

Sweet Home: Uma ferramenta de visualização de dados focada no mercado imobiliário

José Rodolfo de Lima Farias, Nivan Ferreira

¹Centro de informática – Universidade Federal de Pernambuco (UFPE)
Recife – PE – Brazil

jrlf@cin.ufpe.br, nivan@cin.ufpe.br

Abstract. *The process of choosing a place to live is a complex one, whose many criteria must be taken into consideration before a final decision. Besides the property's characteristics, like the number of bedrooms, its size, and its price, the urban context the property is located in is also very relevant. For instance, recreation and entertainment availability, cultural activities, safety, healthy environment, transportation and accessibility are very important aspects to be contemplated. Despite its importance, modern search tools, as OLX, ZapImoveis and Viva Real, ignore or only partly consider such relevant aspects. In order to solve this problem, we propose Sweet Home an interactive visualization tool whose goal is to support data exploration of real estate offers along with its urban context. In order to do so, our tool integrates several urban datasets together with real estate offers data. It is possible to analyse socio-economical values of any areas in the city, as well as their relation to the properties for sale, through the usage of visualization techniques. We demonstrate the efficiency of the Sweet Home through a series of case studies that prove its capability during the process of choosing a property to live.*

Resumo. *O processo de escolha de um imóvel para moradia é complexo e vários critérios são considerados. Além de características do imóvel, como número de quartos, tamanho e preço, uma grande importância é dada para fatores relacionados ao contexto urbano no qual o imóvel está inserido. Por exemplo, fatores como disponibilidade de lazer, atividades culturais, segurança, saúde, transporte e acessibilidade são relevantes na escolha de um imóvel. Apesar disso, as ferramentas atuais como OLX, ZapImoveis e VivaReal ignoram ou, nos melhores casos, só consideram parcialmente tais fatores. Para resolver este problema, neste artigo é proposto o Sweet Home, uma ferramenta interativa para a exploração de dados de ofertas imobiliárias complementadas com dados sobre o contexto urbano. Para este fim, nossa ferramenta integra diversas coleções de dados urbanos e ofertas imobiliárias a técnicas de visualização para explorar esta complexa coleção de dados. Através do uso das técnicas de visualização é possível analisar valores socio-econômicos das áreas de interesse na cidade, bem como sua relação com os imóveis a venda. Nós demonstramos a eficiência do Sweet Home por meio de uma série de estudos de caso que mostram o poder do Sweet Home no processo de procura de imóveis.*

1. Introdução

O mercado imobiliário movimentava 325 bilhões de reais por ano, o que equivale a 6,4% do PIB brasileiro. Mesmo com o mercado em crise o número de imóveis para venda ou locação

se mantém em crescimento. De fato, nos 7 primeiros meses de 2016, foram lançados 33.975 novas unidades imobiliárias, número 13,8% superior ao observado nos primeiros 7 meses de 2015¹. Dada a grande popularidade deste mercado, foi criado um grande número de aplicações de venda de imóveis. Exemplos de tais aplicações são OLX², ZapImoveis³ e VivaReal⁴. Uma característica comum a esse tipo de ferramenta é o fato de que elas se concentram em explorar informações do imóvel em si (quantidade de quartos, banheiros, área). Entretanto, existem muitos outros fatores envolvidos no processo de escolha de uma moradia ou compra de imóvel. Em particular, são de extrema importância fatores ligados ao contexto urbano no qual o imóvel está inserido como: segurança, lazer, cultura, transporte, diversidade populacional, presença de áreas verdes, dentre outros, [Silva 2009, Ferreira et al. 2015, DeSimone 2017] cruciais para a escolha de onde morar. Apesar da relevância, as ferramentas atuais como ZapImoveis ou VivaReal ignoram ou, nos melhores casos, só consideram parcialmente tais fatores. Dada a iniciativa global de abertura de dados urbanos, existe uma grande oportunidade para melhor dar suporte a decisão na escolha de imóveis para moradia. Este suporte se dará por um melhor entendimento da cidade, através do uso de dados que descrevem múltiplos aspectos da cidade em estudo. Existem diversas aplicações focadas em visualizar conjuntos de dados urbanos isoladamente. Por exemplo, TaxiVis [Ferreira et al. 2013] o qual foca na visualização de dados de transporte, enquanto que o trabalho de Janetzko et al. [Janetzko et al. 2014] foca na exploração de dados de consumo de energia. Entretanto, poucos sistemas concentram-se em visualizar os vários componentes de uma cidade e suas interações. Exemplos destes sistemas são Urbane [Ferreira et al. 2015] e Legible Cities [Chang et al. 2007]. Entretanto, nenhum deles foca no domínio de imóveis.

2. Análise e tratamento dos dados

A fim de analisar e dar um melhor suporte à tomada de decisão na compra de imóveis, Sweet Home integra dois tipos de dados: os referentes a anúncio de imóveis, descritos na seção 2.1, e dados de características externas, ou seja do ambiente urbano no qual os imóveis estão inseridos, descritos na seção 2.2.

