

# LayerBase: Uma Solução para Visualização e Análise Temporal de Dados Georreferenciados

Pedro Pongelupe Lopes<sup>1</sup>, Humberto Torres Marques-Neto<sup>1</sup>

<sup>1</sup>Departamento de Ciência da Computação  
Instituto de Ciências Exatas de Informática  
Pontifícia Universidade Católica de Minas Gerais (PUC Minas)  
Avenida Dom José Gaspar, 500 - Coração Eucarístico - 30535-901 - Belo Horizonte/MG

pedro.pongelupe@sga.pucminas.br, humberto@pucminas.br

**Abstract.** *The understanding of human mobility patterns in major cities may improve services offered to the population. These patterns are hidden among massive datasets making it hard to work on it manually. In this context, geovisualization applications provide tools and functions to execute complex tasks over huge workloads. This paper presents LayerBase, a light-web application designed for visualization and analysis of spatio-temporal features simultaneously. In order to present LayerBase key features, we analyzed the COVID-19 open-data from Belo Horizonte throughout thirteen months. The results point patterns between neighborhoods and epidemiological focus throughout the analyzed interval.*

**Resumo.** *A exploração de padrões de mobilidade nos grandes centros urbanos pode auxiliar na tomada de decisões para melhorar serviços prestados à população. Esses padrões estão escondidos em meio a grandes bases de dados, tornando difícil a manipulação manual. Neste sentido, ferramentas de geovisualização trazem aparatos e métodos para executar tarefas complexas sobre grandes cargas de trabalho. Este trabalho apresenta o LayerBase, que é uma ferramenta web capaz de manipular várias camadas espaciais e temporais interagindo simultaneamente. A solução é apresentada com dados abertos de treze meses da pandemia de COVID-19 em Belo Horizonte, apontando padrões sobre a relação entre os bairros e focos epidemiológicos ao longo do tempo.*

## 1. Introdução

Na computação urbana, mobilidade humana pode ser útil como ferramental para planejamento e desenvolvimento de soluções para uma determinada região, baseando-se no deslocamento das pessoas nessa região [Silveira et al. 2015]. A análise desses padrões de movimentação, especialmente em grandes centros urbanos, auxiliam organizações governamentais e do setor privado a melhorarem os serviços de mobilidade de diversos âmbitos, como o transporte público, eventos turísticos e contenção da disseminação de epidemias [Desai 2020, Varlamis et al. 2021].

Os grandes centros urbanos fornecem dezenas, e até centenas, de bases de dados que podem ser acessadas livremente sem restrições quanto a direitos autorais ou outras formas de controle disponibilizadas através de portais de dados abertos [Auer et al. 2007].

Nesse sentido, bases de dados que são atualizadas frequentemente e são compostas por dados de diversificadas áreas do conhecimento como planejamento urbano, saúde, turismo, dentre outras. Ademais, os atributos que compõem essas bases podem ser caracterizados como dados estáticos e dados dinâmicos. Sendo os estáticos, os que, essencialmente, não se alteram com a passagem do tempo, como a delimitação do perímetro urbano, em contraste com os dados dinâmicos, estes que se alteram ao passar do tempo, como fluxo de carros em vias ou focos de epidemias.

As características dinâmicas impactam diretamente no padrão de mobilidade das pessoas no espaço urbano. No contexto de saúde pública, por exemplo, a pandemia de COVID-19 alterou por completo os padrões que haviam anteriormente, inclusive, por medidas para mitigar a disseminação do vírus [Aleta et al. 2020]. Uma das técnicas adotadas foi o rastreamento de contatos que consiste em identificar pessoas infectadas para rastrear as localidades e as outras pessoas a qual essa teve contato. Logo, este método é utilizado para contenções de epidemias anteriormente a pandemia de COVID-19, sendo realizado por meio de coleta manual de arquivos e entrevistas [Lai et al. 2020]. As ferramentas de computação urbana podem auxiliar por computar grandes volumes de dados, levantando rastreios em sinal de Wi-Fi, reconhecimento facial, APIs públicas, Bluetooth, movimentações bancárias, QR Code e outros [Huang et al. 2020, Ramos 2020, Desai 2020, Saran et al. 2020, Vannoni et al. 2020].

Nesse contexto de exploração de dados de mobilidade, os aparatos de computação urbana auxiliam na tomada de decisões. Em consonância, a Geo-Visualização é uma subárea que agrega ferramentas e técnicas para análise de dados geoespaciais por meio de uma visualização interativa, baseando-se na interdisciplinaridade, atendendo usuários que são de áreas diferente que Ciência da Computação, como Geografia e Cartografia [Elwood 2009]. Isto posto, este estudo tem como objetivo apresentar o LayerBase, uma ferramenta de geo-visualização interativa na *web* capaz de realizar visualização e análises de várias camadas espaciais e temporais, simultaneamente. Sem ser dependente de nenhuma base de dados, esta ferramenta consegue efetuar análises temporais com dados de múltiplas fontes e contextos, como turismo, por exemplo.

