjeiras	-37.1646, -10.8062	SE	6,1	1,9	2,8	2,1	1,6
Maruim	-37.0765, -10.7351	SE	6,7	3,7	3,8	2,8	2,8
Nossa Senhora do Socorro	-10.855, -37.125833	SE	0,8	0,7	0,6	0,5	0,6
Propriá	-36.8394, -10.2301	SE	2,1	2,1	2,1	1,6	1,5
São Cristóvão	-37.2224, -11.0135	SE	3,6	3,8	2,4	4,1	4,7

Araçatuba	-50.4257,-21.2110	SP	1,6	2,3	2,8	5,1	6,7
Araraquara	-21.793889, -48.175833	SP	0,6	0,3	1,3	3,2	*
Barueri	-46.8768,-23.5113	SP	1,9	1	0,7	3,7	3,8
Birigui	-21.288889, -50.34	SP	0,8	0,6	1,2	2,8	*
Caraguatatuba	-23.62, -45.412778	SP	1,2	0,8	0,4	0,9	2,5
Catanduva	-21.137778, -48.972778	SP	4	1,5	1,1	5,6	*
Fernandópolis	-20.283889, -50.245833	SP	1	0,5	0,8	3,5	*
Franca	-20.538889, -47.400833	SP	0,7	0,3	1	1,2	0,8
Guarujá	-46.2569,-23.9946	SP	1,5	2,9	1,5	4,5	3,1
Jaboticabal	-48.3216,-21.2568	SP	0,4	2,5	1,4	4,7	5,8
Limeira	-22.565, -47.401944	SP	0,1	0,4	0,4	1,7	1,9
Matão	-21.602778, -48.365833	SP	0,6	0,2	1	1,6	1,2
Mirassol	-20.818611, -49.508333	SP	2,2	1,2	1,4	4,4	5,6
Peruíbe	-49.5124,-20.8118	SP	0,1	1,1	1	2,7	*
Pirassununga	-46.9954,-24.3173	SP	1,1	0,4	1,3	1,4	*
Praia Grande	-24.005833, -46.402778	SP	0,5	0,6	0,8	1,8	0,6
Ribeirão Preto	-21.177778, -47.81	SP	1,9	1,6	2,1	4,9	4
Santa Barbara D'Oeste	-50.8334,-20.1429	SP	0,1	0,2	0,3	0,7	2
São Sebastião	-45.4120,-23.7610	SP	0,9	1,3	1,5	3,6	3,7
São Vicente	-23.962778, -46.391944	SP	1,4	0,8	1,3	2,9	4,3
Sumaré	-22.821944, -47.266944	SP	0,5	0,6	1,4	2,2	*
Taubaté	-23.025833, -45.558611	SP	0,6	0,5	0,6	1,6	5,1
Angra dos Reis	-44.3184,-23.0100	RJ	1,1	1,2	1,4	1,7	1,6
Araruama	-22.872778, -42.342778	RJ	1,1	0,7	0,7	1,2	0,8
Armação de Búzios	-41.8813,-22.7481	RJ	1,5	1,8	1,3	1,7	0,7
Barra do Piraí	-43.8268,-22.4705	RJ	1,1	1	0,7	1	3,3
Barra Mansa	-22.543889, -44.170833	RJ	0,2	0,1	0,7	0,9	0,9
Belford Roxo	-43.3989,-22.7640	RJ	0,9	1,5	1,2	0,5	0,5
Cabo Frio	-42.0199,-22.8787	RJ	1,6	1,4	1,3	1,4	0,5
Campos dos Goytacazes	-41.3244,-21.7545	RJ	1,8	1,2	1,2	2,1	2,9
Carapebus	-22.186944, -41.660833	RJ	*	0	0	2,1	1,2
Cardoso Moreira	-21.487778, -41.615833	RJ	0,9	0	0	3,1	1,5
Casemiro de Abreu	-22.480833, -42.203889	RJ	0,3	0,5	0,2	1,1	0,6
Cordeiro	-22.028889, -42.360833	RJ	0,6	0,4	0,2	0,4	0,8
Duque de Caxias	-43.3131,-22.7868	RJ	2,4	2,1	1,7	1,7	1,7
Engenheiro Paulo de Frontin	-22.55, -43.677778	RJ	0	0	0	0	0
Guapimirim	-42.9900,-22.5326	RJ	1,2	1	0,9	1,6	1,1
Itaboraí	-42.8585,-22.7472	RJ	4,4	1,6	2,4	1,9	3
Itaguaí	-43.7772,-22.8665	RJ	2	1,6	2,1	1,9	1,6
Italva	-43.6540,-22.6431	RJ	2,5	0,9	1,6	1,6	2,8
Itaperuna	-21.205, -41.887778	RJ	0,4	0,3	0,6	0,6	0,1
Itatiaia	-22.491389, -44.559167	RJ	0	0,3	0,9	1,9	1,8
Japerí	-22.642778, -43.652778	RJ	1,4	1,1	2,3	2,2	0,8
Macaé	-41.7857,-22.3717	RJ	0,7	1,2	1,8	3,8	2,3
Macuco	21.983889, -42.252778	RJ	0	0	0,7	0,4	0,6

Magé	-22.652778, -43.040833	RJ	0,7	0,7	0,4	1,4	0,6
Mangaratiba	-22.96, -44.040833	RJ	0,6	0,3	0,3	0,2	0,8
Mendes	-22.526944, -43.732778	RJ	*	0	0,2	0,8	*
Mesquita	-43.4294, -22.7824	RJ	1,3	1,7	0,8	1,4	1,2
Miguel Pereira	-22.453889, -43.468889	RJ	*	0	0	0	0,1
Miracema	-42.1965, -21.4126	RJ	2,4	1,1	1,3	0,3	0,3
Natividade	-21.041944, -41.972778	RJ	*	0,6	0,4	2,7	*