2.1. Dataset de Anúncios de Imóveis

Como fonte de dados para informações de características e preços de imóveis, foi usado um conjunto de dados obtido a partir de um *webscraper* no site ZapImoveis. *Webscraper* é uma ferramenta com finalidade de extrair data a partir de um site *HyperText Markup Language* (HTML). O *webscraper* foi desenvolvido pelo usuário do github pauloromeira⁵. O mesmo disponibilizou de forma aberta e gratuita os dados em uma plataforma de compartilhamento chamada data.world.⁶ Tal base de dados é relevante, haja vista que o ZapImoveis é um site consolidado no mercado. Fundado em 2000 e adquirido pelo grupo Globo em 2001⁷, o Zap Imóveis veio a se tornar líder no mercado imobiliário em 2005 e desde então se mantém na liderança. O conjunto de dados utilizado se baseia em anúncios

¹Notícia no portal G1. Link: <https://goo.gl/f14B7b>

²<http://www.olx.com.br/imoveis>

³<https://www.zapimoveis.com.br/>

⁴<https://www.vivareal.com.br/>

⁵<https://github.com/pauloromeira/realstate-scraper>

⁶<https://data.world/pauloromeira/anuncios-de-imoveis-recife-pe>

⁷https://pt.wikipedia.org/wiki/Zap_Imóveis

na cidade do Recife contendo 7203 entidades. Cada uma delas contém título (nome do imóvel), preço, tipo (residencial ou comercial, rua, bairro, CEP, latitude, longitude, tipo vendedor (pessoa física ou imobiliária), número de quartos, número de suítes, área útil, área total, número de vagas, taxa condomínio, IPTU, e data da coleta dos dados. Como todo processo automático para coleta de dados, o webscraper descrito acima gerou dados com problemas de qualidade. Para resolver este problema, aplicamos alguns processos de limpeza de dados. A primeira filtragem foi remover instâncias que tinham valores nulos (faltando) para atributos que julgamos fundamentais para nossa análise. Os atributos fundamentais escolhidos foram: Título, número de quartos, preço, área útil, número de vagas, taxa condomínio, latitude e longitude. A segunda filtragem se deu em remover todos os estabelecimentos comerciais, pois o foco de nosso trabalho é dar suporte na escolha de imóveis residenciais. Em um terceiro passo, realizamos um processo de limpeza de acordo com as coordenadas geográficas. Imóveis cuja localização se encontrava fora de um retângulo em volta da cidade do Recife foram removidos da base de dados. Finalmente, uma filtragem em imóveis que seus valores para os atributos fundamentais eram maiores que 95 % do atributos. Essa filtragem foi necessária por que alguns imóveis estavam com valores claramente errados nos atributos fundamentais. Ao fim da aplicação de todos os filtros citados anteriormente, o *dataset* de imóveis apresentou 2642 entidades.

2.2. Dataset de Características Urbanas

A fim de dar melhor suporte ao processo de decisão na compra de imóveis, é necessário ser capaz de comparar imóveis de acordo com características externas na qual o imóvel está localizado. Para tanto precisamos de uma fonte de dados que contenha a localização de várias *commodities urbanas* para diversas áreas em uma cidade de interesse. Para este fim foi selecionado o *OpenStreetMaps* (OSM) [Haklay and Weber 2008], que é um projeto de geolocalização baseado em *crowdsourcing*. Este projeto tem como principal objetivo manter e disponibilizar de forma gratuita dados espaciais e uma infraestrutura para mapeamento destes dados. Assim como outros projetos *crowdsourced*, os dados contidos no *Open Street Maps* (OSM) são oriundos de contribuições voluntárias e devem respeitar *Open Database License* (ODbL). O ODbL define o uso, modificação e o compartilhamento livre desses dados desde que essa mesma liberdade seja repassada à quem usar sua plataforma. Logo toda informação contida no OSM é livre e gratuita. Outro ponto que chamou atenção no OSM, além da gratuidade, o número elevado de contribuições. O número total de contribuintes ultrapassa quatro milhões, já o número total de objetos geográficos se aproxima de quatro bilhões⁸.

A aquisição dos dados do OSM foi via uma *Application program interface* (API) chamada *Overpass*⁹. A *Overpass* API funciona a base de *queries* de pesquisa, ou seja uma *query* é enviada ao servidor e se obtém uma resposta. Essa resposta pode ser de vários formatos, mas por questão de facilidade optou-se por manter o padrão que é *GeoJson*. *GeoJson* é um formato de dados semelhante a *JavaScript Object Notation* (JSON), porém com a peculiaridade de uma tag especificamente para geoposicionamento contendo latitude e longitude. Os dados do OSM são categorizados pela união de elementos e tags. Os elementos são organizados em:

⁸http://www.openstreetmap.org/stats/data_stats.html

⁹<http://overpass-api.de/>

- *Nodes* são localizações pontuais no mapa, esses pontos podem ser isolados ou conectados. Cada *node* apresenta latitude, longitude, identificador e um conjunto de tags. A função de cada tag será explicada posteriormente;
- *Ways* são criados a partir de ligações entre os *nodes*, podendo dar origem a rotas ou rios por exemplo;
- *Closed ways* são criados a partir de um *loop* de *ways*, por exemplo uma *area* ou barreiras;
- *Areas* são também formados a partir de *ways*, mas obrigatoriamente possuem a tag *area* com o valor positivo;
- *Relation* são usados para criar formas geométricas mais complexas, ou expressar relacionamento entre os elementos citados anteriormente sem a necessidade de uma ligação física entre eles;
- *Tags* são propriedades referentes ao elemento vinculado, por exemplo um *node* restaurante contém a tag com identificador *amenity* igual a *restaurant*.

