

# Emprego de componentes móveis de IoT para análises espacotemporais de alta resolução para avaliar a qualidade do ar em cidades médias brasileiras

Alessandro Santiago dos Santos<sup>1,2</sup>, Luiz Gustavo Faccini<sup>1</sup>, Claudio L. Marte<sup>2</sup>,  
Jorge Pimentel Cintra<sup>2</sup>

<sup>1</sup>Instituto de Pesquisas Tecnológicas do Estado de SP – (IPT)  
Av. Prof. Almeida Prado, 532 – Cidade Universitária Butantã – São Paulo – SP – Brazil

<sup>2</sup>Departamento de Engenharia de Transportes – Escola Politécnica  
Universidade de São Paulo (USP) – São Paulo, SP – Brazil

{alesan,faccini}@ipt.br, {claudio.marte,jpcintra}@usp.br

**Abstract.** *The traditional monitoring of air quality uses fixed stations that promote a low spatial resolution, as well as presenting significant structural asymmetries in the coverage of Brazilian metropolitan regions. The opportunity arises to equip public buses with wireless sensor networks that evaluate the air quality during its journey. New ways of performing spatiotemporal analyzes by cartographic models created with data of mobile sensors, promoting a resolution greater than the traditional monitoring.*

**Resumo.** *O monitoramento tradicional da qualidade do ar utiliza estações fixas, que pelo alto custo e pequena quantidade instalada em centros urbanos, promovem uma baixa resolução espacial, além de deficiências de cobertura de regiões do Brasil. Surge à oportunidade de equipar ônibus coletivos com kits de Internet das Coisas, como parte de uma rede de sensores sem fio de avaliação da qualidade do ar. Este artigo realiza a análise de dados de experimento em cidades brasileiras como validação do modelo e apresentação de novas formas de avaliação do ambiente urbano, com base em resultados de processamento e mineração de dados com alta resolução espacial.*

## 1. Introdução

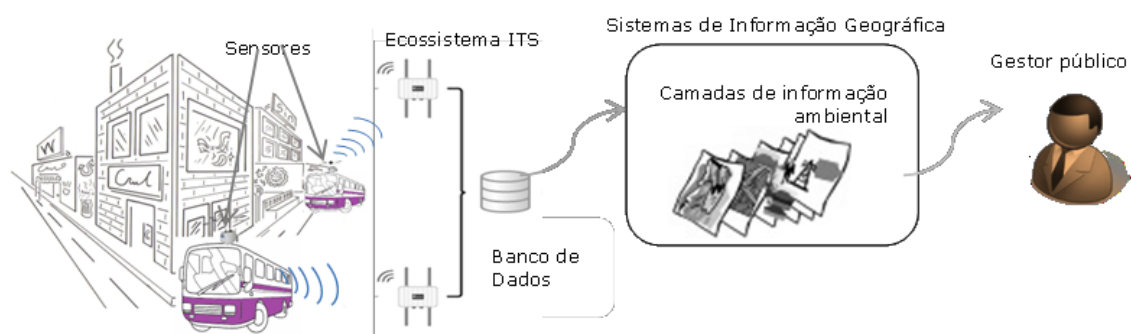
Viver nas regiões urbanas tem se tornado uma realidade cada vez mais presente na realidade mundial, estudos da ONU mostram que, no período de 1950 a 2011, a população mundial urbana passou de 26% para 51% do total, e já há perspectivas de que, em 2050, 70% da população mundial viverá em meio urbano [UNITED NATIONS, 2012]. Considerando o território brasileiro, o censo demográfico de 2010 identificou que 84,4% da população vivem em áreas urbanas [IBGE, 2011]. Esta constatação aponta para a criticidade e os desafios dos gestores públicos, na difícil missão de oferecer uma boa qualidade de vida aos cidadãos.

Um modelo moderno de compreensão das cidades emerge dentro de um conceito de cidades inteligentes e sustentáveis. Sendo clara a importância de se discutir questões relacionadas ao meio ambiente, principalmente nas interferências causadas pelo homem, por exemplo, os impactos sobre a qualidade do ar, gerados pelo crescimento da frota veicular em centros urbanos.

As principais regiões metropolitanas brasileiras possuem monitoramento da qualidade do ar; no entanto, o primeiro diagnóstico das redes nacionais para este fim [IEMA, 2014], sinaliza que partes importantes não contam com monitoramento, e existem assimetrias estruturais significativas, entre as redes de monitoramento. Além disso, as estações de monitoramento geralmente são instaladas em áreas que permitem uma larga cobertura geográfica das medições, esta característica projeta regiões com baixa resolução espacial de dados (escala quilométrica), assim, não permite que características de microrregiões sejam perceptíveis. No entanto, a literatura já aponta que túneis, cruzamentos viários, e cânions urbanos são microrregiões de concentração de poluentes [BARREFORS, 1996] [AHMAD; KHARE; CHAUDHRY, 2005].

Neste sentido, os avanços tecnológicos têm proporcionado novas análises de perspectivas urbanas, com o processamento de grande quantidade de informação, provenientes de componentes de Internet das Coisas. Assim, as cidades podem contar com sensores que coletam dados de forma automatizada, criando uma base de conhecimento urbano. No entanto, para proporcionar uma visão abrangente seria necessário um grande número de sensores fixos de qualidade do ar, além de um acréscimo constante para acompanhar o crescimento de cidades médias. Neste cenário, ao invés de instrumentar a cidade com um grande número de sensores, surge a oportunidade de instrumentação de ônibus coletivos com sensores que medem a poluição do ar durante seu trajeto diário, assim aproveitando as características de mobilidade do transporte público.

Aproveitando dos princípios de mobilidade do transporte público, o presente artigo sugere a utilização de ônibus urbanos como hospedeiros móveis de sensores ambientais, capturando dados por onde trafegam, permitindo cobrir uma vasta região geográfica, com leituras periódicas. Os dados coletados pelos sensores serão enviados para Sistemas Inteligentes de Transporte – ITS, em uma central de monitoramento, onde serão integrados a Sistemas de Informações Geográficas – SIG, conforme a Figura 1.



**Figura 1 - Arquitetura de monitoramento por sensores embarcados em ônibus**

Este artigo apresenta alternativas de monitoramento da qualidade do ar com alta resolução espacial, por meio de uma plataforma tecnológica para a elaboração de mapas temáticos com informações ambientais coletadas de forma distribuída e móvel, permitindo análises com correlações espaçotemporais, suportando a tomada de decisões de gestores públicos, ou como ferramenta informativa para a sociedade.