Nilópolis	-43.4145, -22.8085	RJ	2,6	1,3	1	1,2	0,9
Niterói	-43.1043, -22.8808	RJ	1,7	1,2	1,2	1,2	1,5
Nova Iguaçu	-43.4516, -22.7598	RJ	2,3	1,7	1,3	2,2	2
Paracambi	-22.610833, -43.708889	RJ	0,5	0,1	0,4	0,4	0,4
Paraíba do Sul	-22.161944, -43.292778	RJ	0,7	0,4	0,1	0,1	0,5
Paty dos Alferes	-22.428889, -43.418889	RJ	0,7	0	0	0,1	*
Petrópolis	-22.505, -43.178889	RJ	0,2	0,2	0,4	0,5	0,9
Pinheiral	-22.512778, -44.000833	RJ	0	0	0	0,1	0,9
Piraí	-22.628889, -43.897778	RJ	0	0	0,2	1,3	1,3
Porciúncula	-20.962778, -42.040833	RJ	0,2	0	0,9	1	0,6
Porto Real	-22.42, -44.29	RJ	0	0	0,2	0,4	0,4
Quatis	-22.406944, -44.257778	RJ	0	0,4	0,4	0,7	0,2
Queimados	-43.5554, -22.7165	RJ	1,8	1,1	1	1	1,5
Quissamã	-22.106944, -41.471944	RJ	2,5	0	0,6	1,2	1,1
Resende	-22.468889, -44.446944	RJ	0,2	0,3	0,6	1,8	2,5
Rio Bonito	-42.6258, -22.7094	RJ	0,9	1,2	1,3	1	1,5
Rio das Flores	-22.167778, -43.585833	RJ	0	0	0,8	0	0
Rio das Ostras	-41.9456, -22.5273	RJ	1,5	1,6	1,2	1,6	1,6
Rio de Janeiro	-43.2096, -22.9035	RJ	2	1,6	1,1	1,3	1,1
Santa Maria Madalena	-21.955, -42.007778	RJ	0	0	0	0	0,6
Santo Antônio de Pádua	-42.1816, -21.5398	RJ	1	1,6	2,6	2,2	3,8
São Fidélis	-21.645833, -41.746944	RJ	5,9	0,9	0,7	0,8	0,6
São Gonçalo	-43.0544, -22.8271	RJ	1,9	1,5	1,2	1,4	1,3
São João da Barra	-21.64, -41.050833	RJ	0,9	*	0,7	1,3	0,6
São Pedro da Aldeia	-22.838889, -42.102778	RJ	1,5	0,4	0,6	0,6	*
Saquarema	-22.92, -42.51	RJ	0,6	0,6	0,2	0,6	0,2
Seropédica	-22.743889, -43.707778	RJ	1,3	0,7	0,3	0,3	0,5
Silva Jardim	-22.650833, -42.391944	RJ	0,3	0,3	0,3	0,5	0,4
Três Rios	-43.2104, -22.1197	RJ	1,3	1,1	0,7	2	1,1
Vassouras	-22.403889, -43.662778	RJ	7	0	0,6	2	0,6
Volta Redonda	-22.523056, -44.104167	RJ	0,5	0,6	0,6	1,1	2,4
Aimorés	-41.0616, -19.4922	MG	2,2	1,3	1,5	1,6	3,2
Alfenas	-21.428889, -45.946944	MG	0,4	0,8	0,9	2,6	0
Araxá	-19.592778, -46.940833	MG	0,5	0	0,1	0,9	0,4
Belo Horizonte	-19.916667, -43.933333	MG	0,7	0,5	0,7	2,1	1,1
Carangola	-20.732778, -42.028889	MG	1	0	0,2	2,5	0,5
Curvelo	-18.755833, -44.430833	MG	0,5	0,9	2,1	6,4	3,5
Frutal	-20.025, -48.940833	MG	0,5	0,2	2	2,9	3,4

Governador Valadares	-41.9493,-18.8499	MG	6	4,8	6	6,7	6,6
Guaxupé	-21.305, -46.712778	MG	1	0,2	0	1,4	1
Ipatinga	-42.5371,-19.4682	MG	3,6	1,9	3,2	2,9	2,6
Ituiutaba	-49.4631,-18.9654	MG	3,6	1,9	3,8	6,6	10,7
Januária	-15.487778, -44.361944	MG	0,5	0,9	0,5	1,9	1,6
Lavras	-21.245, -45	MG	0,5	0,3	0,1	0,8	0,6
Patos de Minas	-18.578889, -46.517778	MG	0,3	0,5	0,6	1,3	1
Teófilo Otoni	-49.4631,-18.9654	MG	1,8	1,8	1,5	2,9	1,6
Uberaba	-47.9325,-19.7502	MG	1,4	1,4	0,7	2,3	2,7
Uberlândia	-48.2622,-18.9113	MG	1,1	1	0	3,3	3,4
Varginha	-21.550833, -45.43	MG	0,4	0,1	0,5	1,3	0
Vazante	-17.986944, -46.907778	MG	1	0	1,4	1,4	0
Bom Jesus do Norte	-21.113889, -41.671944	ES	0,2	0	0	0	0
Cachoeiro do Itapemirim	-20.848889, -41.112778	ES	1,8	0,7	0,3	0,8	1,1
Guarapari	-20.657778, -40.510833	ES	0,7	0,7	1,5	1,8	0,7
Linhares	-19.390833, -40.071944	ES	*	0,9	1,5	2,3	*
Piúma	-20.835, -40.728889	ES	*	0,8	0,4	0,4	*
Serra	-40.3083,-20.1287	ES	1,7	1,1	2,3	2,1	*
Vitória	-40.3018,-20.3154	ES	1,1	1,8	1,4	2,4	2,3