Desse modo, para apresentar a utilização do LayerBase, foi feito um estudo de caso analisando a evolução de casos de COVID-19 por meio de boletins epidemiológicos, na cidade de Belo Horizonte, durante o período de 2 de fevereiro de 2020 até 12 de março de 2021, obtidos pela plataforma de dados abertos da cidade. Durante esse período, foram analisados diferentes cenários da doença, variando entre casos leves até óbitos. O LayerBase auxiliou em obter percepções sobre o desdobramento da pandemia em Belo Horizonte, que foram fundamentais para análises realizadas sobre essa mesma base de dados na Seção 5.

Sendo assim, esse estudo está organizado da seguinte maneira: após a introdução, a Seção 2 apresenta os trabalhos relacionados que auxiliaram no desenvolvimento do LayerBase. Na sequência, a Seção 3 apresenta nossa solução implementada, LayerBase. Logo após, a Seção 4 contém a validação da proposta e na Seção 5 é apresentado os resultados baseado nas percepções levantadas pelo LayerBase. Na Seção 6, as conclusões e, finalmente, na Seção 7, os trabalhos futuros desse estudo.

## 2. Trabalhos Relacionados

Nesta Seção, são abordados trabalhos de ferramentas de geo-visualização, assim, revelando as principais funcionalidades. Além disso, são explorados trabalhos que apontam a utilização de técnicas de computação urbana aplicadas à mobilidade humana. Logo, apontando como esses arcabouços tecnológicos podem auxiliar na tomada de decisão em diversificados do cenários do mundo real, como o turismo e contenção de epidemias.

O MapMosaic [Lobo et al. 2017] é uma ferramenta avançada para manipulação de mapas. O conceito chave do MapMosaic é a possibilidade de compor regiões em um mapa único, isso se dá pela combinação dinâmica de múltiplas camadas de mapa em uma interface auto-ajustável. O desenvolvimento do MapMosaic foi baseado em uma série de entrevistas com especialistas em sistema de informação geográfica (GIS) para compreender as tarefas e as interações dos usuários com esse tipo de plataforma.

[Carvalho et al. 2018] classificam que existem três fases claras de uma viagem, a preparação (*pre-trip*), a viagem em si (*trip*) e o momento após (*after trip*) e de modo a buscar uma melhor experiência ao turista é necessário integrar essas fases continuamente, preferencialmente em tempo real [Carvalho et al. 2018]. Tal integração deve extrapolar as tecnologias de sistema de posicionamento global (GPS do inglês, *Global Positioning System*) e compor um contexto a cerca dos hábitos do turista. Partindo desse contexto, é proposto um *framework* de integração agregando dados sobre os turistas e os comércios que podem os servir gerando um perfil único e acessível ao turista possibilitando um refinamento das recomendações.

[Aleta et al. 2020] exploraram dados georreferenciados de mobilidade da região metropolitana de Boston levantados pelo senso de telefonia. Esses dados são relativos à mobilidade logo após a primeira onda de COVID-19. Serviram para elaboração de estratégias para mitigar a transmissão do vírus e conciliar o fechamento do comércio local nas próximas ondas. Um modelo sintético de uma rede complexa multidimensional valorada foi construído correlacionando três principais camadas: camada de escolas, camada ambiente de trabalho e comunidade e a camada residencial. Nessa rede complexa, as arestas representam a probabilidade de dois agentes, esses representados pelos vértices, compartilharem o mesmo espaço, e o peso da aresta denota o tempo gasto. Os resultados foram encontrados por diversas simulações feitas ao longo do tempo.

[Sonkin et al. 2020] exploraram técnicas de GIS para implementação de rastreamento de contatos de COVID-19 em Israel utilizando dados do Google Maps Timeline (GMTL). No intuito de demonstrar a acurácia do GMTL, foi comparado com métodos de auto-records. Como os dados do GMTL são sensíveis, o estudo foi conduzido com 17 participantes que concordaram em participar. A acurácia foi mensurada por cinco diferentes tipos de dados: localizações, rotas, meios de transporte, tempo e duração. Os resultados apontaram uma acurácia de 83,98%, inclusive revelando locais quais os participantes não se recordaram.

[Huang et al. 2020] mensuram os impactos da pandemia da COVID-19 utilizando dados de mobilidade do Baidu Maps na China. Foi analisado o período de janeiro até abril dos anos de 2018, 2019 e 2020, sendo o último o período de pandemia. O foco das análises foram sobre a relação de mobilidade humana e transportes, especialmente em cinco aspectos: os meios de transporte, tipos de locais visitados, horários de circulação,

distâncias percorridas e padrões de origem e destino. Os resultados apontam que a pandemia alterou os padrões de mobilidade das pessoas, medidas e métodos que promovem isolamento social foram amplamente adotados.

[Xavier et al. 2017] apresentam o Geo-Data Visualizer que uma ferramenta de geo-visualização na *web* para visualização de cargas de trabalho de redes de internet. A entrada de dados é feita por arquivos CSV que cada linha é composta seis informações: identificador da antena (*name*), a latitude e longitude, a data e hora e a carga associada à essa antena. Após, a entrada dos dados, o Geo-Data Visualizer possui funcionalidades de visualização como mapa de calor e disposição de elementos por marcadores ou *clusters*. Além disso, é incorporado algumas análises estatísticas que podem ser aplicadas sobre a massa de dados, cálculo de variância, assimetria e desvio quartil possibilitando interpretação mais profundas.