Este modelo baseia-se na análise de dados proveniente de vários sensores, que possuem um custo menor e facilitam o uso disseminado; mesmo que com acurácia menor, as coletas por vários sensores distribuídos no espaço e no tempo agregam um nível de confiabilidade satisfatório [SANCHEZ et al., 2014].

## 2. Trabalhos relacionados

Aqui avultamos dois tipos de soluções de rede de sensores sem fio (RSSF), aquelas que aplicam sensores fixos e outras que aplicam sensores móveis.

No contexto de sensores fixos destacam-se os projetos: Oulu; CitySense e SmartSantander. O Oulu Smart City [OJALA, 2010] utilizou como base a cidade de Oulu na Finlândia, onde foi criada uma infraestrutura de testes (*Testbed*) de computação ubíqua, com diferentes tipos de redes sem fio, displays públicos e serviços. Outro caso, o CitySense [MURTY et al., 2008], foi realizado em Cambridge, Massachusetts nos Estados Unidos, e envolveu mais de 100 nós. Cada nó era um computador com Linux instalado em um poste de iluminação. O projeto SmartSantander [SANCHEZ et al., 2014] foi projetado para uma escala urbana, com 1500 sensores, propondo a formar uma cidade real como campo experimental para testes de componentes de IoT (*Internet of Things*). Nos três casos, os componentes eram instalados fisicamente em pontos estratégicos da cidade, e tinham o objetivo de criar um ambiente experimental em uma escala maior que o ambiente laboratorial, principalmente para facilitar os experimentos e estudos de novas tecnologias, protocolos de comunicação e estratégias computacionais. Apesar de coletarem dados de poluição, estes não tinham propósito de explorar mapas e cenários sobre o tema de qualidade do ar.

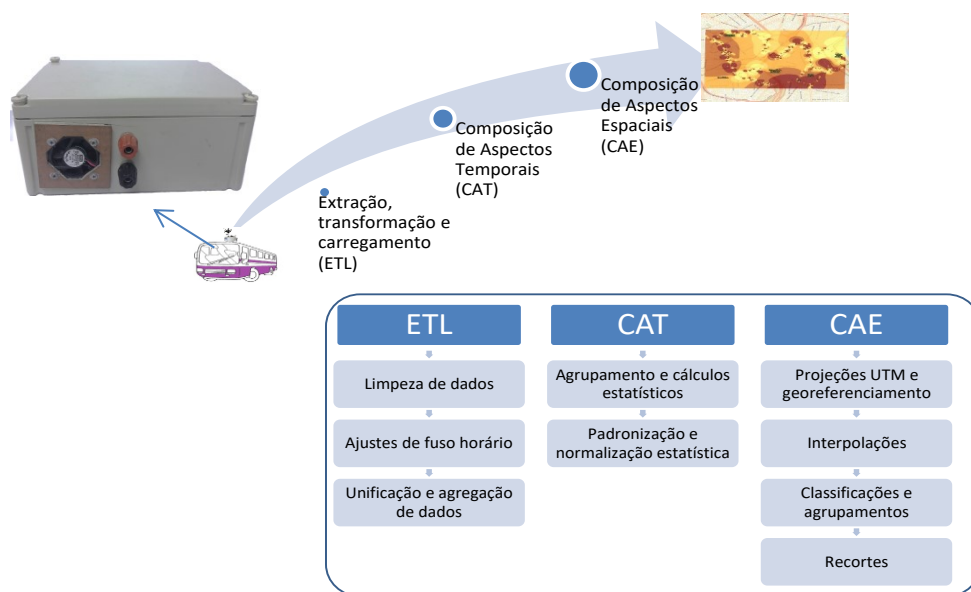
No contexto de sensores móveis hospedados em veículos, destacamos três projetos: Mitos, Ekobus e caso Zurique. Dois subprojetos derivados do SmartSantander, o Mitos [SmartSantander, 2017] e Ekobus [BIELSA, 2012] utilizavam kits IoT hospedados em ônibus para monitoramento da poluição. Estes se restringiam em apresentar dados pontuais dos nós sensores sem as análises espaçotemporais. Já o caso de Zurique [HASENFRATZ, 2015], na Suíça, hospedou sensores no topo de ônibus coletivos para experimentos de longa duração com análise temporal de alta resolução proveniente de dados brutos dos sensores. No entanto, este não aplicou técnicas adicionais para explorar correlações das informações com ocupação do solo, focando em apresentar projeções com resultados de cálculos estatísticos.

Este artigo aplica técnicas computacionais, a fim de denotar as correlações com a ocupação do solo e principalmente expor aplicações de análises espaçotemporais em espaços urbanos, apresentando quais são as características predominantes de uma cidade média e uma metrópole brasileira, que possuem perfis diferentes de cidades europeias. Desta forma, o modelo pôde ser validado, por meio de experimentos e comparação com modelos tradicionais de monitoramento da qualidade do ar, o qual foi importante para compor o grupo de controle dos experimentos.

## 3. Construção de mapas para interpretações análises espaçotemporais

Para criar um ambiente para análise espaçotemporais de alta resolução é necessário o suporte de uma plataforma tecnológica complexa, com diversos recursos técnicos e que exige conhecimento multidisciplinar. Portanto, a plataforma emprega técnicas computacionais, a fim de construir representações espaçotemporais com base nos dados provenientes de sensores ambientais. Para se revelar informação além de cálculos estatísticos, utilizaram-se estratégias de mineração de dados para realçar características das microrregiões e correlacioná-las com a ocupação do solo.

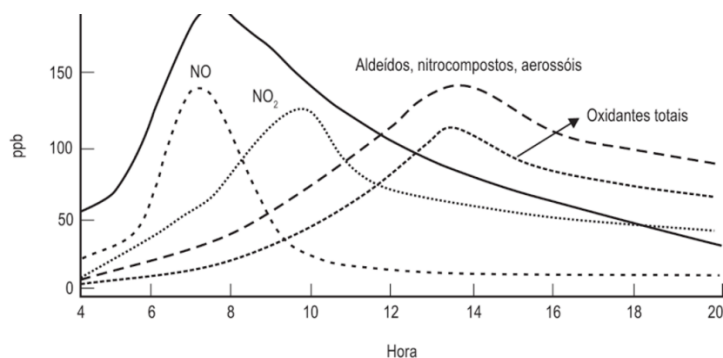
A metodologia empregada nos mapeamentos é observada em detalhes em [Santos, 2018], de forma geral, esta é dividida em três fases, conforme Figura 2.



**Figura 2 – Etapas metodológica para geração de modelos espaçotemporais**

A Fase ETL é responsável pelo primeiro tratamento dos dados dos sensores, carregando as informações nas bases, com o devido processamento e filtragem.