Brasília	-15.793889, -47.882778	DF	1,1	*	*	0,9	0,7
Abadiânia	-16.203889, -48.706944	GO	0,8	0,5	0,5	2	2,7
Catalão	-18.17, -47.941944	GO	0,6	0,5	0,3	2,6	1,5
Cidade Ocidental	-47.9372,-16.1144	GO	0,5	1,1	0,7	2,3	2,4
Formosa	-15.536944, -47.333889	GO	0,9	0,6	1,2	2,5	2,2
Goiânia	-49.2676,-16.6777	GO	1,2	2,1	1,3	2,3	1,4
Luziânia	-47.9275,-16.2511	GO	1	1,3	1,3	2,9	0,9
Padre Bernardo	-15.16, -48.283889	GO	0,4	0,2	1,1	1,5	1
Planaltina	-47.6149-15.4503	GO	1,1	0,2	1,8	4,3	2,3
Senador Canedo	-16.707778, -49.092778	GO	1,1	0,7	2,1	4,2	4
Valparaíso de Goiás	-16.065833, -47.978889	GO	0,5	0,3	0,9	1,5	1,3
Barra do Bugres	-15.072778, -57.180833	MT	*	0,8	6	2	1,1
Cuiabá	-56.0949,-15.5989	MT	4,3	3,1	7,4	8,3	6,6
Poconé	-16.256944, -56.622778	MT	0,7	0,1	3,4	2,5	0,4
Tangará da Serra	-57.5065,-14.6312	MT	*	1,5	1,7	4,1	3,8
Aquidauana	-20.470833, -55.786944	MS	0,4	0,9	1,2	1,4	0,6
Bataguassu	-21.713889, -52.421944	MS	0,2	0,2	1,5	0,7	2,6
Bonito	-21.120833, -56.481944	MS	0,3	0,2	1	1,6	0,8
Campo Grande	-20.442778, -54.645833	MS	1	0,6	1,8	2,1	1,8
Corumbá	-56.1495,-21.4755	MS	1	2,2	1,8	4,6	1,8
Coxim	-18.506944, -54.76	MS	1,9	0,9	2	3,1	3,2
Ivinhema	-53.8176,-22.3139	MS	0	1	1,2	1,3	2,2
Jardim	-21.48, -56.137778	MS	0,3	2,1	2,8	1,2	1,8
Naviraí	-54.1906,-23.0652	MS	1,4	1,7	1,4	2,9	1,9
Nova Alvorada do Sul	-21.465833, -54.383889	MS	1	0,2	0	0	0
Nova Andradina	-22.232778, -53.342778	MS	0,3	0,9	0,7	1,2	*

Paranaíba	-19.676944, -51.190833	MS	0,1	0,3	1,8	3,5	8,7
Ponta Porã	-22.535833, -55.725833	MS	0,4	0,2	1	*	1,8
Rio Verde de Mato Grosso	-18.917778, -54.843889	MS	0,2	0,6	1,4	0,5	0,7
São Gabriel do Oeste	-19.395, -54.565833	MS	0,9	0,6	1,4	1,3	0,7
Sidrolândia	-20.931944, -54.960833	MS	0,5	0,4	1,4	2,3	4
Três Lagoas	-20.751111, -51.678333	MS	1,4	0,9	4,1	3,7	3,5
Altônia	-53.8967,-23.8726	PR	1,1	3,4	0,8	1,8	6,4
Campo Mourão	-52.3838,-24.0460	PR	0,9	1,9	0,2	2,4	6,7
Cianorte	-52.6055,-23.6633	PR	1,7	1,6	0,8	2,1	2,8
Cidade Gaúcha	-52.9453,-23.3832	PR	1,7	1,7	0,5	3,4	3,9
Cruzeiro do Oeste	-23.785, -53.072778	PR	1	0,4	1,1	5,5	6
Curitiba	-25.429722, -49.271944	PR	0	0	0	0	*
Iporã	-24.002778, -53.703889	PR	*	*	2,2	8,6	8,2
Ivaiporã	-24.247778, -51.685	PR	0,9	0,4	0,2	2,1	*
Jacarezinho	-23.160833, -49.968889	PR	*	0	1	6,1	6,2
Medianeira	-54.0858,-25.2846	PR	3,6	1	2,2	6,3	*
Missal	-54.2477,-25.0915	PR	1,2	3,6	1,3	0,8	*
Rondon	-23.410833, -52.760833	PR	2,9	0,9	0,4	1	1,7
Santo Antônio da Platina	-23.295, -50.076944	PR	*	0,2	1,1	1,3	1
São Miguel do Iguaçu	-54.2391,-25.3470	PR	*	8,7	1,2	7,1	*
Umuarama	-23.765833, -53.325	PR	1,4	0,9	0,5	2,3	3,6

Apêndice 2. Tabela das informações sobre localidade (latitude e longitude) e investimento per capita (R\$) dos anos de 2011 a 2014 dos respectivos municípios (valores não informados pelos municípios estão representados com “*”).

Município	Habitantes	UF	2011	2012	2013	2014
Acrelândia	8695	AC	*	17166,39	35168,72	14437,23
Brasiléia			28002,07	30214,50	60171,48	24758,39
Bujari			6543	12326,23	15706,28	26688,48
Xapuri			14314	19814,02	21510,40	50565,89
Apuí	18790	AM	*	56909,07	92192,69	36393,95