Classificamos os dados de características urbanas em seis classes: Educação, Entretenimento, Financeiro, Saúde, Alimentação e Transporte. Para cada uma das classes, usamos a API Overpass para acessar elementos geográficos do OSM associados a cada uma delas. Em mais detalhes, para cada classe temos uma *query* :

- Educação foi buscado *nodes* com a tag *amenity* igual a colégios, universidades, escola de idiomas e outros locais ligados diretamente a estudo;
- Entretenimento foi buscado *nodes* com as tag *amenity* ou tag *leisure* igual a centro de artes, cinema, teatros e outros locais vinculados a diversão ou entretenimento;
- Financeiro foi buscado *nodes* com a tag *amenity* igual a caixa eletrônico, bancos ou casa de câmbio;
- Saúde foi buscado *nodes* com a tag *amenity* igual a clínicas, hospitais, farmácias e outros locais relacionados diretamente a saúde;
- Alimentação foi buscado *nodes* com a tag *amenity* igual a restaurantes, cafés, bares e outros locais vinculados a alimentação;
- Transporte foi buscado *nodes* com a tag *amenity* ou tag *leisure* igual parada de ônibus, táxi, metrô e outros locais relacionados a transporte;

Já em relação as *tags* foram utilizadas as seguintes *keys*: *Area* que define a área dos *nodes*, que no caso específico desse trabalho são *nodes* com valor de *area* igual a Recife; *Amenity*, *nodes* que contém essa tag são referentes a locais de uso público ou de interesse comum. *Leisure*, *nodes* que contém *leisure* como tag são referentes a locais de entretenimento. *Highway* foi utilizado pois contém as paradas de ônibus. Cada *query* dará origem a um sub conjunto de dados que será usado para criar escores de proximidade para a classe dado um imóvel ou uma localidade como veremos na próxima seção.

2.3. Integração dos Dados

A fim de poder comparar imóveis de acordo com as características urbanas de seu entorno, usamos as queries definidas na seção anterior para definir escores para cada uma das classes Educação, Entretenimento, Financeiro, Saúde, Alimentação e Transporte. Isto foi feito adicionando seis atributos ao *dataset* de imóveis. Cada escore foi calculado em relação a quão próximo um imóvel (ou localidade) está de elementos geográficos associados a cada classe. Para tanto, para cada classe e cada imóvel, foram filtrados todos os elementos do

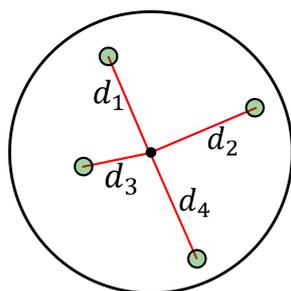


Figura 1. Computação dos escores de características urbanas. Os elementos de cada categoria dentro de um raio dado (1 km) são utilizados para computar o escore correspondente à categoria.

OSM dentro de um raio de 1 Km. Para cada um dos elementos resultantes foi calculada a distância para o imóvel e estas foram agregadas de acordo com a fórmula abaixo:

$$E = \sum_x \frac{r - d_x}{r},$$

onde $r = 1km$ e d_x representa a distância do imóvel ao elemento x . A Figura 1 ilustra este processo. Para este exemplo existem quatro elementos (pontos verdes) próximos ao ponto de interesse (ponto preto). Neste caso, o escore é dado por:

$$E = \frac{r - d_1}{r} + \frac{r - d_2}{r} + \frac{r - d_3}{r} + \frac{r - d_4}{r}$$

Como resultado desse processo foi obtido um *dataset* com 2642 entidades e com valores concretos para título, quartos, preço, área útil, vagas, taxa condomínio, educação, entretenimento, financeiro, saúde, alimentação e transporte.

3. Sweet Home

Esta seção apresenta o design do Sweet Home. Este processo de design se deu de forma iterativa e incremental, no qual tarefas analíticas foram elicitadas (Seção 3.1) e estas foram usadas na escolha das visualizações e iterações implementadas no sistema.

3.1. Tarefas Analíticas

Partindo da premissa que a principal característica do Sweet Home é o entendimento do imóvel em relação a suas características externas, o sistema Sweet Home foi desenvolvido para suportar as seguintes tarefas analíticas:

- (T1) Conhecer a cidade a partir da identificação das características externas do imóvel.
- (T2) Possibilitar a identificação de imóveis com preço abaixo do valor em relação aos valores das demais variáveis;
- (T3) Entender como as variáveis do ambiente influenciam o preço da residência;
- (T4) Possibilitar a manipulação de filtros, a fim de possibilitar tanto filtros ligados as características internas quando características externas.

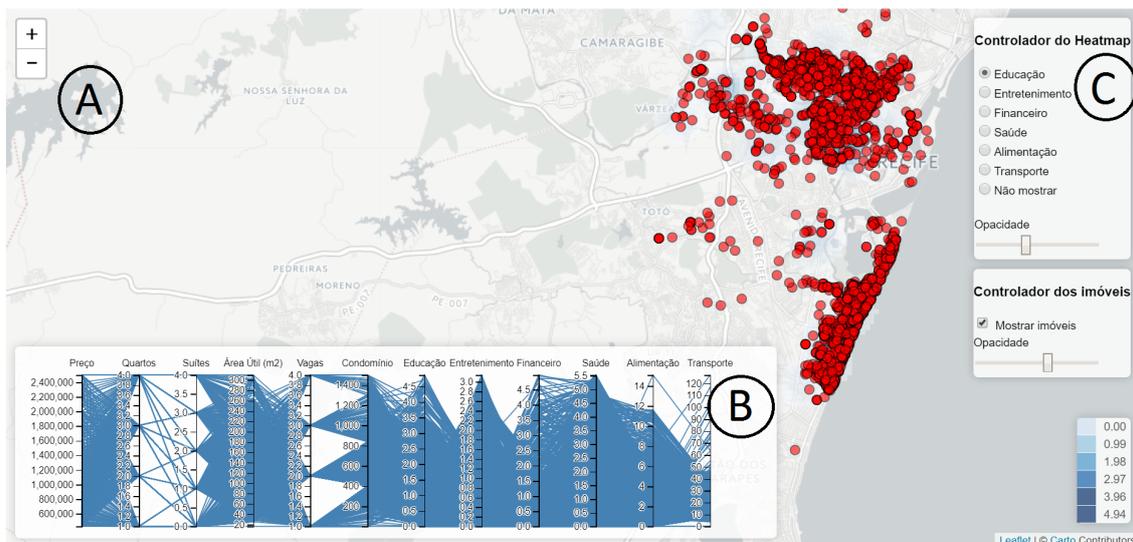


Figura 2. Interface do Sweet Home é composta por 3 componentes: a vista geográfica (A), a vista de atributos dos imóveis (B) e o painel controles do sistema (C).