A Fase CAT é responsável pelas operações que formam a perspectiva temporal. Além de cálculos estatísticos, um comportamento típico apontado por [Rocha, Rosa e Cardoso,2009] da concentração de poluentes em centro urbanos (Figura 3) exigiu estudo de melhores técnicas para realçar pontos importantes das regiões mapeadas. Assim se explorou estratégias utilizadas em mineração de dados, como normalização e padronização de dados [HAN, J; KAMBER, M; 2006]. Adotaram-se variações em faixas de uma hora, conforme padrões internacionais [U.GOVERNMENT,2010], classificando em níveis de concentrações de poluentes, seja de forma absoluta ou relativa, a qual revela pontos que concentram poluentes com maior ou menor tendência.



**Figura 3 – Perfil típico da concentração de gases durante o dia.**

A Fase CAE realiza as composições espaciais e incorpora a conversão para a projeção cartográfica em UTM e realiza interpolações com técnicas baseadas na ponderação pelo inverso da distância (IDW). Esta técnica visa transformar a entidade espacial de dados pontuais (discretos) para dados poligonais (contínuos), fazendo uma média entre os dados coletados com base na primeira lei da geografia “Tudo está relacionado com tudo o resto, mas coisas próximas estão mais relacionadas do que coisas distantes”, ou seja, o valor para as áreas sem obtenção de dados é definida pela relação inversa da distância. IDW é comum em mapas para expressar a qualidade do ar.

A combinação das três fases geram os modelos: Relativo e Absoluto. O Relativo representa o resultado do processamento com dados normalizados ou padronizados, abordados pelas fórmulas (1) e (2), já o modelo absoluto trabalha com valores brutos.

$$V_i = \frac{\sum_{j=1}^n \left( \frac{1}{d_{ij}^p} Vp(x) \right)}{\sum_{j=1}^n \frac{1}{d_{ij}^p}} \quad (1) \quad \text{ou} \quad V_i = \frac{\sum_{j=1}^n \left( \frac{1}{d_{ij}^p} Vn(x) \right)}{\sum_{j=1}^n \frac{1}{d_{ij}^p}} \quad (2)$$

Onde:  $Vp(x) = \frac{(x - \bar{C}(x))}{\sigma(C(x))}$        $Vn(x) = \frac{(x - \text{mínimo}(C(x)))}{\text{máximo}(C(x)) - \text{mínimo}(C(x))}$

$Vp(x)$  é o valor padronizado do ponto  $x$ ;       $Vn(x)$  é o valor normalizado do ponto  $x$   
 $C(x)$  é o conjunto de dados com a mesma data e mesma faixa horária de  $x$   
 $V_i$  é o valor desconhecido  $i$ ;       $n$  é o número de pontos a ser utilizados para compor  $V_i$ ;  
 $d_{ij}$  é a distância entre o ponto com valor a determinar  $i$  e o ponto com valor conhecido  $j$ ; e  
 $p$  a potência para ser usada como ponderação.

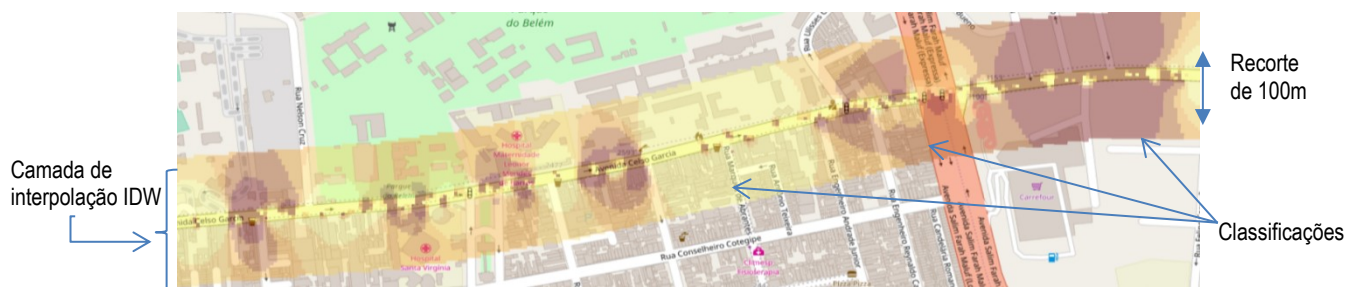
Um dos fatores relevantes para a projeção dos resultados em modelos cartográficos é a cobertura da leitura de uma medição. Esta é determinada pelos critérios de representatividade espacial, baseado em regulamentos internacionais [U.GOVERNMENT,2010], que é classificada em quatro escalas, conforme Tabela 1.

**Tabela 1 - Representatividade espacial de estações para avaliar a Qualidade do ar**

Escala	Representatividade espacial
Microescala	Dimensão de poucos metros até 100 metros
Média escala	Blocos de áreas urbanas com dimensões entre 101 e 500 metros
Bairro	Áreas de bairros urbanos com atividade uniforme e dimensões entre 501 e 4.000 metros
Urbana	Cidades ou regiões metropolitanas, da ordem de 4 a 50 km

De forma geral, a escala é determinada pela distância da estação até uma via pública de alto tráfego, por exemplo, para uma estação ser considerada de escala bairro, esta deverá estar distante pelo menos 150 metros de uma via com o volume diário de 60 mil veículos. No caso da plataforma proposta neste artigo, os sensores estão hospedados em veículos que transitam nas via, assim as medidas terão a representatividade espacial em microescala, e assim qualquer projeção feita além dos 100 metros de distância do ponto de coleta pode gerar erros de interpretação. Considerando os fatores de representatividade espacial, após a interpolação dos dados das medidas, recortes (buffers) devem ser feitos a fim de delimitar os valores representados.

E por fim, a Figura 4 apresenta um exemplo do resultado da aplicação do processo proposto, com uma classificação de três níveis (alto, médio, baixo).



**Figura 4 – Exemplo de projeção de camada cartográfica após etapas metodológicas**

## 4. Estudos de caso

Foram realizados estudos na cidade de Juiz de Fora - MG (médio porte) e em São Paulo - SP (grande metrópole).

### 4.1 Estudo de caso – Juiz de Fora

A cidade de Juiz de Fora, segundo o IBGE, é uma cidade de médio porte com aproximadamente 500 mil habitantes, exatamente o limite entre uma cidade média e uma cidade de grande porte. Os dados foram coletados pelos autores deste artigo, durante realização do XXXIII Simpósio Brasileiro de Telecomunicações – SBrT 2015, o qual incluiu em seu programa uma competição de soluções mais inovadoras para cidades inteligentes.

