

José Aderson Araújo Passos Filho é Arquiteto Urbanista e Mestre em Arquitetura e Urbanismo e Design. Pesquisa fabricação digital, modelagem paramétrica, programação, conforto ambiental e eficiência energética. É programador, buscando a abordagem sistêmica nos estágios de concepção projetual, assimilando contexto e diretrizes como inputs paramétricos em processos algorítmicos de otimização.

Daniel Ribeiro Cardoso é Arquiteto e Urbanista e Doutor em Semiótica, com Pós-doutorado em Modelagem da Informação na Cidade. É Professor Associado do Departamento de Arquitetura, Urbanismo e Design, e do Programa de Pós-graduação em Arquitetura e Urbanismo, ambos da Universidade Federal do Ceará. Atua na área de Modelagem da Informação na Cidade.

Como citar esse texto: PASSOS FILHO, J. A. A.; CARDOSO, D. R. Machine Learning para a acessibilização de análises em escala urbana. **VIRUS**, São Carlos, n. 19, 2019. [online] Disponível em: <http://www.nomads.usp.br/virus/_virus19/?sec=4&item=3&lang=pt>. Acesso em: 13 Dez. 2019.

ARTIGO SUBMETIDO EM 18 DE AGOSTO DE 2019

Resumo

É proposta, neste artigo, a implementação de *Machine Learning* para a simplificação e acessibilização da obtenção de resultados de análises complexas, mais especificamente na avaliação do conforto térmico em escala urbana. A complexidade da relação estabelecida entre o planejamento, a forma da cidade e as condições de clima torna necessário o uso de estratégias em análise e produção do espaço urbano que muitas vezes excede o arcabouço teórico e técnico do planejador. Pensar o *trade-off* entre precisão e velocidade dos métodos aplicados se faz importante para a construção de ferramentas que sejam não apenas potentes, mas que facilitem a ação rápida e constante dos profissionais de planejamento. De uma perspectiva tecnológica, política e ambiental, o método proposto visa, através da construção da informação, melhorar a compreensão das implicações que as edificações trazem ao ambiente urbano e contribuir com a produção da cidade contemporânea.

Palavras-chave: Planejamento urbano, *Machine learning*, Conforto térmico

1 Introdução

O planejamento, a forma da cidade e as condições de clima na escala urbana são elementos de uma relação complexa que se estabelece de modo a tornar necessário o uso de estratégias em análise e produção do espaço que sejam adaptadas tanto à alta complexidade de sistemas urbanos quanto a climas específicos. Com vistas à melhor saúde e ao aumento da vida social de seus habitantes, recomenda-se considerar as particularidades climáticas locais de uma cidade, promovendo o seu conforto ambiental (ZHAO, et al., 2011). Considerando as cidades como o principal espaço de ocupação humana, inclusive no Brasil (IBGE, 2010), tem-

se que a inerente complexidade de grandes centros urbanos deve ser contemplada com um arcabouço teórico e técnico onde constem ferramentas que sejam não apenas potentes, mas que facilitem a ação rápida e constante dos planejadores.

De acordo com a NBR 15220-1 (ABNT, 2003), a maior parte da extensão territorial do país, compreendida pela Zona Bioclimática 8, de clima quente e úmido e que inclui quase todas as capitais litorâneas, exige o sombreamento e a permissão da ventilação natural como medidas corretivas para horas do ano em desconforto térmico. Dentro do ferramental composto para a análise climática e do conforto ambiental em abordagens computacionais de projeto e planejamento, constam *software* capazes de expressar essas medidas corretivas através de cálculos de geometria solar e simulações de ventilação natural. Mais simples e de menor custo computacional, os cálculos de geometria solar são frequentemente capazes de entregar resultados de forma suficientemente rápida para a tarefa do planejador. No entanto, simulações de ventilação natural através de *software* de fluidodinâmica computacional (CFD, do inglês, *Computational Fluid Dynamics*) tipicamente envolvem longos tempos de resposta que são obstrutivos para iterações rápidas necessárias em abordagens contemporâneas de análise e prática de projeto e planejamento (WILKINSON, et al., 2014). Ainda, estas simulações exigem um maior nível de aprofundamento técnico e teórico para seu uso correto, nem sempre presente na formação de arquitetos e urbanistas.