3.2. Sweet Home

Nesta seção é descrito o design do Sweet Home para suportar as tarefas analíticas descritas na seção anterior. A Figura 2 apresenta a interface do sistema. Esta interface é formada por três componentes principais: a vista geográfica, a vista de atributos de imóveis e um painel de controles. Estes componentes são descritos em detalhes neste capítulo.

3.2.1. Vista Geográfica

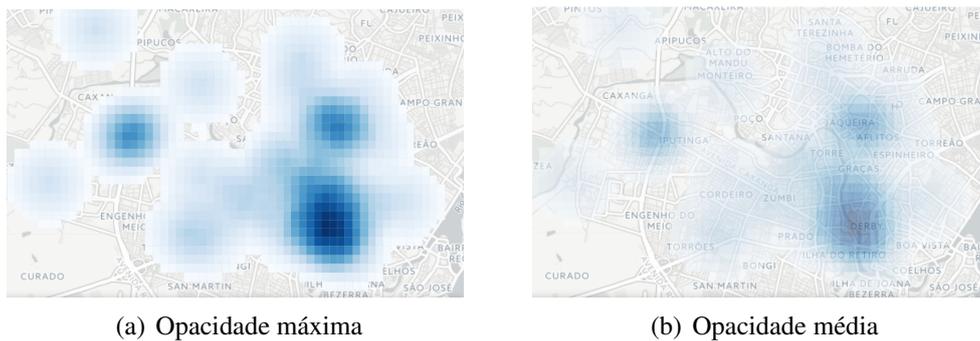
O componente de visão geográfica é constituído de um mapa que mostra os aspectos espaciais dos dados, possibilitando ver os imóveis presentes no conjunto de dados de anúncios e as características externas dos imóveis por meio de *heatmaps*. Os imóveis são apresentados como círculos sobre o mapa. A fim de ver detalhes sobre cada imóvel, ao passar o mouse por cima do círculo correspondente, um *tooltip* é apresentado com os seus atributos. Para suportar a tarefa analítica T1 foi necessária a criação de *heatmaps*. Os *heatmaps* são apresentados em uma escala de cores sequencial obtida do ColorBrewer [Brewer and Harrower 2017] (canto direito inferior da Figura 2). Com as informações da base de dados recolhidas do OSM, foi criado então um *grid*, de área retangular, sobre a cidade do Recife. O *grid* apresenta 10000 células, onde cada célula tem altura de aproximadamente 250 metros e largura de 180 metros. O tamanho da célula foi determinado empiricamente para satisfazer critérios de desempenho computacional e precisão geográfica. Cada célula é colorida com uma intensidade de cor referente ao valor da célula. A função utilizada corresponde a mesma função citada na seção 2.1. O valor se refere à quantidade de itens que estão na área de um quilômetro de raio do centro da célula, com uma função de decaimento linear baseado na proximidade com o centro da célula. O valor da célula é pre-calculado e colocado em uma estrutura de dados, para então quando a página for carregada, o *web browser* irá colorir a célula com a cor referente ao valor anteriormente calculado na estrutura de dados. Se a célula não tem valor, a mesma não será

colorida, ou seja não aparecerá no mapa. No controle do *heatmap*, existem seis opções de *heatmap* ou a opção de não mostrar o mesmo. Então para cada *heatmap* selecionado, o javascript irá remover e colorir novamente a célula com o novo valor referente ao seu centro. A fim de se adaptar a necessidades específicas, é possível mudar a opacidade do *heatmap*. No canto inferior direito, existe uma legenda para cada intensidade de cor no *heatmap*, a mesma se modifica de acordo com a seção escolhida. A implementação do mapa foi feita utilizando a biblioteca *Leaflet.js*, direcionada à construção de aplicações *web* com mapas interativos. Além de proporcionar as interações de *pan* e *zoom* [You et al. 2007], a biblioteca proporciona funções para a composição de mapas interativos através da definição de camadas de informações geográficas indicando as coordenadas (latitue e longitude) de objetos a serem visualizados.

3.2.2. Vista de Atributos dos Imóveis

Para solucionar as tarefas analíticas T2, T3 e T4 foi necessária a criação de um gráfico de coordenadas paralelas [Inselberg and Dimsdale 1990]. Este gráfico é uma técnica de visualização de dados multi-dimensionais tradicional e bastante poderosa. Nele dimensões, atributos dos imóveis, são representadas por linhas verticais paralelas e cada ponto multi-dimensional (imóvel) é representado por uma linha poligonal ligando as coordenadas correspondentes. Interações de *brushing* podem ser utilizadas para selecionar pontos nesta visualização. Além disso, correlações podem ser investigadas por inspeção do padrão visual das linhas entre eixos consecutivos. No Sweet Home, o gráfico apresenta doze dimensões (Figura 2 (B)) representando tanto atributos do imóvel quanto atributos do entorno urbano:

- Preço, valor anunciado do imóvel;
- Quartos, número de quartos do imóvel;
- Suítes, número de suítes do imóvel;
- Área útil, valor de área do imóvel em metros quadrados;
- Vagas, número de vagas na garagem;
- Condomínio, valor da taxa de condomínio em reais;
- Educação, valor referente ao retorno da função de proximidade com as escolas, universidades, jardim de infância e etc;
- Entretenimento, valor referente ao retorno da função de proximidade com os cinemas, teatros, centro de artes e etc;
- Financeiro, valor referente ao retorno da função de proximidade com os caixas eletrônicos, bancos e casas de câmbio;
- Saúde, valor referente ao retorno da função de proximidade com os hospitais, clínicas, farmácias e etc;
- Alimentação, valor referente ao retorno da função de proximidade com os bares, restaurantes, cafés e etc;
- Transporte, valor referente ao retorno da função de proximidade com as paradas de ônibus, paradas de metro, posto de combustível e etc.