#### 4.1.1 Materiais e métodos

Neste experimento foram equacionados os seguintes fatores:

- kit sensor: kit sensor foi instalado no topo de um ônibus coletivo, transitando conforme sua escala de atendimento diário; a base fundamental do kit é proveniente do fornecedor Libelium [LIBELIUM, 2014];
- Variáveis ambientais coletadas: Concentração de gases O<sub>3</sub>, NO<sub>2</sub>, CO<sub>2</sub>, além dos valores de temperatura e umidade;
- Local do experimento: O kit foi embarcado em um ônibus coletivo a diesel da linha 535 (Cidade Universitária – Vila São Pedro), em Juiz de Fora – MG. O trajeto escolhido compreende o trânsito em uma rota circular de IDA e Volta, passando pelas regiões da cidade universitária (região arborizada), centro da cidade em corredores de ônibus, e na Avenida Presidente Itamar Franco, uma das principais vias da cidade com aproximadamente 4 km, com trechos de via dupla com pontos de subida e descida;
- Duração: 12 horas de coleta de dados, compreendido em duas faixas horárias: das 8h às 14h, e das 14h às 20h;
- Amostra: O sensor foi configurado para realizar coletas, a cada 30 segundos (tempo mínimo para estabilização do sensor).

O experimento ocorreu nos dias 02 e 03 de Setembro de 2015. No primeiro dia foram obtidos os dados do período das 14h às 20h, já no segundo dia, o período foi das 09h às 14h, completando um ciclo completo do horário da manhã, e até o fim de horário de pico da tarde (Figura 5).



**Figura 5 – Instalação do kit sensor na Cid. Universitária**

Cabe salientar que durante a coleta, o sensor de “CO” apresentou problemas, sendo assim, para este experimento esta variável foi descartada da análise.

#### 4.1.2 Resultados

A Figura 6 apresenta a projeção no terreno de todos os pontos coletados, os quais foram separados em 6 grupos, cada um representando uma parte da cidade (Tabela 2), que possui características similares de ocupação de solo.


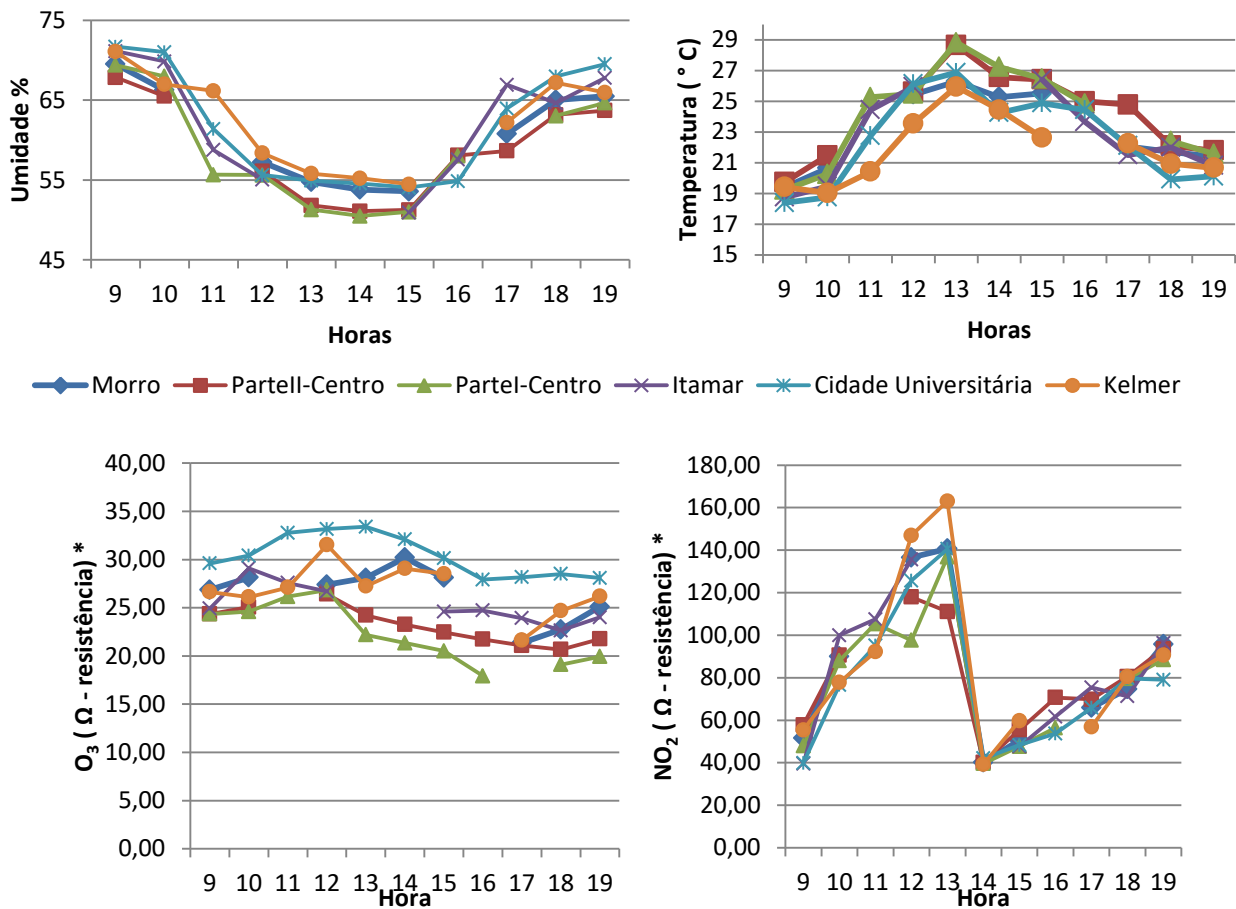


Figura 6 – Projeção dos pontos coletados.

Tabela 2 - Trecho segregados para estudo e suas características

<i>Grupo</i>	<i>Cor</i>	<i>Característica da Região</i>
1 - Centro I	Azul escuro	Centro da cidade, iniciando pelo corredor exclusivo de ônibus no centro da cidade, com alto tráfego urbano, o trecho está ligado à região arborizada do morro do imperador.
2 - Centro II	Verde	Centro da Cidade, com região urbanizada com vias duplicadas de ocupação urbana essencialmente comercial, com sobrados de 2 andares, e com alto tráfego urbano.
3 - Itamar	Azul claro	Compreendido principalmente pela av. Itamar franco, com região urbanizada com vias duplicadas, com trechos de aclive e declive, e com alto tráfego.
4 - Cidade Universitária	Branca	Cidade universitária, essencialmente arborizada com poucas estruturas prediais, com baixo tráfego urbano.
5 - Kelmer	Rosa	Trecho residencial, transitando principalmente pela Av. Kelmer, que liga duas áreas arborizadas, Cidade Universitária e Morro do Imperador.
6 - Morro	Amarelo	Trecho com baixa ocupação predial, essencialmente arborizada.