Como forma de contornar a necessidade de uma maior proficiência técnica nas tarefas que exigem um maior rigor analítico na avaliação do conforto térmico em espaços urbanos, é proposto, neste trabalho, a utilização de técnicas computacionais de aprendizado de máquina, ou *Machine Learning*, para a simplificação e acessibilização da obtenção de resultados de análises complexas. Segundo Mena (2011), uma das formas de se enxergar o *Machine Learning* é exatamente como se este fosse um simplificador, sendo uma tecnologia que permite a compressão de grandes e diversos conjuntos de dados em apenas algumas variáveis que sejam mais significativas para o problema em questão. Portanto, propõe-se a remodelagem do problema em função de variáveis mais simples: dimensões predominantes de edifícios e orientações azimutais de cânions urbanos substituem parâmetros de configuração de simulações computacionais complexas que envolvem mais do que apenas a geometria da forma urbana. Tem-se, assim, um artifício aproximador de profissionais de planejamento urbano de diversas áreas e níveis de aprofundamento técnico que tenham em comum o tema do conforto térmico. Com isso, e ao extrapolar a proposta para outros temas, poderá se pensar nesta tecnologia como uma forma de facilitar e aumentar o alcance dos profissionais a métodos aprofundados e pertinentes a áreas correlatas ao planejamento, de forma simplificada, mais eficiente, e próxima do conhecimento técnico de especialistas.

Na área de Arquitetura e Urbanismo, objetos de estudo são tratados multidisciplinarmente. Seus variados critérios de qualidade muitas vezes necessitam de visões aprofundadas que não se encontram, todas, em um só profissional. Torna-se possível pensar que um maior nível de autonomia se faz alcançável com estratégias como a apresentada neste trabalho. Para suas avaliações, um só profissional ou pesquisador poderá atacar seu problema sob a ótica aprofundada de diversos temas de cunho técnico, mediante o uso de modelos simplificados com o aprendizado de máquina. De uma perspectiva tecnológica, política e ambiental, o método proposto visa contribuir com a produção da cidade contemporânea, melhorando a compreensão das implicações diretas que as edificações têm no ambiente urbano. Ascher (2010) enfatiza a importância da compreensão de novas dinâmicas da cidade atreladas à maneira como a própria sociedade rapidamente se transforma. Respostas rápidas, não necessariamente precisas, tornam-se interessantes para a convergência em denominadores comuns a tantos critérios envolvidos nos processos de tomadas de decisão em planejamento urbano.

Esta pesquisa trata da construção da informação sobre conforto térmico em escala urbana, mapeando esta variável por meio do processamento de arquivos climáticos e dados sobre a forma da cidade, barateando o custo de métodos de simulação computacional e tornando o processo mais acessível. A metodologia adotada parte da definição de parâmetros descritivos da forma urbana, correlacionando-os a resultados obtidos em simulações de ventilação natural e sombreamento. O trabalho tem por objetivo a elaboração de um modelo simplificado do conforto térmico urbano mediante a aplicação de algoritmos de aprendizado de máquina, visando mais ampla aplicação deste tipo de análise em processos de tomada de decisão, e enfatizar a importância destas técnicas computacionais na produção da cidade contemporânea.

2 *Machine Learning*

Segundo Belém, Santos e Leitão (2019), nas últimas décadas, avanços computacionais mudaram a forma com que arquitetos e urbanistas atuam em projeto e planejamento. A computação revolucionou a arquitetura e, atualmente, abordagens computacionais estão completamente incorporadas na prática projetual. Belém, Santos e Leitão (2019) dizem ainda que, recentemente, uma nova revolução computacional está em curso, sendo conduzida, de acordo com Bishop (2006), por avanços na área de *Machine Learning*.