Neste trabalho, a solução proposta, LayerBase, engloba técnicas apresentadas nos trabalhos citados como funcionalidades básicas de GIS e a visualização de informações espaço-temporais, os paralelo entre outras ferramentas é explorado na Seção seguinte. Todavia, o LayerBase não possui dependência de bases de dados, assim, garantindo uma maior maleabilidade com as diversas áreas do conhecimento. De tal forma, permitindo certos níveis de análises e percepções sobre a mobilidade humana.

### 3. LayerBase

Esta seção apresenta a solução chamada LayerBase, a qual foi projetada para proporcionar uma experiência simplificada ao usuário que realiza tarefas relacionadas à edição de mapas e geo-visualização, especialmente, de informações espaço-temporais na *web*, tendo sua arquitetura exposta na Seção 3.1. O ferramental para manipulação de mapas que é especificado na Seção 3.3. O processo de importação/exportação de projetos abrange diversos formatos e interação entre esses formatos, sendo o processo de entrada e saída de dados é explorado na Seção 3.2. O conceito chave do LayerBase é a geo-visualização de características estáticas e dinâmicas pela interface *web*, que são detalhados na Seção 3.4. Em todas as Subseções dessa Seção, é traçado um paralelo entre as funcionalidades do LayerBase e do Mapshaper, ferramenta base para o LayerBase.

#### 3.1. Arquitetura

O LayerBase<sup>1</sup> é uma solução *web stateless* escrita em JavaScript baseada na aplicação *open-source* Mapshaper [Harrower and Bloch 2006]<sup>2</sup>. Todas as funcionalidades para manipulação de mapas estão disponíveis tanto em ambiente *web* e via interface de linha de comando (CLI), utilizando o mesmo código fonte. Neste estudo, é destacado apenas o ambiente *web*, pois a geo-visualização se faz presente somente nesse ambiente.

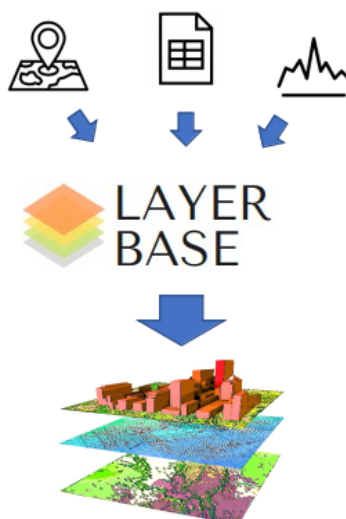
Apesar de várias funcionalidades serem originais do Mapshaper, o LayerBase possui algumas aplicabilidades exclusivas, como a visualização e análise de atributos temporais. Dado que essas funcionalidades não estão disponíveis em outras ferramentas de geo-visualização, como o MapMosaic, em um ambiente *web*, o Mapshaper foi utilizado como ferramenta base. As funcionalidades exclusivas do LayerBase estão descritas à seguir.

---

<sup>1</sup>O LayerBase está disponível em <https://github.com/Pongelupe/layerBase>

<sup>2</sup>Disponível em <https://github.com/mbloch/mapshaper>

- Importação de coordenadas geográficas por arquivos CSV.
- Adição do parâmetro *gradient* na função *colorizer*: Permitindo ao usuário realizar visualizações sobre a variância de valores de um atributo, possibilitando elaboração de mapas de calor, por exemplo.
- Suporte gráfico para adição/remoção de chaves de atributos: Permitindo ao usuário modificar os dados dentro do LayerBase sem ter que os importar novamente, exemplificado na Figura 4.
- O comando *duplicate*: Permitindo ao usuário que duplique uma camada, assim, possibilitando diferentes análises em cada uma das camadas com a visualização simultânea, exemplificado na Figura 8.
- O comando *temporal*: Permitindo ao usuário realizar através da interface gráfica operações temporais. A operação padrão é realizar um mapa de calor sobre um atributo dinâmico. A visualização é atualizada em milissegundos baseado no parâmetro *timeout*, o valor padrão é de 3000 milissegundos.



**Figura 1. Modelo arquitetural do LayerBase**

A Figura 1 ilustra a arquitetura proposta para o LayerBase, a qual é composta por três diferentes etapas: importação de dados, processamento de dados e saída de dados. A primeira consiste em importar as camadas para o LayerBase oriundas de diversas fontes. Então, a etapa do processamento, possibilita ao usuário manipular as camadas com as funções disponíveis. Finalmente, a saída de dados, essa que é constituída pela geo-visualização interativa e a exportação de dados. As etapas não geram bloqueio entre si e nem são terminais, em outras palavras, as etapas podem ser executadas de maneira desordenadas. Além disso, é possível decompor as camadas para a visualização separadas, assim, ocultando e revelando as camadas.