Boca do Acre			28261	59358,30	96160,43	37467,08
Coari			83078	102712,34	156671,25	253807,41
Codajás			23206	*	50771,66	21492,13
Humaitá			44227	*	140366,50	225893,73
Iranduba			46703	71702,00	118713,78	192616,31
Labrea			43263		56397,59	91364,07
Manacapuru			85141	105479,25	119617,26	206339,76
Manaus			2057711	2135238,16	2613126,98	5188942,47
Nhamunda			20633	*	*	39175,92
Nova Olinda do Norte			35156	*	*	66387,12
Novo Airão			14723	*	*	61131,02
Parintins			112716	116615,97	130270,87	224717,25
Rio Preto da Eva	31274	AM	*	96618,05	156521,22	62386,96
São Gabriel da Cachoeira			43831	69886,42	72868,02	81751,82
Tapauá			19077	*	45441,15	73614,63
Tefé			62230	79533,90	86394,51	139959,11
Itaituba	97493	PA	*	159317,59	279683,96	11239,49
Parauapebas			153908	147976,15	155193,97	475172,52
Salinópolis			37421	39042,17	39360,37	108610,77
Salvaterra			20183	18380,03	20862,61	59840,03
Soure			23001	23962,24	24790,17	67018,68
Ariquemes	102860	RO	82347,31	88151,20	194768,67	85065,96
Buritis			*	64086,63	120229,20	52639,20
Cacoal			78263	65770,29	66092,55	166592,99
Espigão D'Oeste			28729	30873,45	31124,91	61296,87
Guajará-Mirim			41656	71205,21	73252,51	133949,12
Ji-Paraná			130419	97289,61	102857,40	247993,20
Ouro Preto do Oeste			37928	41193,52	42542,89	78712,20
Porto Velho			428527	600247,75	683195,76	1264354,05
Boa Vista	284313	RR	442306,43	481813,90	966423,35	402238,63
Pacaraima			*	37327,67	54611,64	22782,03
Araguaína	150484	TO	185381,26	237622,15	373983,23	157229,95
Palmas			228332	304620,69	379984,20	635737,07
Barra de Santo Antônio	15909	AL	12055,44	12242,66	30149,46	12645,29

Barra de São Miguel	7574	AL	5879,54	5952,52	16135,20	6751,19
Delmiro Gouveia	48096	AL	37982,47	38295,99	77540,25	32363,34
Maragogi	29280	AL	26128,03	28357,50	56089,68	23569,19
Marechal Deodoro	45977	AL	37471,66	38104,91	94650,08	39732,16
Messias	15682	AL	12182,26	12402,87	34122,99	14334,51
Palmeira dos Índios	70368	AL	56770,10	56921,77	113956,38	47382,97
Paripueira	11347	AL	8837,45	10029,66	25725,17	10836,49
Pilar	35428	AL	27717,10	28406,30	67507,56	28111,32
Rio Largo	68481	AL	64247,11	65278,14	138373,77	57662,96
Santana do Ipanema	48033	AL	36084,67	37321,65	74469,63	31032,37
Satuba	14603	AL	12612,86	12795,97	30843,54	12926,37
Teotônio Vilela	41152	AL	34101,24	34373,04	68091,08	28414,59
União dos Palmares	62358	AL	48961,37	49186,71	98251,85	40907,17
Alagoinhas	155362	BA	92057,08	95437,15	236709,00	100696,20
Camaçari	242970	BA	185300,82	196872,73	421142,69	181789,50
Feira de Santana	622639	BA	395260,28	399395,77	937363,32	400051,74
Ilhéus	184236	BA	146469,69	147713,88	332356,20	132492,52
Jequié	151895	BA	100561,39	101628,18	251413,77	106518,06
Lauro de Freitas	194641	BA	123979,44	132174,10	282219,30	121692,28
Porto Seguro	147444	BA	82094,53	86389,09	217209,27	93063,78
Simões Filho	118047	BA	92162,98	94610,40	200336,40	85776,24
Vitória da Conquista	306866	BA	213025,87	215291,03	521208,57	222411,42
Água Branca	17068	PI	12897,20	13014,01	26147,16	10536,94
Barras	44850	PI	32307,20	32526,18	66748,07	26897,79