Machine Learning é uma ramificação da Inteligência Artificial baseado em estatística computacional e procedimentos de otimização, que explora técnicas de aprendizado auto-aperfeiçoadas para a solução de problemas ou execução de tarefas específicas. Diferente de outras abordagens da Inteligência Artificial, ramificações como a do *Machine Learning* tentam construir sistemas que não precisam ser programados para realizar as tarefas. Ainda, no caso específico do *Machine Learning*, são construídos modelos matemáticos a partir de dados de amostragem, chamados de dados de treino, para que os parâmetros do modelo sejam

adaptados progressivamente até que seu desempenho em tarefas específicas seja melhorado sem qualquer intervenção humana (BISHOP, et al., *apud* BELÉM, et al., 2019).

Explicado de forma alternativa, como ilustrado no diagrama da Figura 1, o *Machine Learning* funciona de forma diferente da computação clássica, que tem como *inputs* as regras e os dados de um problema, para que sejam obtidas as respostas, ou *outputs*. No *Machine Learning*, dados de treino e respostas previamente obtidas são *inputs* para a estimativa de regras, desta vez como *outputs*. Conectada a uma nova iteração de programação clássica, as regras estimadas são usadas com um novo conjunto de dados para a obtenção de respostas preditivas.

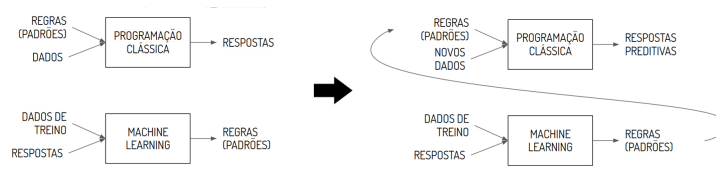


Fig. 1: Programação clássica e *Machine Learning*. Fonte: Autores, 2019.

Ao longo da última década, como exemplo do impacto dessa tecnologia em áreas onde foi aplicada, o *Machine Learning* aprimorou os principais processos computacionais em quase todos os setores econômicos. Sua adoção antecipada ofereceu um poderoso impulso para a inovação e mostrou o potencial de expandir a percepção nos problemas de otimização, automação e previsão (MCKINSEY GLOBAL INSTITUTE, 2017 *apud* KHEAN, et al., 2018). Além desta, várias outras áreas também já foram afetadas (MAGOULAS, 2001), como a medicina (MAGOULAS, et al., 2001; DEO, 2015), a física (FERREIRA, 2018), e finanças (BOLTON, et al., 2015). Ainda, segundo Brynjolfsson e McAfee (2017), pesquisas recentes sugerem que os avanços feitos em *Machine Learning* conseguirão ser tão transformadores para os dias de hoje quanto a eletricidade cem anos atrás.

O historiador Mario Carpo (2016 *apud* KHEAN, et al., 2018) prevê que a próxima virada digital em arquitetura e urbanismo se dará com a convergência de poder computacional sem precedentes e *big data* para fazer das estratégias computacionais de grande escala (como a metaheurística computacional do algoritmo genético e algum tipo de *Machine Learning*) uma abordagem mais viável e generalizada em projeto e planejamento.

3 Facilitação de análises complexas

Khean, Fabbri e Haeusler (2018) colocam que a arquitetura tem sido tradicionalmente uma disciplina quase totalmente desprovida da análise rigorosa de dados. No entanto, *data* torna-se cada vez mais um elemento protagonista no projeto interativo. Em comparação, planejamento urbano, apoiado há mais tempo em análise de dados, consegue se tornar ainda mais aperfeiçoado pela mesma tendência. Khean, Fabbri e Haeusler (2018, s.p., tradução nossa) explicam ainda:

Esses dados podem ser coletados a partir do entorno, analisados, manipulados e avaliados no processo de projeto ou planejamento, e, em alguns casos, visualizados através do produto final. Nos últimos anos, os esforços em pesquisas produziram uma grande quantidade de ferramentas computacionais para projeto orientado a dados, úteis para uma variedade de aplicações. No entanto, o desenvolvimento de estruturas para projeto orientado a dados continuou a depender de uma combinação de experiência, intuição e construção e recuperação manuais de conhecimento.