(a) Opacidade máxima

(b) Opacidade média

Figura 3. Uso de opacidade nos heat maps. Note que, usando níveis de opacidade, é possível explorar o rate de interesse sem perder o contexto geográfico.

3.2.3. Painel de Controles

O painel de controle é composto por dois controladores, um para os imóveis e o outro para os *heatmaps*. No controlador dos imóveis é possível remover os círculos do mapa, ou alterar a opacidade do mesmo, com o intuito de atender a necessidades específicas. Já no controlador do *heatmap*, existem seis opções de *heatmap* ou a opção de não mostrar o mesmo. Cada opção de visualização do *heatmap* está ligado a uma categoria citada no na Seção 2.2. Então para cada *heatmap* selecionado, o sistema irá atualizar a visualização de acordo com a escolha do usuário. Além disso, é possível ajustar a opacidade do heatmap para ser possível ver o mapa renderizado abaixo da camada do *heatmap*.

4. Casos de uso

Esta seção demonstra a utilidade do Sweet Home através de uma série de casos de uso, demonstrando o poder e a versatilidade do sistema em objetivos desde a limpeza de dados até a identificação de padrões.

4.1. Detectando Erros nos Dados

Através das ferramentas de visualização do Sweet Home é possível encontrar erros e inconsistências nos dados. Como um primeiro exemplo disso, somente observando a distribuição geográfica dos imóveis é possível ver que no processo de mineração usados para extrair os dados de imóveis em Recife é possível ver que foram minerados imóveis em outras localidades ou até mesmo com latitude e longitude incoerentes, conforme Figura 4. Analogamente, inspecionando os atributos dos imóveis através do gráfico de coordenadas paralelas também é possível encontrar problemas nos dados. Vemos que em todas as coordenadas do conjunto de dados de anúncio (Preço, Quartos, Suítes, Área Útil, Vagas e Condomínio) existem problemas. Por exemplo, imóveis com área útil de 20000 metros quadrados ou com taxa de condomínio de mais de 3 milhões de reais. Estes erros foram a motivação para o processo de limpeza de dados descrito na Seção 2.1. Em qualquer processo automático de curagem de dados (como o descrito acima), ainda é possível que existam instâncias de dados inconsistentes Com o uso do gráfico de coordenadas paralelas é possível filtrar os dados de forma rápida, ganhando facilidade na hora de identificar possível erros ou incoerências nos dados. Por exemplo, as figuras 6 e 7 mostram como foi possível identificar incoerências na base de dados. Selecionando um vértice do gráfico



Figura 4. Incoerências geográficas.

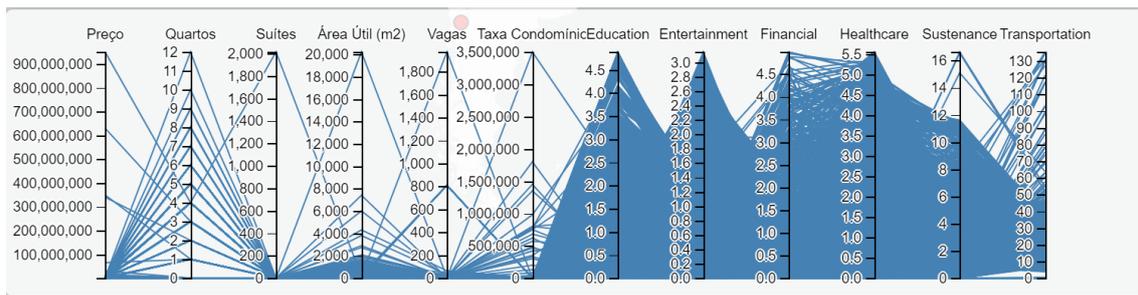


Figura 5. Incoerências nos valores dos atributos.

é de esperar um número condizente com esse vértice, como por exemplo área útil está diretamente ligada ao número de quartos. No exemplo da Figura 6 foram selecionados apartamentos com área útil entre 16 e 40 metros quadrados. A linha em evidência mostra que na nossa base existe um apartamento com 3 quartos e área útil de 16 metros quadrados, o que provavelmente é um erro.

4.2. Entendendo a Cidade

O Sweet Home possibilita um maior entendimento da cidade. Como por exemplo, através dos *heatmaps* é possível conhecer a cidade e suas regiões. Na Figura 8 é possível identificar o centro da cidade por meio da maior intensidade de transporte do mesmo. Outra inferência que é possível fazer ocorre na forma do *heatmap* financeiro 8. Analisando o *heatmap* financeiro 8 é possível identificar áreas com maior movimentação financeira ou de maior comércio. É natural o surgimento de bancos ou caixas eletrônicos em áreas de maior movimentação monetária. Com a união de *heatmaps* é possível extrair informações mais complexas. Um exemplo é na observação de que transporte, financeiro e alimentação aparecem de forma mais intensa no centro da cidade. Pois o centro é onde se acumula o