Campo Maior	45177	PI	36993,80	37125,63	73487,94	29611,00
Canto do Buriti	20619	PI	11474,60	11578,33	29788,62	12004,93
Castelo do Piauí	18336	PI	11624,20	11624,19	26807,58	10800,81
Elesbão Veloso	14512	PI	9394,60	9408,86	21044,30	8477,37
Esperantina	37767	PI	23618,40	23951,39	56027,52	22577,68
Ilha Grande	9242	PI	5367,80	5526,97	13259,04	5342,80
José de Freitas	37085	PI	29450,60	30197,25	73448,60	29598,29
Luís Correia	28406	PI	19356,00	20480,37	42448,28	17106,80
Parnaíba	145705	PI	116961,40	117789,00	232513,20	93697,80
São Pedro do Piauí	13639	PI	10718,80	10862,83	21480,77	8656,39
Teresina	814230	PI	963231,72	987028,74	1867719,20	752706,38
Bayeux	99716	PB	75796,89	78900,52	180977,40	72390,96
Cabedelo	57944	PB	56230,53	64078,84	108406,80	45385,20
Campina Grande	407754	PB	262637,17	265292,52	526493,22	216001,08
Guarabira	55326	PB	30356,08	30537,68	75568,92	30986,82
Monteiro	30852	PB	19254,97	19406,62	42295,50	17393,94
Santa Rita	120310	PB	137839,59	138820,31	219589,20	95667,12
Sousa	69196	PB	40947,96	41155,18	89716,92	36736,20
Caicó	62709	RN	51876,19	52239,35	105082,85	43801,85
Ceará-Mirim	73370	RN	58517,97	59131,00	113858,24	47424,96
Mossoró	259815	RN	209180,47	225498,78	440950,97	185343,61

Pau dos Ferros	30206	RN	23298,87	23492,01	46609,62	19459,11
Caxias	155129	MA	176948,61	186813,47	301102,38	121459,75
Codó			139732,64	145412,10	346774,02	139364,26
Imperatriz			280035,63	294369,21	650394,78	261619,64
Itapecuru Mirim			66009,68	73229,95	187704,47	76308,35
Miranda do Norte			20250,29	27445,30	72906,87	30000,81
Paço do Lumiar			112392,02	116506,80	298127,04	122555,27
São José de Ribamar			163045	173324,61	205566,74	503259,36
São Luís			1014837	1778289,58	1832385,64	2959877,70
Timon			155460	144153,37	150663,64	225995,46
Abreu e Lima			94429	81430,37	81787,37	157150,94
Afogados da Ingazeira	35088	PE	22832,69	22941,36	58436,39	24010,14
Araripina			77302	53695,31	54037,05	113178,42
Belo Jardim			72432	53501,92	53713,91	120443,40
Bezerros			58668	45595,37	45918,85	97125,59
Cabo de Santo Agostinho			95979	150257,13	163897,20	312216,30
Camaragibe			144466	129747,24	131981,41	242297,52
Carpina			74858	39765,51	44226,34	94816,94
Caruaru			314912	260536,00	278934,05	534756,74
Floresta			22169	17877,25	18853,81	43340,94
Gravatá			76458	52308,84	53654,29	128444,22
Limoeiro			55439	40946,19	40946,18	80025,95
Moreno			56696	44560,68	45851,24	95416,20
Paudalho	51357	PE	31471,85	34328,88	75621,45	32263,09
Petrolina			293962	205199,45	218232,12	503830,80
Santa Cruz do Capibaribe			23467	56217,34	62825,83	151620,12
Serra Talhada			79232	46867,70	47245,68	116387,06
Timbaúba			53825	35292,94	36693,88	77158,55
Toritama			35554	18202,91	20068,92	46624,79
Aquidabã	20056	SE	15657,07	15891,64	31248,03	12934,82
Aracaju			571149	373954,15	398372,15	1029478,20
Barra dos Coqueiros			24976	15779,38	20142,01	39618,00
Estância			64409	46812,77	47727,93	99845,70
Itabaiana			86967	66277,73	67183,48	135457,05
Itaporanga d'Ajuda			30419	22304,93	23407,74	47754,47
Lagarto			94861	70756,30	73259,85	147426,66