Propõe-se, neste trabalho, que experiência e intuição, pressupostos para o desenvolvimento e aplicação de métodos aprofundados de análises complexas, possam ser contornadas com o uso de *Machine Learning*. Enquanto essa tecnologia ainda não foi amplamente compreendida ou adotada em arquitetura e urbanismo, existem exemplos documentados de redes neurais¹ aplicadas no desenvolvimento de ferramentas preditivas na construção civil, mais especificamente para a estimativa do custo de obras, a depender de variáveis em menores números e de mais fácil obtenção do que em outros métodos, como a área e a quantidade de pavimentos, o ano de construção e o preço de principais insumos (LUU, et al., 2009; ELSAWY, et al., 2011). Em projeto, Cudzik e Radziszewski (2018) sugerem que a adoção de técnicas de Inteligência Artificial e *Machine Learning* resultarão em ferramentas mais intuitivas.

4 *Machine Learning* e fluidodinâmica computacional

Tamke, Nicholas e Zwierzycki (2018) acreditam que interseções entre *Machine Learning* e simulações computacionais podem possibilitar uma prática de intuição sobre o que está sendo simulado. Os mesmos autores (2018) complementam:

A integração da simulação computacional em fluxos de trabalho deu origem a uma metodologia de projeto baseada em desempenho. O uso de ferramentas paramétricas e generativas com simuladores de estrutura, energia, geometria solar, ventilação natural, dentre outros, configura, hoje, o estado da arte. Como

qualquer outra prática de simulação, esta abordagem requer uma boa compreensão das relações internas do sistema, bem como dados sobre o comportamento dos elementos, e ferramentas computacionais eficientes para o cálculo dos modelos complexos subjacentes. Nenhum destes objetos de simulação é normalmente bem abordado no processo de projeto, que é caracterizado por problemas mal definidos, mudanças constantes nas partes fundamentais dos sistemas a serem simulados, falta de tempo, recursos e também dados sobre o comportamento de materiais, dentre outros obstáculos. Enquanto praticantes experientes confiam nas suas intuições, em situações como essas, o *Machine Learning* pode agir de forma semelhante e prever, a partir de resultados de simulações precedentes, como novos sistemas se comportarão. (TAMKE; NICHOLAS; ZWIERZYCKI, 2018, s.p., tradução nossa.)

Como exemplos, Wilkinson, Bradbury e Hanna (2014) introduzem o *Machine Learning* na engenharia para acelerar simulações complexas, como no caso de *Computational Fluid Dynamics*, e prever padrões complexos plausíveis de interferência do vento utilizando métodos de aprendizado supervisionado², e Tamke, Zwierzycki, Deleuran, Baranovskaya, Tinning e Thomsen (2017) utilizam a mesma técnica para *form-finding* em sistemas complexos.

A análise de *Computational Fluid Dynamics* tipicamente envolve tempos de resposta que são obstrutivos para iterações rápidas necessárias em abordagens contemporâneas de análise e prática de projeto e planejamento. Nesse paradigma, os arquitetos podem facilmente gerar imensos números de cenários alternativos, mas enfrentam a tarefa demorada de avaliação e seleção (WILKINSON, et al., 2014). Uma solução para este problema, por Wilkinson, Hanna, Hesselgren e Mueller (2013), se dá nos estágios iniciais de projeto de edificações altas, usando conjuntos de modelos procedurais pré-computados, características da forma dos edifícios, e *Machine Learning* através de redes neurais artificiais. Neste exemplo, mostrou-se que tempos de previsão significativamente mais rápidos podem ser alcançados, enquanto erros de aproximação são minimizados até níveis toleráveis para a tarefa em questão.

5 Precisão e velocidade

Computational Fluid Dynamics, de grande importância para questões de segurança, conforto e eficiência, é, sobretudo, uma das simulações mais intensas e demoradas na avaliação de desempenho da forma arquitetônica e urbana. Surge, portanto, tipicamente, em estágios iniciais de projeto, a dificuldade em orientar decisões através desta ferramenta, devido ao *feedback* lento das abordagens convencionais de *Computational Fluid Dynamics*, onde este tipo de simulação, quando lenta e precisa, é melhor investida em estágios posteriores. Torna-se prudente, então, considerar comprometimentos de *trade-off* entre precisão e velocidade, sacrificando a precisão a favor da velocidade, durante esses estágios iniciais, para que mais possibilidades possam ser analisadas (WILKINSON, et al., 2014).