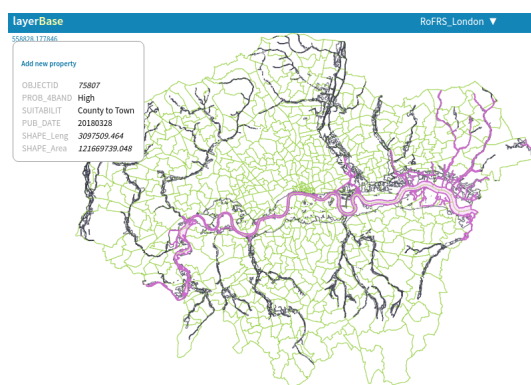
### **3.2. Importação e Exportação de Dados**

Para começar a utilizar o LayerBase, é necessário de pelo menos uma camada. Existem dois tipos de camadas: *Georreferenciáveis* e de *Dados*. A primeira possui dados espaciais

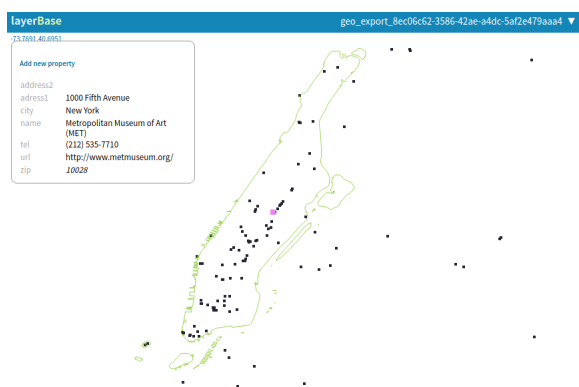
e informações complementares. A segunda possui informações, mas não tem dados espaciais. Todas as camadas podem ser importadas em qualquer um dos seguintes formatos: Shapefile, GeoJson, TopoJson<sup>3</sup>, CSV ou DBF.

Expandindo o processo de importação do Mapshaper, o LayerBase tem suporte para importar coordenadas geográficas de arquivos CSV. A única configuração necessária é definir duas novas colunas, 'X' e 'Y'. Então, essas coordenadas geográficas são convertidas em pontos, assim, permitindo a interação com outras camadas sem mais nenhuma configuração.

Além disso, o LayerBase possui boa interoperabilidade com dados abertos. As Figuras 2 e 3 apresentam dois exemplos, ambos sendo dados abertos sem modificações vindos de plataformas de grandes centros urbanos, importados no LayerBase. A Figura 2 retrata os distritos de Londres e as áreas com risco de inundações<sup>4</sup>. A Figura 3 retrata um bairro de Nova Iorque, Manhattan, e as atrações presentes nele<sup>5</sup>.



**Figura 2. Distritos com as zonas de alagamento em Londres**



**Figura 3. Museus em Nova Iorque e região de Manhattan destacada**

A qualquer momento durante a utilização do LayerBase, seja enquanto edita ou após finalizar, é exportar os dados para todos os formatos descritos acima. É uma maneira viável para se acompanhar do processo ou de compartilhar com outras pessoas.

<sup>3</sup>Disponível em <https://github.com/topojson/topojson/wiki>

<sup>4</sup>Disponível em <https://data.london.gov.uk/dataset>

<sup>5</sup>Disponível em <https://data.cityofnewyork.us>

### 3.3. Operações

Com as camadas importadas, o LayerBase tem várias ferramentas para manipular e correlacionar informações. Além das funcionalidades herdadas do Mapshaper, como *affine*, *colorizer*, *each*, *polygons* e *join*, as principais funcionalidades exclusivas do LayerBase estão descritas a seguir.

#### 1. *duplicate*

- Duplica a camada selecionada
- Parâmetros:
  - name** O nome da camada duplicada
  - affine** Possibilita transformar coordenadas por arrastar, redimensionamento e rotação da camada duplicada
  - points** Transforma polígonos em pontos
  - style** Aplica estilos de propriedades de SVG utilizando JavaScript ou valores literais

#### 2. *temporal*

- Executa uma expressão por uma série temporal
- Parâmetros:
  - id** Coluna de ligação da camada estática com a camada dinâmica.  
Por padrão uma coluna chamada *id*.
  - date** Coluna com o atributo temporal que será iterado sobre.  
Por padrão uma coluna chamada *date*.
  - timeout** Intervalo entre as épocas temporais.  
Por padrão 3000 milissegundos.
  - exp** Expressão JavaScript que será aplicada em cada época iterada.  
Por padrão é realizado um mapa de calor.

A interface *web* permite acompanhar a análise em tempo-real, a medida que o usuário for utilizando. Também, foi adicionado na função *colorizer* um parâmetro para definir diferentes gradientes, assim facilitando a percepção de diferenças dados dentre as camadas. Além disso, boa parte das funcionalidades disponíveis possuem a opção de desfazer, ajudando a desfazer erros.

### 3.4. Geo-Visualização

Geo-visualização tem papel central no LayerBase, pois permite ao usuário que fique atualizado com as modificações em tempo-real. Os dois tipos de visualização no LayerBase: estática e dinâmica.

A visualização estática provê uma visão inerte sobre as camadas inseridas. As Figuras 2 e 3 são exemplos da visualização estática, ambas com duas camadas cada. Essa visualização permite que o usuário interaja com os dados, modificando, adicionando ou removendo. Também, é disponibilizado ferramentas para melhorar a experiência, como *zoom in* e *zoom out*, destacar *polygons* específicos e alterar a camada principal, como Figura 4 exemplifica. Por ser uma ferramenta *stateless*, portanto, é necessário exportar uma nova camada com os dados alterados para persistir as alterações, caso contrário, as alterações serão descartadas.