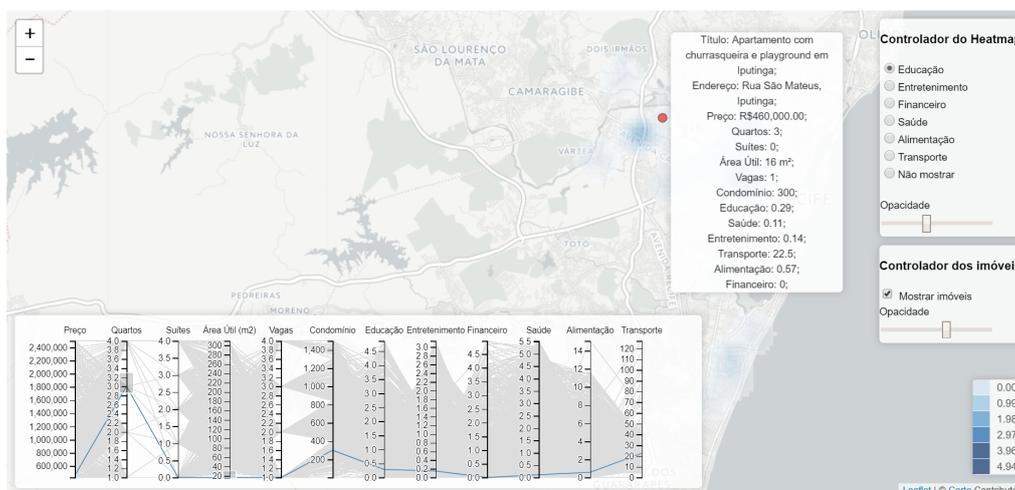


Figura 6. Exemplo de apartamento de 60 metros quadrados com 7 quartos

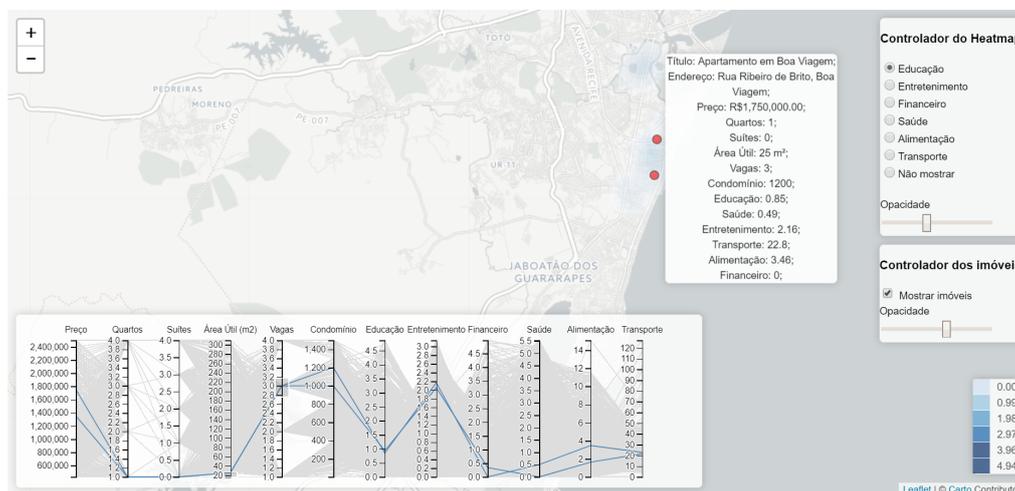


Figura 7. Exemplo de apartamento de 25 metros quadrados com 1 quarto e 3 vagas na garagem

maior número de trabalhadores diários, logo é natural o aparecimento de restaurantes para suprir a demanda alimentícia. Já em outras áreas com muito entretenimento e alimentação mediana dar-se a entender que são locais mais focados em finais de semanas, e não para o dia-a-dia. Outra forma de conhecer a cidade é por meio dos imóveis. Tipicamente cada cidade tem suas áreas mais "nobres", as quais não necessariamente estão ligadas a proximidade com características externas, mas sim ligadas a uma convenção social que agrega aquela área um maior valor econômico.

4.3. Buscando Imóveis

Essa seção será dedicada a mostrar exemplos de buscas relacionadas na escolha do imóvel.

A Figura 9 exemplifica uma busca por valores referentes a estrutura do imóvel, como por exemplo número de vagas, quartos, suítes e quartos. Nesse tipo de busca, o usuário deseja localizar um imóvel de acordo com suas características internas, desprezando as características externas. Possibilitando ao usuário buscar da mesma forma que os outros