A Figura 7 apresenta os gráficos dos dados coletados pelo kit por trecho percorrido.



\*Quanto maior a resistência, maior a concentração

Figura 7 – Médias horárias temperatura, umidade, concentração de O<sub>3</sub> e NO<sub>2</sub> por trecho.

#### 4.1.3 Análise dos dados e projeções espaçotemporais

Ao analisar os dados é perceptível a variação temporal, o trecho da cidade universitária apresenta maiores índices de concentração do poluente O<sub>3</sub>. Por outro lado, a região do centro é a região que apresenta os menores índices. Com relação aos demais gases, não é clara uma conclusão sobre as regiões mais críticas, com apenas a análise dos dados. Sendo necessário construir as representações espaçotemporais para analisar a situação.

Cabe salientar, que os valores de concentração de poluentes, neste experimento, foram expressos em unidades elétricas, o que pode dificultar a análise, no entanto, a proporcionalidade, ou sejam a relatividade entre as áreas é mantida, sendo possível perceber variações em diferentes regiões, nas novas versões do kit esta característica foi resolvida com a apresentação dos valores de concentração de gases, através da calibração em unidades tradicionais como ppm (partes por milhão). A seguir são apresentados os resultados do mapeamento (Figuras 9 e 10).



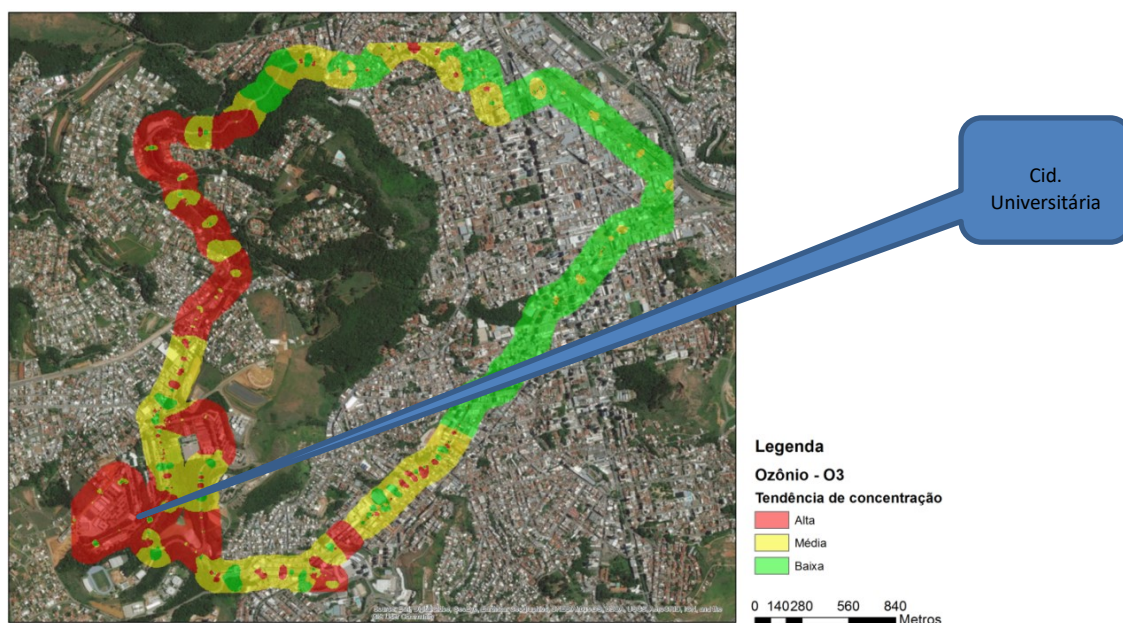


Figura 8 – Mapa com o valor da resistência do sensor de O<sub>3</sub> na rota da linha 535

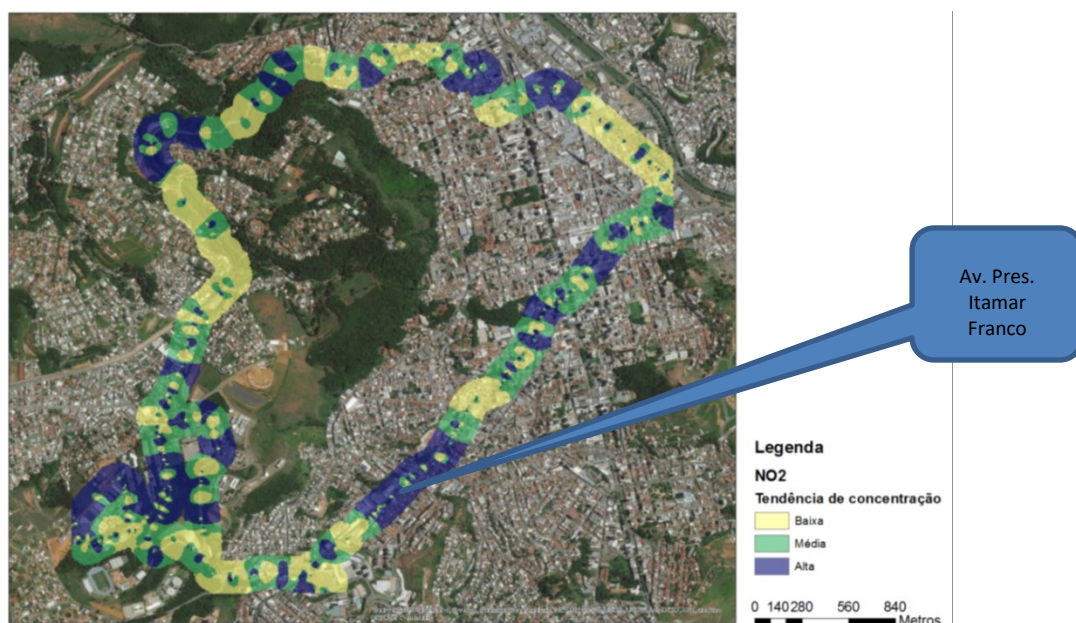


Figura 9 – Mapa com o valor da resistência do sensor de NO<sub>2</sub> dia 03/09 de manhã