-73.92456,40.65300

Add new property

address1	Central Park West at 79th Street	✕
city	New York	✕
name	American Museum of Natural History	✕
tel	(212) 769-5100	✕
url	http://www.amnh.org/	✕
zip	10024	✕

**Figura 4. Editando os dados da camada de museus em Nova Iorque**

A visualização dinâmica é a principal característica do LayerBase e, consiste em apresentar informações espaço-temporais de maneira simplificada. É necessário, pelo menos, duas camadas, uma camada de dados com atributos temporais que correlacione uma outra camada com um atributo georreferenciado. Então, o LayerBase irá correlacionar essas duas camadas para o intervalo de tempo definido na camada com os dados temporais, ordenados de forma crescente. Uma ação definida pelo usuário será executada para cada data, se nenhuma ação for definida, a ação padrão é executar um mapa de calor pela evolução temporal. Essa visualização é amplamente explorada na seção seguinte, Seção 4.

## 4. Validação da Proposta

Para apresentar a utilização do LayerBase como ferramenta de geo-visualização foram importados dados abertos da cidade de Belo Horizonte retratando um período da pandemia de COVID-19. Esta seção aborda as etapas necessárias para a realização dos objetivos propostos deste estudo.

### 4.1. Coleta de dados

Para ter os insumos do LayerBase, foram coletadas informações disponibilizadas por boletins epidemiológicos diários sobre a evolução da pandemia de COVID-19 em Belo Horizonte. Esses boletins epidemiológicos diários fazem parte do programa DATASUS<sup>6</sup>, que é uma iniciativa do governo federal para disseminar informações sobre a saúde. Portanto, além de Belo Horizonte, outras cidades possuem essas informações na *web*.

O período analisado é referente de 2 de Fevereiro de 2020 até 12 de Março de 2021, 404 dias no total. Os boletins descrevem três cenários de casos, sendo categorizados por bairros de residência: Síndrome Gripal, Síndrome Respiratória Aguda Grave e Óbitos, que evoluem da Síndrome Respiratória Aguda Grave. Os casos estão descritos de maneira acumulativa, conforme mostra a Figura 5<sup>7</sup>.

<sup>6</sup>Disponível em <https://datasus.saude.gov.br/>

<sup>7</sup>Disponível em <https://prefeitura.pbh.gov.br/saude/coronavirus>



Bairro de Residência	Síndrome Gripal	Síndrome Respiratória Aguda Grave	
		Total de Casos*	Óbitos
Aarão Reis	32	3	2
Acaba Mundo	3	0	0
Acaiaca	17	2	0
Ademar Maldonado	35	3	2
Aeroporto	20	3	0
Águas Claras	5	0	0
Alípio de Melo	218	7	2
Alpes	11	1	0
Alta Tensão	3	0	0
Alta Tensão I	4	0	0
Alto Barroca	68	1	0
Alto Caiçaras	88	6	0
Alto dos Pinheiros	31	2	1
Alto Vera Cruz	90	22	5

**Figura 5. Fragmento de boletim epidemiológico de Belo Horizonte do dia 12/03/2021**

Para a importação no LayerBase, os dados foram convertidos para um arquivo CSV, contendo 83096 linhas. Esse arquivo foi importado no LayerBase como a camada de dados temporais analisados com os atributos descritos a seguir.

**date** O atributo temporal. Representa o dia analisado.

**id** O identificador do bairro analisado.

**SG** Quantidade cumulativa de casos de Síndrome Gripal de um bairro.

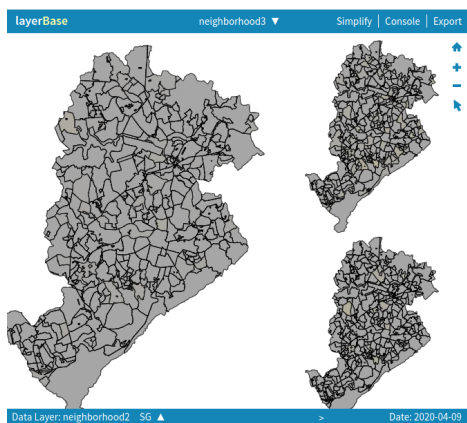
**SRAG** Quantidade cumulativa de casos de Síndrome Respiratória Aguda Grave de um bairro.

**OB** Quantidade cumulativa de casos de Óbitos de um bairro.

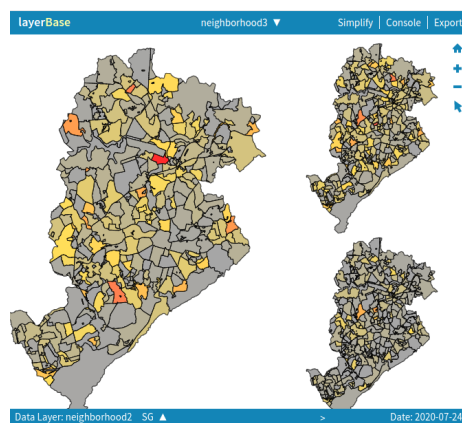
Além da camada de dados temporais, foi utilizado uma camada de dados estáticos, o perímetro urbano de Belo Horizonte segregado por bairros. Portanto, para o estudo de caso foram utilizados essas duas camadas.