Laranjeiras			26902	20712,82	22777,05	42078,02
Maruim			16343	11144,38	11737,99	25416,93
Nossa Senhora do Socorro			160827	130570,27	137053,64	252012,02
Propriá			28451	20165,28	20223,39	43776,50
São Cristóvão			78864	56348,52	59988,84	123420,35
Araçatuba	181579	SP	116802,24	117411,40	180974,12	75189,48
Araraquara			208662	112396,51	118001,60	199647,36
Barueri			240749	137417,59	138840,57	230667,23
Birigui			108728	66634,75	67313,79	104141,66

Caraguatatuba	100840	SP	38138,47	40676,93	97796,84	41195,05
Catanduva	112820	SP	68851,10	69178,20	107520,66	44645,91
Fernandópolis	64696	SP	34550,06	35306,97	53603,70	22226,66
Franca	344704	SP	171181,06	172455,34	303585,26	126477,29
Guarujá	290752	SP	294823,03	296842,92	451229,58	187850,70
Jaboticabal	71662	SP	33029,71	33180,42	52586,10	21830,38
Limeira	276022	SP	162167,33	163384,06	263010,12	109580,54
Matão	82990	SP	41861,04	42072,01	65872,86	27362,40
Mirassol	53792	SP	32139,05	32389,98	50665,74	21116,77
Peruíbe	59773	SP	20960,93	21951,45	54927,00	22973,40
Pirassununga	70081	SP	31997,69	32180,77	51037,16	21271,70
Praia Grande	262051	SP	287087,83	307514,64	438091,85	185257,90
Ribeirão Preto	604682	SP	348560,11	379035,06	581941,47	243973,23
Santa Barbara D'Oeste	180009	SP	116725,13	117219,88	180346,71	74838,48
São Sebastião	73942	SP	30344,76	30976,12	68709,60	28936,44
São Vicente	332445	SP	291794,14	295206,09	447837,08	186397,89
Sumaré	241311	SP	145979,93	147120,14	231225,90	97113,63
Taubaté	278686	SP	88647,74	91212,25	266581,14	111339,48
Angra dos Reis	169511	RJ	148441,19	152582,93	297529,67	121958,59
Araruama	112008	RJ	88810,58	92489,94	195582,24	79943,80
Armação de Búzios	27560	RJ	24158,49	24788,74	48674,63	20018,88
Barra do Piraí	44850	RJ	91034,54	91497,50	160819,67	64687,39
Barra Mansa	177813	RJ	161038,24	162363,69	300518,39	120605,18
Belford Roxo	469332	RJ	439723,69	442230,86	797321,27	320935,77
Cabo Frio	186227	RJ	150577,68	154449,70	327930,95	134655,36
Campos dos Goytacazes	463731	RJ	392512,18	423332,85	793463,97	320683,77
Carapebus	13359	RJ	*	11318,37	23560,31	9682,17
Cardoso Moreira	12600	RJ	*	10201,00	21169,65	8467,87
Casemiro de Abreu	35347	RJ	24749,26	29434,87	62731,19	25866,62
Cordeiro	20430	RJ	16111,46	16653,04	34787,73	14019,93
Duque de Caxias	855048	RJ	794510,16	800187,56	1456672,53	587274,91
Engenheiro Paulo de Frontin	13237	RJ	*	11436,39	22525,41	9075,36
Guapimirim	51483	RJ	40273,00	42518,65	89925,33	36762,43
Itaboraí	218008	RJ	185381,42	187374,62	373998,24	151376,73
Itaguaí	109091	RJ	87288,77	91865,04	190145,73	77644,22
Italva	14063	RJ	12373,92	12471,58	23992,05	9680,16
Itaperuna	95841	RJ	92511,99	93188,64	163327,89	65858,62
Itatiaia	28783	RJ	*	32737,10	50832,21	20574,99
Japerí	95492	RJ	82322,12	83130,75	163526,15	66120,09
Macaé	206728	RJ	163917,38	179110,75	366157,65	150825,02
Macuco	5269	RJ	4554,47	4580,40	8949,35	3601,92
Magé	227322	RJ	214217,39	215772,27	387354,24	156185,56
Mangaratiba	36456	RJ	28522,98	32740,09	64177,67	26349,12
Mendes	17935	RJ	15676,11	15764,65	30280,32	12144,38

Mesquita	168376	RJ	173015,58	173621,83	284822,13	144364,32