#### 4.1.4 Discussão dos resultados

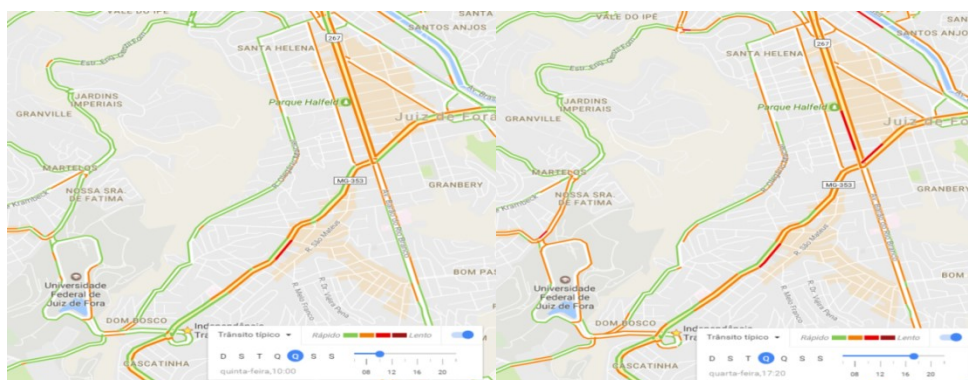
A cidade apresenta congestionamento em horários de pico, e são sensíveis os efeitos da poluição gerada pelos veículos. Para o poluente O<sub>3</sub>, os gráficos da Figura 7 permitem observar que a região da Cidade Universitária apresenta as maiores concentrações, enquanto o trecho do centro da cidade é o menor em qualquer faixa horária.

O mapeamento revelou a situação característica com maiores concentrações de O<sub>3</sub> nas regiões mais arborizadas (Figura 8), e que incluem o trecho da Cidade Universitária. Esta característica é comum em áreas urbanas. O gás O<sub>3</sub> é um poluente secundário formado de reações químicas entre hidrocarbonetos (isopreno) emitidos por

plantas com NO<sub>x</sub> emitidos pelos veículos, com catalização pela radiação solar, e devido a isso, regiões arborizadas urbanas tendem a ter maior concentração de O<sub>3</sub>, logo após os períodos de maior insolação [MENDES, 2016].

Ao analisar as concentrações de NO<sub>2</sub> observa-se que as regiões mais críticas estão esparsas, e dependendo do horário estão localizadas em pontos diferentes. O NO<sub>2</sub> é um gás primário, isto é, é emitido diretamente pelos veículos; sendo assim, poderia haver uma correlação com volume de tráfego e congestionamentos; para averiguar, coletou-se o perfil típico de trânsito, que é informado pelo *Google Maps*, que apresenta a velocidade do trânsito conforme o perfil típico da hora e do dia. Ao analisar o perfil típico (Figura 10) com os mapas de NO<sub>2</sub> (Figura 9), pode-se perceber que os pontos com maior concentração de NO<sub>2</sub> estão em regiões com tráfego lento, o que pode ser visto tanto no período da manhã como no período da tarde.

Em ambos os períodos, as regiões mais críticas foram o centro e a Av. Pres. Itamar Franco, com destaque para esta última, que revelou ser o pior trecho. Esta avenida é composta por quatro vias com duas faixas de ida e duas de volta, com canteiro central estreito; boa parte do trecho é composta por edificações de média e alta estatura, formando os chamados “cânions urbanos” com o agravante de que o ponto mais crítico ocorre em regiões de aclave. Esta constatação é coerente com estudos que mostram que em cânions urbanos são pontos com concentração de poluentes (KRECL et al., 2016).



**Figura 10 – Perfil de trânsito da manhã e tarde do experimento. Fonte:Google Maps (2017).**

Após as análises espaçotemporais foi possível evidenciar que o kit sensor hospedado em ônibus coletivo permite coletar dados para realizar microanálises de regiões geográficas com diferentes graduações de concentração de poluentes com interpretações por faixa horária. No entanto, a amostra de apenas um dia, não promove uma amostra consistente e, além disso, o kit continha leituras de concentrações de gases em unidades não tradicionais e sem calibração, o que dificultava o uso de vários sensores. Para cobrir as deficiências apresentadas em Juiz de Fora, um novo kit foi montado, com calibração apropriada. Definiu-se que pelo menos 30 leituras a cada 100 metros deveriam ser utilizadas como referência mínima para a amostra de análise (amostra estatisticamente não pequena). Optou-se então, utilizar o novo kit calibrado em uma nova cidade com uma rede monitoramento da qualidade do ar estabelecida, como forma de grupo de controle dos dados coletados pelos sensores móveis.

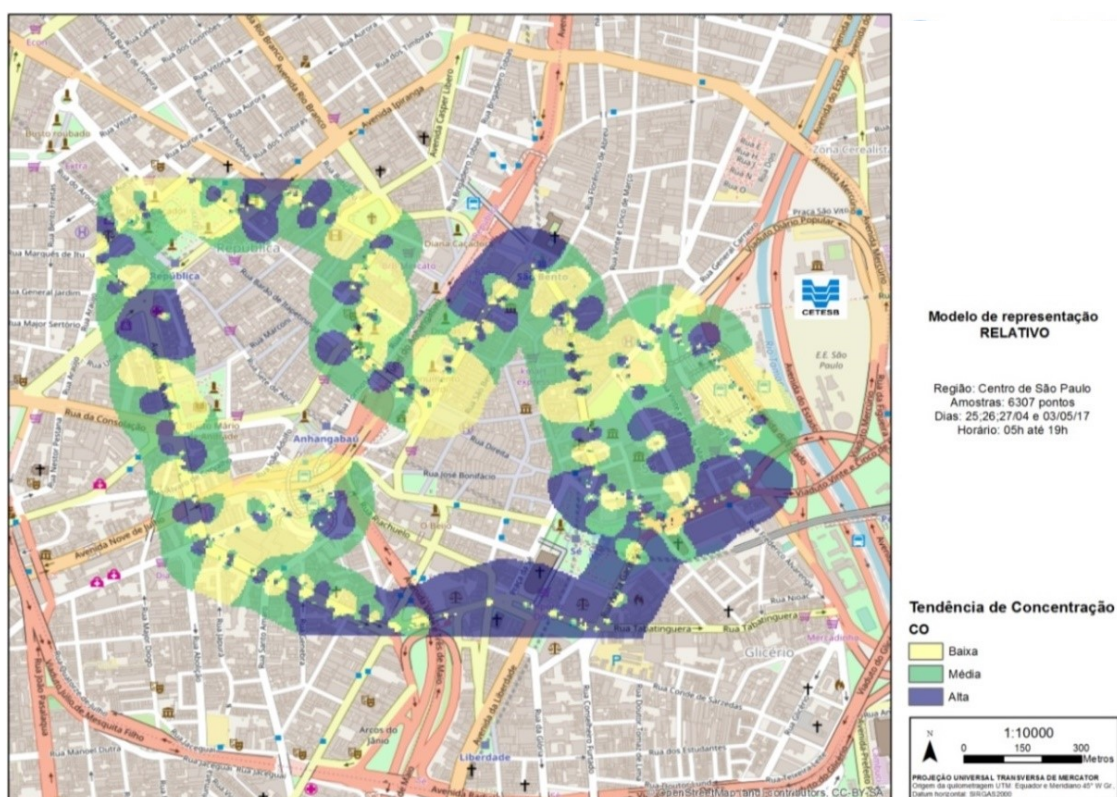
#### **4.2 Estudo de caso: cidade de São Paulo**

Apesar de não ser uma cidade média, São Paulo concentra uma variedade de características de ocupação do solo, problemas com tráfego urbano, e uma rede bem

estabelecida de estações tradicionais de monitoramento da qualidade do ar, os quais são fatores importantes para validar todos os métodos e a plataforma.