## 4.2. Geo-Visualização Temporal

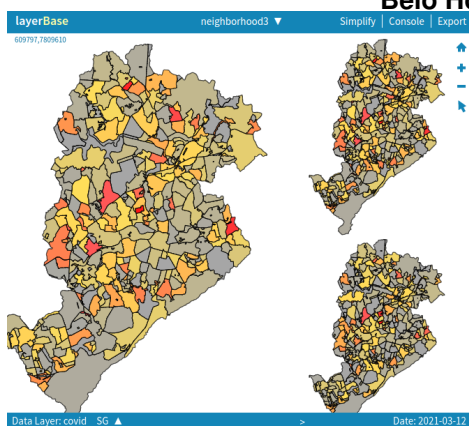
Feito o processo de importação dos dados coletados no LayerBase, a camada com o espaço urbano foi duplicada mais duas vezes, totalizando três, para representar simultaneamente os três cenários, utilizando o comando *duplicate*, conforme visto na Figura 6. Em sequência, foi disparado a função *temporal* para cada cenário, assim possibilitando a visualização simultânea dos casos ao longo do tempo. As Figuras 6, 7 e 8 representam a visualização temporal dos casos de COVID-19 em Belo Horizonte, por um mapa de calor. A variação de amarelo até vermelho indicam a concentração de casos nos bairros e a data referente a época está demarcada no canto inferior direito das três figuras, sendo a Figura 6 representando o primeiro dia, a Figura 7 ilustrando um dia intermediário do período e a Figura 8, o estado final.



**Figura 6. Estado inicial da visualização dos casos em Belo Horizonte**



**Figura 7. Estado intermediário da visualização dos casos em Belo Horizonte**




**Figura 8. Estado final da visualização dos casos em Belo Horizonte**

## 5. Resultados

Após o uso do LayerBase sobre os dados da COVID-19 em Belo Horizonte, foi possível extrair padrões anteriormente não reparados. O ponto de partida foi a percepção que diferentes bairros possuíam densidades de casos parecidas entre a série temporal, como pode ser visto na Figura 9. Além disso, um mesmo bairro não está, necessariamente, com a mesma densidade de casos nos três cenários analisados. O bairro Havaí, por exemplo, está com densidades diferentes para cada cenário, como pode ser notado na Figura 10.

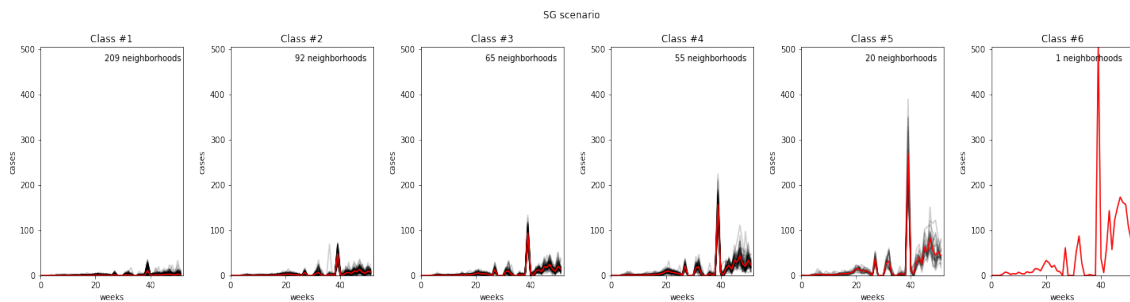


**Figura 9. Visualização de seis bairros vizinhos com diversas densidades de casos de OB**

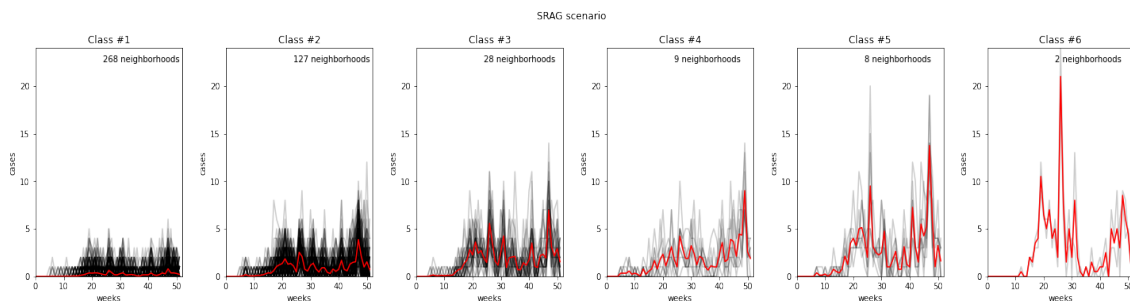


**Figura 10. Visualização do bairro Havai para os cenários SG, SRAG e OB, respectivamente**

Postulado essas percepções, foram realizados agrupamentos dos bairros utilizando o algoritmo *k-means* para cada um dos cenários da pandemia. Portanto, permitindo a identificação de grupos e mobilidade dos bairros entre os grupos durante a série temporal. Após testes e interpretações dos grupos, o *k* utilizado foi de 6, portanto, os bairros se dividiram em seis grupos. Além disso, a série temporal foi agrupada por intervalos de semanas, totalizando 57 semanas, devido à natureza da doença que tem ciclos de sintomas e transmissão baseado em semanas [Aleta et al. 2020, Ro et al. 2020]. Foi utilizado a implementação do algoritmo do pacote Tslern para gerar vários conjuntos de agrupamento séries temporais para cada cenário da pandemia em Belo Horizonte.