Miguel Pereira	24642	RJ	*	22730,20	41586,69	16657,68
Miracema	26843	RJ	*	21730,47	45040,79	18016,32
Natividade	15082	RJ	13507,06	13507,05	25327,65	10131,07
Nilópolis	157425	RJ	139759,37	140012,38	265416,48	106369,53
Niterói	487562	RJ	448402,43	458070,43	826235,75	332102,40
Nova Iguaçu	796257	RJ	758458,13	761115,68	1346933,27	504835,68
Paracambi	47124	RJ	37198,52	39362,70	80856,72	32729,76
Paraíba do Sul	41084	RJ	36541,64	36793,35	69953,51	28193,76
Paty dos Alferes	26359	RJ	*	22672,81	44645,97	17939,71
Petrópolis	295917	RJ	255101,44	255660,05	499282,56	200180,73
Pinheiral	22719	RJ	*	20136,96	38989,44	15783,93
Piraí	26314	RJ	23772,62	24248,72	45272,63	18352,99
Porciúncula	17760	RJ	14931,16	15048,01	30297,09	12222,33
Porto Real	16592	RJ	*	14850,22	29016,93	11869,53
Quatis	12793	RJ	*	12107,76	22016,37	8926,17
Queimados	76	RJ	117515,17	118559,46	235828,29	95258,01
Quissamã	20242	RJ	*	17492,62	35673,12	14653,63
Resende	119769	RJ	118376,06	119531,46	205074,21	82914,72
Rio Bonito	55551	RJ	48265,42	49098,31	94812,48	38265,02
Rio das Flores	8561	RJ	*	7768,70	14621,04	5902,17
Rio das Ostras	105676	RJ	81465,88	93581,79	195105,09	82115,71
Rio de Janeiro	6320446	RJ	5632009,58	5786074,61	10735687,19	4320908,25
Santa Maria Madalena	10321	RJ	*	9446,87	17300,63	6920,25
Santo Antônio de Pádua	40589	RJ	34328,54	34452,02	68671,65	27575,52
São Fidélis	37543	RJ	31779,30	31828,39	63263,73	25345,82
São Gonçalo	999728	RJ	869184,25	883810,90	1707095,01	689140,70
São João da Barra	32747	RJ	*	26824,91	56300,15	22815,07
São Pedro da Aldeia	87875	RJ	71553,92	75662,53	153790,56	62938,84
Saquarema	74234	RJ	56161,03	61448,94	130236,95	53370,91
Seropédica	78186	RJ	69103,77	69981,42	134631,83	54606,72
Silva Jardim	21349	RJ	18743,00	18749,14	35888,15	14357,95
Três Rios	77432	RJ	76397,49	78181,01	131470,05	52901,85
Vassouras	34410	RJ	*	31532,35	58561,41	23595,26
Volta Redonda	257803	RJ	241182,47	242313,52	437102,39	175742,78
Aimorés	24959	MG	17499,70	17594,16	35909,28	14788,80
Alfenas	79222	MG	56243,30	56642,77	107717,76	44707,96
Araxá	103287	MG	63381,02	64657,81	138078,72	57591,39
Belo Horizonte	2375151	MG	3149472,09	3163380,59	5933880,29	2456158,34
Carangola	32296	MG	23687,62	23708,89	46588,32	19214,20
Curvelo	74219	MG	53870,28	54244,08	108020,16	44826,62
Frutal	53468	MG	37267,92	37637,32	78495,84	32670,72
Governador Valadares	260	MG	234594,19	236096,52	431227,80	178568,06

Guaxupé	49430	MG	37836,69	37977,53	71700,48	29657,08
Ipatinga	148687	MG	213578,39	215425,48	394536,42	164007,50
Ituiutaba	103945	MG	77025,15	77847,46	141684,48	58763,52
Januária	68420	MG	45904,55	46004,82	94671,36	39096,00
Lavras	100243	MG	64959,64	65686,03	135688,32	56547,07
Patos de Minas	149856	MG	115031,39	115975,95	228339,00	94877,56
Teófilo Otoni	141502	MG	104714,93	108435,23	219589,38	90763,41
Uberaba	325279	MG	258580,96	261527,68	490249,26	204353,28
Uberlândia	604013	MG	545640,19	552768,58	1003648,32	419044,10
Varginha	133384	MG	108277,07	110390,41	202836,96	84330,07
Vazante	19723	MG	13198,44	13239,92	28575,36	11811,45