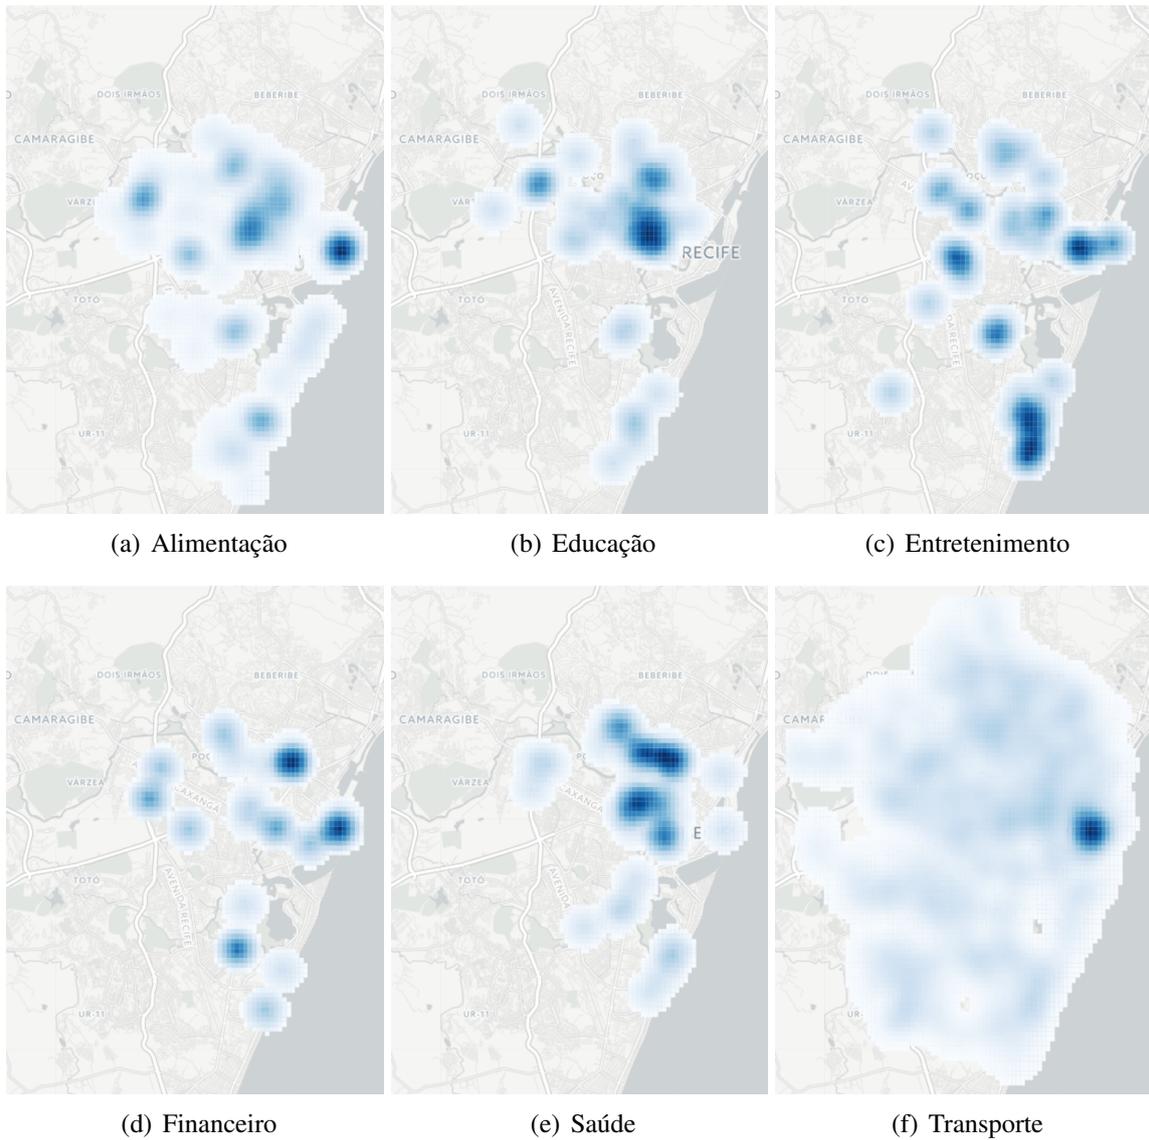


Figura 8. Heat maps de ilustrando a distribuição das métricas de fatores urbanos para a cidade de Recife.