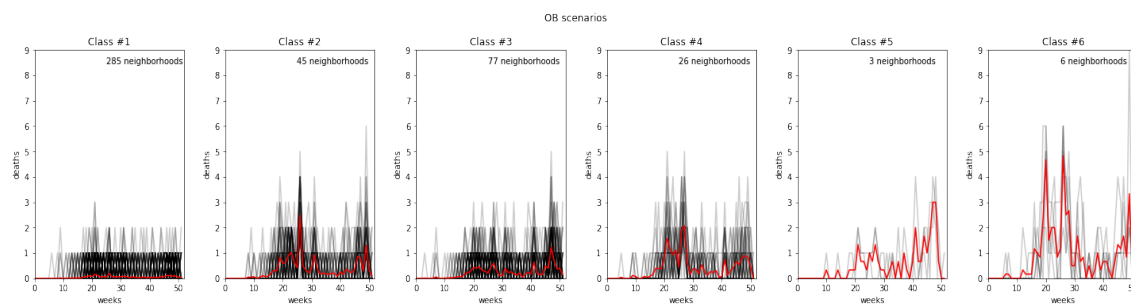


**Figura 11. Bairros de Belo Horizonte agrupados por casos de SG**



**Figura 12. Bairros de Belo Horizonte agrupados por casos de SRAG**

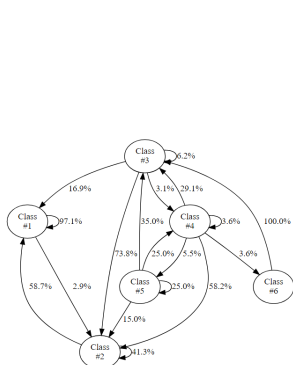
As Figuras 11, 12 e 13 apresentam todos os três cenários, em quais o eixo y representa as ocorrências de casos de COVID-19 analisadas, o eixo x demarca o tempo, em semanas, a linha vermelha representa os centroides de cada grupo. Em todos os cenários, a Classe #1 contém a maior quantidade de bairros, apesar de representar a maior quantidade




**Figura 13. Bairros de Belo Horizonte agrupados por casos de OB**

de casos. A Classe #6 tem os bairros *outliers*, que são onde tiveram a maior incidência de casos, inclusive, demarcado por um pico, de mais de 500 ocorrências, próximo da semana 40, denotando o ápice da pandemia em Belo Horizonte durante o período avaliado.

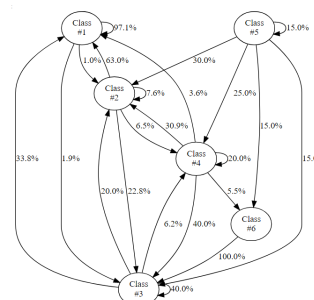
Além do que é retratado na Figura 10, existe a mobilidade dos bairros entre os 6 grupos durante a série temporal. Ou seja, com o passar do tempo, um determinado bairro pode ter sua situação agravada ou suavizada, em relação a números de casos, por cenário. As Figuras 14, 15 e 16 retratam as porcentagens relativas de um bairro de uma classe se mover para outra classe baseando-se na série temporal.



**Figura 14. Casos SG para SRAG**



**Figura 15. Casos SRAG para OB**



**Figura 16. Casos SG para OB**

Nas Figuras 14, 15 e 16, todos os bairros da Classe #1 têm altas probabilidades de se manterem na mesma classe. Todavia, das três possíveis mobilidades apresentadas, as chances de evolução de um bairro para o pior caso, demarcado pela movimentação para a Classe #6, são inferiores do que a chance de um bairro abandonar a Classe #6. Em outras palavras, é mais provável que a situação de um bairro não evolua para o pior caso, e sim, que um bairro no pior caso amenize suas ocorrências.

## 6. Conclusões

Este estudo apresenta a possibilidade de representações espaço-temporais compostas por várias camadas em uma ferramenta, o LayerBase. Aplicação que permite a combinação de informações estáticas e dinâmicas para elaboração de análises mais completas para diversos problemas. Sendo apresentado pela utilização do LayerBase para análise de dados de nove meses da pandemia de COVID-19 em Belo Horizonte gerando percepções que foram exploradas mais a fundo na sequência.

## 7. Trabalhos Futuros

O LayerBase é uma nova ferramenta de geo-visualização que possui várias possibilidades de crescimento. Nesta Seção é explorado algumas funcionalidades que podem ser desenvolvidas e acrescentadas ao LayerBase que a projeção é de possuir um robusto ferramental para tarefas de cunho espaço-temporais em um ambiente *web* de simples utilização. Consequentemente, ao passo que foi sendo desenvolvido a funcionalidade de mapa de calor para função *temporal*, a necessidade de outras visualizações foram aparecendo, como a clusterização, rastreamento e monitoramento. A seguir estão as próximas funcionalidades pensadas para o LayerBase:

**Clusterização.** Como foi utilizado o Tslern para clusterização, uma integração dessa funcionalidade é interessante para análises estáticas e temporais.