Bom Jesus do Norte	9476	ES	7011,23	7026,03	13985,57	5935,86
Cachoeiro do Itapemirim	189889	ES	192249,96	193417,29	293998,68	125590,35
Guarapari	105286	ES	148239,66	151145,34	227426,10	98092,12
Linhares	141306	ES	94324,56	102035,38	214089,30	92794,63
Piúma	18123	ES	29514,93	31490,36	47254,97	20411,34
Serra	409267	ES	455109,51	467863,52	794852,28	351610,06
Vitória	327801	ES	358552,43	370166,10	626677,70	262036,84
Brasília	2914830	DF	*	*	*	*
Abadiânia	15757	GO	10752,05	12930,10	29045,73	12268,31
Catalão	86647	GO	66659,26	72613,54	127968,05	53969,42
Cidade Ocidental	55915	GO	35584,33	38796,29	72186,59	30505,17
Formosa	100085	GO	77618,77	82009,83	153194,43	64350,50
Goiânia	1302001	GO	1544466,86	1588047,69	2390586,23	999113,40
Luziânia	174531	GO	155860,49	158153,77	257177,16	107796,67
Padre Bernardo	27671	GO	*	20515,27	49166,21	20660,03
Planaltina	81649	GO	73225,43	75622,12	128818,86	53497,29
Senador Canedo	84443	GO	*	77483,73	147140,39	62711,88
Valparaíso de Goiás	132982	GO	101565,74	111821,53	173893,61	73545,19
Barra do Bugres	31793	MT	21217,64	21445,20	49969,80	20331,48
Cuiabá	585367	MT	845206,86	854014,13	1355979,99	550606,21
Poconé	31779	MT	20291,90	20341,70	49149,36	19734,87
Tangará da Serra	83431	MT	47509,42	49456,51	134136,83	55567,70
Aquidauana	45614	MS	42007,82	42161,61	76705,52	31274,58
Bataguassu	19839	MS	*	17281,96	30519,75	12658,58
Bonito	19587	MS	23329,55	25855,08	44395,23	18301,90
Campo Grande	863982	MS	966171,77	1018817,46	1744195,92	721028,25
Corumbá	103703	MS	117881,64	123630,72	214229,81	87680,83
Coxim	32159	MS	31406,98	31504,64	55181,81	22477,27
Ivinhema	22341	MS	17236,00	18322,50	32560,16	13247,46
Jardim	24346	MS	19651,52	19904,34	35595,75	14562,75
Naviraí	46424	MS	*	30020,53	57478,79	23916,96
Nova Alvorada do Sul	16432	MS	*	17944,06	31198,82	13263,00

Nova Andradina	45585	MS	36910,37	37545,17	66430,62	27,687,56
Paranaíba	40192	MS	36421,78	36546,82	63941,15	26060,03
Ponta Porã	77872	MS	62320,56	64973,70	116399,01	48,477,96
Rio Verde de Mato Grosso	18948	MS	25944,07	26023,72	44629,52	18177,78
São Gabriel do Oeste	22203	MS	16893,05	17647,57	31306,50	13077,01
Sidrolândia	42132	MS	*	24384,22	53938,80	23052,69
Três Lagoas	101791	MS	74259,49	85912,08	150653,48	62786,41
Altônia	21867	PR	*	7539,43	15534,39	6447,18
Campo Mourão	92300	PR	48008,36	49022,22	75188,34	31247,88
Cianorte	69958	PR	41653,74	43045,45	67081,68	28141,54
Cidade Gaúcha	11062	PR	4587,03	4635,95	8838,90	3693,97
Cruzeiro do Oeste	20416	PR	8158,61	8164,60	15345,96	6336,84
Curitiba	1751907	PR	200000,00	826103,11	1685178,29	701457,02
Iporã	31274	PR	29098,45	29801,50	46342,14	19346,12
Ivaiporã	31816	PR	*	12679,70	23381,70	9623,84
Jacarezinho	40588	PR	16415,28	16415,28	28569,89	11772,15
Medianeira	41817	PR	21684,62	22918,00	35674,56	14851,45
Missal	10474	PR	5843,24	5845,46	9582,90	3954,59
Rondon	8996	PR	*	3870,00	7250,54	3006,17
Santo Antônio da Platina	45562	PR	17178,13	17553,57	31470,77	13063,81
São Miguel do Iguaçu	25769	PR	14896,27	14955,80	23417,06	9709,10
Umuarama	100676	PR	56212,98	57249,69	87950,73	36627,32