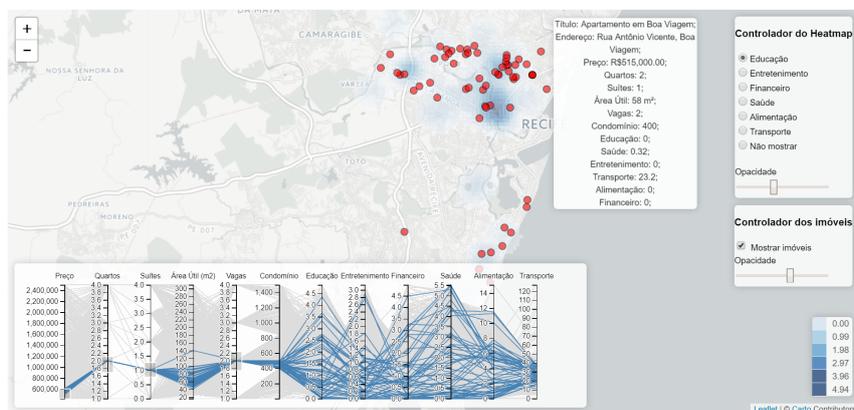


Figura 9. Busca utilizando filtros relacionados a estrutura física do imóvel

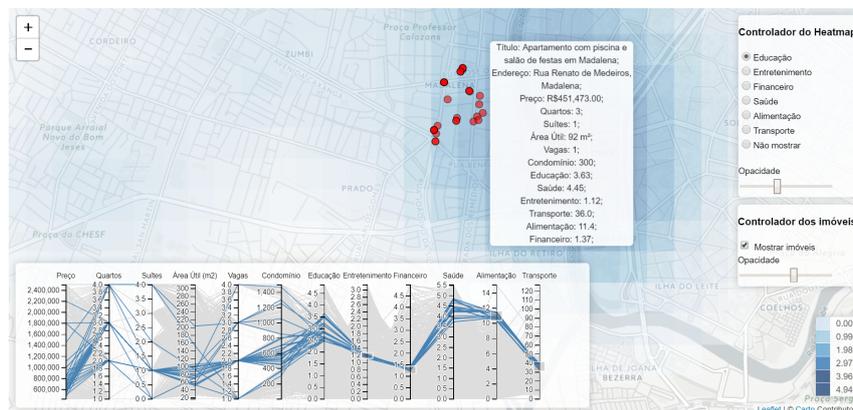


Figura 10. Busca utilizando filtros relacionados as características externas

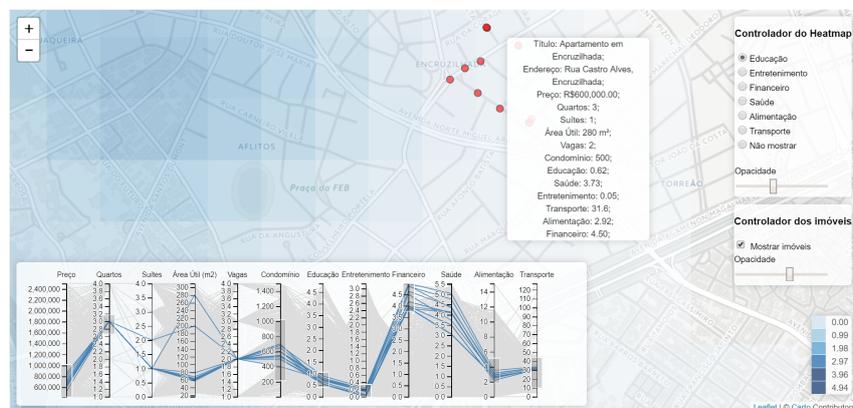


Figura 11. Busca encontrando um apartamento maior com as mesmas características externas

sites fazem.

A Figura 10 exemplifica uma pesquisa por valores referentes às características externas do imóvel está envolvido. Com a opção de filtrar por características externas, o usuário pode selecionar características do seu interesse pessoal.

A Figura 11 exemplifica uma busca com filtros de características internas e externas. Esse tipo de busca apresenta um ganho em relação a busca tradicional pois acrescenta valores externos a já conhecida busca tradicional com características internas. No exemplo da Figura, o usuário seleciona características internas e externas, e é possível ver que área útil apresenta dois imóveis com 280 e 200 metros quadrados, enquanto os outros imóveis ficam entre 80 e 60 metros quadrados. Como consequência disso o usuário pode comprar um imóvel com as mesmas características, mas com um ganho em outras características. Sendo assim o usuário encontra um imóvel melhor.

5. Conclusão

Esse trabalho propôs a criação de um ferramenta web chamada Sweet Home. a qual se concentra na visualização de dados de imóveis para dar suporte a decisão na hora de compra. O Sweet Home cumpriu o objetivo proposto por que o mesmo além de cumprir todas as tarefas analíticas (Seção 3.1) como explanado durante a seção 3.2 ainda mostra de

maneira fácil e rápida um grande volume de dados. Como consequência dessa facilitação é possível uma comparação rápida e eficiente entre imóveis. Assim, com o poder de melhor comparação, o usuário consegue um melhor suporte no momento de busca para compra de imóvel.

5.1. Conclusão e Trabalhos futuros

Mesmo cumprindo o seu objetivo, o Sweet Home deixa espaço para melhoria. Cidades são ambientes dinâmicos e para modelá-las de forma correta os rates das localidades devem evoluir com o tempo (ou serem passíveis de exploração temporal). Outras possíveis melhorias seriam na interface gráfica: Um ciclo de testes com usuário a fim de entender pontos que não estão tão claros para eles; assim como uma forma de extrair a base de imóveis periodicamente para abranger mais cidades e contextos. Um aperfeiçoamento ligado diretamente à base de dados seria utilizar outra fonte de dados em relação às características externas. Mesmo o OSM tendo uma boa quantidade de informação, ele não é tão popular aqui no Brasil como o Google Maps, então uma melhoria futura seria a utilização de outro mapa com mais informações, como por exemplo o Google Maps.

Referências

- Brewer, C. A. and Harrower, M. (2017). Colorbrewer 2.0. *Web site: [http://www. ColorBrewer. org/](http://www.ColorBrewer.org/). Acessado Julho.*
- Chang, R., Wessel, G., Kosara, R., Sauda, E., and Ribarsky, W. (2007). Legible cities: Focus-dependent multi-resolution visualization of urban relationships. *IEEE transactions on visualization and computer graphics*, 13(6):1169–1175.
- DeSimone, B. (2017). Why location matters in real estate. *Web site: <http://www.foxbusiness.com/features/2013/10/22/why-location-matters-in-real-estate.html>. Acessado Julho.*
- Ferreira, N., Lage, M., Doraiswamy, H., Vo, H., Wilson, L., Werner, H., Park, M., and Silva, C. (2015). Urbane: A 3d framework to support data driven decision making in urban development. In *Visual Analytics Science and Technology (VAST), 2015 IEEE Conference on*, pages 97–104. IEEE.
- Ferreira, N., Poco, J., Vo, H. T., Freire, J., and Silva, C. T. (2013). Visual exploration of big spatio-temporal urban data: A study of new york city taxi trips. *IEEE Transactions on Visualization and Computer Graphics*, 19(12):2149–2158.
- Haklay, M. and Weber, P. (2008). Openstreetmap: User-generated street maps. *IEEE Pervasive Computing*, 7(4):12–18.
- Inselberg, A. and Dimsdale, B. (1990). Parallel coordinates: a tool for visualizing multi-dimensional geometry. In *Proceedings of the 1st conference on Visualization '90*, pages 361–378. IEEE Computer Society Press.
- Janetzko, H., Stoffel, F., Mittelstädt, S., and Keim, D. A. (2014). Anomaly detection for visual analytics of power consumption data. *Computers & Graphics*, 38:27–37.
- Silva, D. S. d. (2009). Comportamento do consumidor: critérios de escolha adotados para compra de imóveis residenciais no plano piloto em Brasília DF.
- You, M., Chen, C.-w., Liu, H., and Lin, H. (2007). A usability evaluation of web map zoom and pan functions. *International Journal of Design*, 1(1).