**Monitoramento.** Uma função para acompanhar a mudança de valor de um atributo ao longo do tempo. Essa funcionalidade poderá ser combinada com outras, como a *colorizer*, por exemplo.

**Rastreamento.** Uma função para acompanhar deslocamentos geográficos de um atributo através de diversos *polygons*. Servindo para destacar rotas e caminhos ou realizar rastreio de contatos.

## Agradecimentos

Este trabalho foi desenvolvido com o apoio da Fapemig (PPM-XII).

## Referências

- Aleta, A., Martín-Corral, D., Pastore y Piontti, A., Ajelli, M., Litvinova, M., Chinazzi, M., Dean, N. E., Halloran, M. E., Longini Jr, I. M., Merler, S., Pentland, A., Vespignani, A., Moro, E., and Moreno, Y. (2020). Modelling the impact of testing, contact tracing and household quarantine on second waves of covid-19. *Nature Human Behaviour*, 4(9):964–971.
- Auer, S., Bizer, C., Kobilarov, G., Lehmann, J., Cyganiak, R., and Ives, Z. (2007). Dbpedia: A nucleus for a web of open data. In Aberer, K., Choi, K.-S., Noy, N., Allemang, D., Lee, K.-I., Nixon, L., Golbeck, J., Mika, P., Maynard, D., Mizoguchi, R., Schreiber, G., and Cudré-Mauroux, P., editors, *The Semantic Web*, pages 722–735, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Carvalho, A., Morais, E. P., and Cunha, C. R. (2018). Location based mobile services & Context-aware: An approach to the tourism sector. *Proceedings of the 32nd International Business Information Management Association Conference, IBIMA 2018 - Vision 2020: Sustainable Economic Development and Application of Innovation Management from Regional expansion to Global Growth*, pages 6828–6836.
- Desai, B. C. (2020). Pandemic and big tech. In *Proceedings of the 24th Symposium on International Database Engineering & Applications, IDEAS '20*, New York, NY, USA. Association for Computing Machinery.
- Elwood, S. (2009). Geographic information science: new geovisualization technologies — emerging questions and linkages with giscience research. *Progress in Human Geography*, 33(2):256–263.

- Harrower, M. and Bloch, M. (2006). Mapshaper.org: A map generalization web service. *IEEE computer graphics and applications*, 26:22–7.
- Huang, J., Wang, H., Fan, M., Zhuo, A., Sun, Y., and Li, Y. (2020). Understanding the impact of the covid-19 pandemic on transportation-related behaviors with human mobility data. In *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, KDD '20*, page 3443–3450, New York, NY, USA. Association for Computing Machinery.
- Lai, S. H. S., Tang, C. Q. Y., Kurup, A., and Thevendran, G. (2020). The experience of contact tracing in singapore in the control of covid-19: highlighting the use of digital technology. *International Orthopaedics*.
- Lobo, M.-J., Appert, C., and Pietriga, E. (2017). Mapmosaic: dynamic layer compositing for interactive geovisualization. *International Journal of Geographical Information Science*, 31(9):1818 – 1845.
- Ramos, L. F. M. (2020). Evaluating privacy during the covid-19 public health emergency: The case of facial recognition technologies. In *Proceedings of the 13th International Conference on Theory and Practice of Electronic Governance, ICEGOV 2020*, page 176–179, New York, NY, USA. Association for Computing Machinery.
- Ro, J. W., Allen, N., Ai, W., Prasad, D., and Roop, P. S. (2020). Compositional cyber-physical epidemiology of covid-19. *Scientific Reports*, 10(1):19537.
- Saran, S., Singh, P., Kumar, V., and Chauhan, P. (2020). Review of geospatial technology for infectious disease surveillance: Use case on covid-19. *Journal of the Indian Society of Remote Sensing*, 48(8):1121–1138.
- Silveira, L. M., Almeida, J. M., Marques-Neto, H., and Ziviani, A. (2015). MobDatU: A New Model for Human Mobility Prediction Based on Heterogeneous Data. *Proceedings - 33rd Brazilian Symposium on Computer Networks and Distributed Systems, SBRC 2015*, pages 217–227.
- Sonkin, R., Alpert, E. A., and Jaffe, E. (2020). Epidemic investigations within an arm’s reach – role of google maps during an epidemic outbreak. *Health and Technology*, 10(6):1397–1402.
- Vannoni, M., McKee, M., Semenza, J. C., Bonell, C., and Stuckler, D. (2020). Using volunteered geographic information to assess mobility in the early phases of the covid-19 pandemic: a cross-city time series analysis of 41 cities in 22 countries from march 2nd to 26th 2020. *Globalization and Health*, 16(1):85.
- Varlamis, I., Sardianos, C., Bogorny, V., Alvares, L. O., Carvalho, J. T., Renso, C., Perego, R., and Violos, J. (2021). A novel similarity measure for multiple aspect trajectory clustering. In *Proceedings of the 36th Annual ACM Symposium on Applied Computing, SAC '21*, page 551–558, New York, NY, USA. Association for Computing Machinery.
- Xavier, W. Z., Xavier, F. H. Z., and Marques-Neto, H. T. (2017). Visualizing and analyzing georeferenced workloads of mobile networks. In *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pages 306–310.