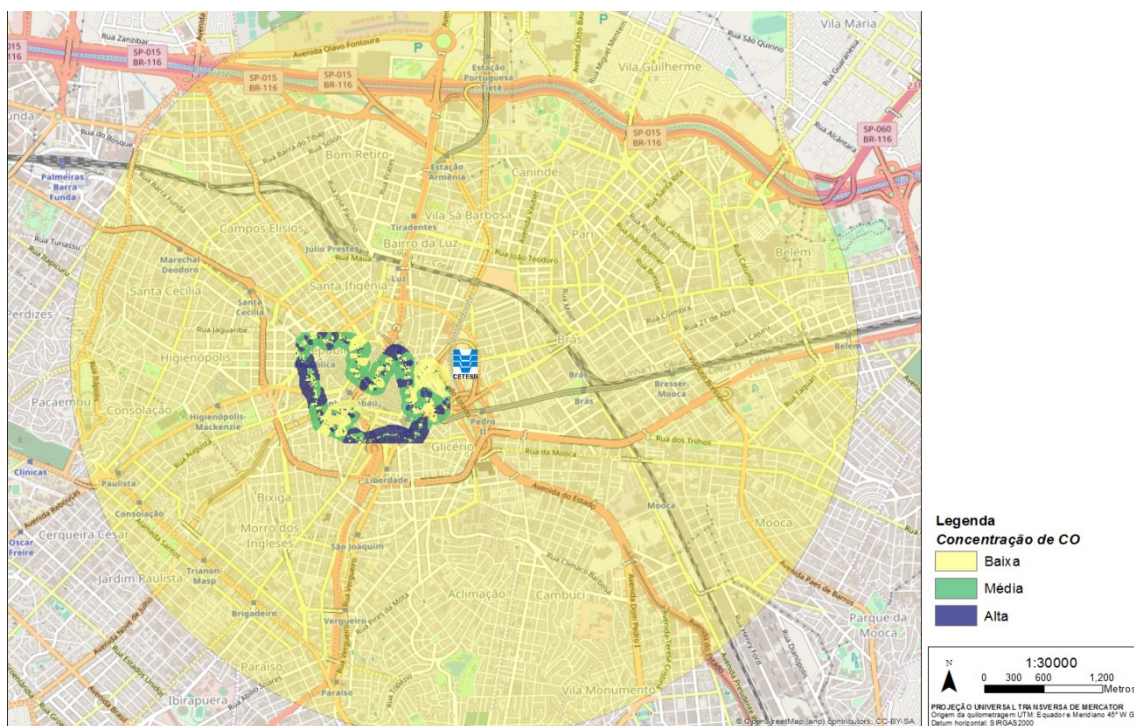
Para validar o contexto, os kits foram instalados em 19/04/2017, em 2 ônibus elétricos do tipo trólebus da empresa AMBIENTAL, na linha 2002-10 - TERM. PQ. D. PEDRO II/TERM. BANDEIRA. A linha 2002-10 realiza um trajeto circular de 7 km, que se inicia pelo Terminal Parque Dom Pedro II, passando por vias tradicionais do centro histórico da cidade.

A coleta realizou-se em 4 dias da semana obtendo-se 6.307 amostras, que permitiu mais de 30 pontos a cada 100 metros. A Figura 11 apresenta o resultado do mapeamento do centro histórico para o poluente monóxido de carbono obtido com os kits em ônibus elétricos, classificados proporcionalmente em 3 classes: baixa, média e alta tendência de concentração de poluentes.




**Figura 11 – Modelo de representação da concentração de CO na Zona Central**

Se formos comparar os resultados obtidos na Figura 11, com os obtidos com os modelos tradicionais de monitoramento, é possível perceber que os modelos atuais não são capazes de revelar as características de pequenas regiões. Por exemplo, a Figura 12 apresenta a projeção da cobertura da estação tradicional de monitoramento automático (Estação Parque Dom Pedro), que projeta uma cobertura de raio de até 4 km. O valor médio da estação se enquadra na classificação “baixa”, se compararmos com os valores obtidos pelo modelo proposto. No entanto, apesar da média geral dos dois modelos serem semelhantes, é perceptível no modelo proposto fica evidenciado que pequenas regiões apresentam níveis diferentes.



**Figura 12 – Projeção dos resultados do modelo proposto sobre o modelo tradicional**

Com os resultados do modelo proposto é possível realizar análises espaçotemporais mais detalhadas. Por exemplo, a Figura 13 apresenta a região crítica (parte inferior da Figura 11). Como indicado nas pesquisas [VARDOULAKISA et al., 2003]; [BARREFORS, 1996]; [AHMAD; KHARE; CHAUDHRY, 2005], esta região tem fatores contribuintes para justificar a maior tendência de concentração, uma vez que recebe poluentes da Avenida 23 de Maio, via de alto tráfego sob o viaduto dona paulina, que canaliza as emissões por um cânion urbano, em vias de cinco faixas com conjuntos semafóricos. Além disso, todos os viadutos do trajeto revelaram alta tendência de concentração de CO, assim como nos grandes cruzamentos com mais de 8 faixas.



**Figura 13 – Visão 3D da região crítica de CO da Zona central. Fonte: Google Maps (2017).**

Além do Monóxido de Carbono também foram obtidos dados e gerados mapas de  $\text{NO}_2$ ,  $\text{O}_3$  que puderam ser analisados por várias faixas horárias, permitindo novas perspectivas de análise do espaço urbano. Além disso, foi possível comparar os resultados com os valores apresentados por estações fixas oficiais de monitoramento da qualidade ao ar, referenciada pelo logo da CETESB na Figura 11 e Figura 12, as quais apresentaram valores médios equivalentes aos apresentados pelos sensores móveis.

## 5. Conclusão

A metodologia empregada permitiu realizar análises das regiões mapeadas usando perspectivas espaciais e temporais com maior resolução que os modelos tradicionais de monitoramento da qualidade do ar, os quais ainda não oferecem esta possibilidade. Esta maior resolução permite uma nova perspectiva de análises de regiões escondidas pela baixa resolução dos modelos tradicionais e, desta forma, permite que os especialistas ou gestores urbanos possam entender melhor as situações, ao utilizarem as ferramentas e recursos disponibilizados pela plataforma para suas análises. Além disso, no momento em que as informações são integradas a um SIG, este se torna uma importante ferramenta de tomada de decisões com potencial de análises em micro escala (até uma centena de metros), podendo ser ampliada com informações adicionais como, por exemplo, dados oficiais de estações automáticas de monitoramento de qualidade do ar.

Também foi possível perceber as melhores práticas para uso dos modelos de representação apresentados por este artigo, sendo que o modelo relativo ajuda a identificar áreas que frequentemente apresentam maiores concentrações de poluentes, e a partir desta usar os modelos absolutos para verificar os níveis com medidas tradicionais de concentração de poluentes. O modelo relativo minimiza o efeito da sazonalidade, já o modelo absoluto permite verificar os índices em unidades de ppm, o que facilita o entendimento e comparativos com os padrões de qualidade do ar, no entanto quanto mais longo for o período de coleta, as médias tendem a amenizar as diferenças, por isso, o modelo absoluto pode ser melhor aplicado em períodos mais curtos, como os tradicionalmente utilizados por Órgãos Estaduais de Meio Ambiente, como por exemplo em períodos de 1h, 8h, 24h. Portanto, o uso combinado dos dois modelos cartográficos é uma boa prática, para realizar interpretações mais claras.

Com as análises espaçotemporais, o gestor poderá adotar estratégias mitigatórias, como por exemplo: a aplicação de restrições ao tráfego em regiões críticas; optar por ônibus urbanos menos poluentes nas rotas ou trechos que apresentam maiores concentrações de poluentes. Os resultados obtidos por este artigo podem ser utilizados para mapear ilhas de calor pela cidade, ampliando as análises para além do escopo de qualidade do ar, incluindo fatores de monitoramento de condições climáticas. Este tópico é discutido para definir, por exemplo, estratégias de arborização, e estudos sobre microclima [DUARTE; SOUZA, 2004]. Os estudos de microclima já deixam claro, a falta de informações de regiões sobre áreas densamente urbanizadas, uma vez que a maioria das estações oficiais está localizada em parques e não oferecem informações nos eixos de maior verticalização, como são os cânions urbanos.

## Referências

- AHMAD, K.; KHARE, M.; CHAUDHRY, K. K. Wind tunnel simulation studies on dispersion at urban street canyons and intersections - a review. *Journal of Wind Engineering and Industrial Aerodynamics*, v. 93, n. 9, p. 697 - 717, Sept. 2005.
- BARREFORS, G. Air pollutants in road tunnels. *The science of Total environment*, v. 189, p. 431-435, 1996.
- BIELSA, A. Smart City project in Serbia for environmental monitoring by Public Transportation. Libelium Web Site, Jan. 2012. Disponível em: <[http://www.libelium.com/smart\\_city\\_environmental\\_parameters\\_public\\_transportation\\_waspmote/](http://www.libelium.com/smart_city_environmental_parameters_public_transportation_waspmote/)>. Acesso em: 14 abr. 2018.

- DUARTE, D.; SOUZA, T. Padrões de ocupação do solo e microclimas urbanos em São Paulo. In: NUTAU, 2004, São Paulo. Anais... São Paulo: USP-FAU, 2004.
- HASENFRATZ, D. Deriving high-resolution urban air pollution maps using mobile sensor nodes. *Pervasive and Mobile Computing*, v.16, p, 268-385, 2015.
- IBGE. Censo Demográfico 2010 - características da população e domicílios - resultados do universo. Rio de Janeiro: IBGE, 2011. 270 p.
- IEMA. 1º Diagnóstico da rede de monitoramento da qualidade do ar no Brasil. São Paulo: Instituto de Energia e Meio Ambiente, 2014. 277 p.
- KRECL, P. et al. Screening of short-lived climate pollutants in a street canyon in a mid-sized city in Brazil. *Atmospheric Pollution Research*, v. 7, n. 6, p. 10022-1036, 2016.
- HAN, J.; KAMBER, M. 2006. *Data Preprocessing. Data Mining: Concepts and Techniques. Second Edition.* San Francisco, USA : Elsevier Inc., 2006.
- LIBELIUM. Gases Board Technical Guide - Document version: v4.7. Zaragoza, Spain: 2014.
- MENDES, S. USP apresenta taxas elevadas de ozônio. *Jornal do Campus*, São Paulo, 10 jun. 2016.
- MURTY, R. N. et al. CitySense: an urban-scale wireless sensor network and testbed. In: IEEE CONFERENCE ON TECHNOLOGIES FOR HOMELAND SECURITY, 2008, Waltham, MA – USA. *Proceedings...* Washington:: IEEE, 2008. p. 583-588.
- OJALA, T. Open urban testbed for ubiquitous computing. In: INTERNATIONAL CONFERENCE ON COMMUNICATIONS AND MOBILE COMPUTING, Shenzhen, China, 2010. **Proceedings...** Washington:: IEEE, p. 442-447.
- ROCHA , J. C.; ROSA , A. H.; CARDOSO, A. A. *Introdução à química ambiental.* 2. ed. Porto Alegre: Bookman, 2009.
- SANCHEZ, L. et al. SmartSantander: IoT experimentation over a smart city testbed. *Computer Networks*, v. 61, p. 217 - 238, Mar. 2014.
- SANTOS, A. S. D. *Análise espaçotemporal da qualidade do ar em vias urbanas por meio de Redes de Sensores com nós embarcados em ônibus coletivos.* (tese de doutorado), Universidade de São Paulo, p. 192, 2018.
- SMARTSANTANDER. *Mitos - Interface web do Experimento piloto no projeto SmartSantander* Disponível em: <<http://smartsantander.eu/index.php/mitos>>. Acesso em: 10 set. 2017.
- UNITED NATIONS. *World Urbanization Prospects the 2011 Revision - highlights.* New York: United Nations, 2012. 33 p.
- U. GOVERNMENT, “Cfr. part 58 – ambient air quality surveillance – probe and monitoring path siting criteria for ambient air quality monitoring,” in *Code of Federal Regulations - Title 40 – Protection of Environment.* Washington, USA: U.S.Government Printing office, 2010, pp. 242–303.
- VARDOULAKISA, S. et al. Modelling air quality in street canyons: a review. *Atmospheric Environment* , v. 37, p. 155-182, Jan. 2003.