Segundo Wilkinson, Bradbury e Hanna (2014), diferente dos cenários de alto risco onde comumente se aplica o uso de *Computational Fluid Dynamics*, como em engenharia de aeronaves, espaçonaves, automóveis, dentre outros, a movimentação do ar na ventilação natural em arquitetura e urbanismo pode ser analisada de forma mais tolerante a erros, principalmente nos estágios iniciais de projeto e planejamento, quando refinamentos tanto no método de simulação como no objeto simulado podem ser feitos a posteriori.

A idéia de que, nesses estágios iniciais de *feedback* rápido e menos preciso, pode haver mais espaço para exploração e otimização de projeto é apoiada pelo conceito de *trade-off* entre precisão e velocidade (CHITTKA, et al., 2009), que sugere que, para problemas de baixo risco, geralmente é melhor tomar decisões mais rápidas e menos precisas. Isso implica que, no escopo de problemas mais complexos, é melhor ter uma perspectiva mais ampla sobre a variabilidade de desempenho ao invés de uma perspectiva extremamente precisa, porém limitada, atenta a um menor número de possibilidades.

De acordo com Chittka, Skorupsko e Raine (2009, s.p., tradução nossa), o *trade-off* entre precisão e velocidade se confirma em exemplos da biologia na eficiência de certas espécies animais:

Quando se leva muito tempo para resolver uma tarefa difícil, e os potenciais prejuízos por conta dos erros são baixos, a melhor solução na perspectiva de um animal pode ser adivinhar a solução rapidamente, uma estratégia que provavelmente resultará em baixa precisão de decisão.

Em concordância, Burns (2005) coloca que tomar mais decisões com mais erros (análises rápidas e imprecisas) resulta em melhor desempenho geral do que tomar decisões com menos erros numa postura mais exigente (análises lentas e precisas), exemplificando com abelhas, onde mais néctar é coletado para a colméia quando o comportamento individual das abelhas é em média mais desleixado e intenso, ao invés de cuidadoso e preciso. Isso fornece uma boa analogia para a caracterização do conforto térmico em escala urbana.

6 Proposta

Para que se entenda como o método proposto, através de *Machine Learning*, pode simplificar a complexidade de uma análise que contemple não só os aspectos climáticos como também de conforto térmico na escala urbana, é necessário primeiro compreender o quão complexo e custoso é um método convencional que envolva cálculos de geometria solar e simulações de Fluidodinâmica Computacional.

Uma das formas de correlacionar clima e conforto faz uso da carta de Olgay. A carta bioclimática de Olgay (1963) descreve estratégias corretivas para o clima do espaço construído. No diagrama, consta uma zona de conforto central, fora da qual os pontos que representam determinados momentos de desconforto térmico ao longo do ano no clima de uma localidade específica poderão ser adaptados a partir da zona da estratégia corretiva em que se encontra. No exemplo da Figura 2, a cidade de Fortaleza, pertencente à Zona Bioclimática 8, pode ter os pontos fora da sua zona de conforto corrigidos a partir do uso de ventilação natural. A carta também informa qual a velocidade mínima do vento necessária para corrigir a condição de temperatura e umidade expressa por um ponto no gráfico.

Os pontos marcados na carta de Olgay podem ser obtidos através da leitura de arquivos climáticos por *software* capaz de extrair essas informações. No exemplo das Figuras 2 e 3, utilizou-se o arquivo climático de formatação *Typical Meteorological Year* (TMY) para a cidade de Fortaleza, obtido no website do Laboratório de Eficiência Energética em Edificações da Universidade Federal de Santa Catarina, LabEEE-UFSC (UNIVERSIDADE FEDERAL DE SANTA CATARINA, 2019). Seus dados foram importados pelo *software Grasshopper*, um modelador paramétrico da plataforma de desenho auxiliado por computador *Rhinoceros 3D*, através do plugin de análise climática *Ladybug Tools*, e interpretados nos gráficos da carta de Olgay e dos histogramas da Figuras 2 e 3 através de uma definição paramétrica implementada em uma Linguagem de Programação Visual (VPL, do inglês, *Visual Programming Language*).

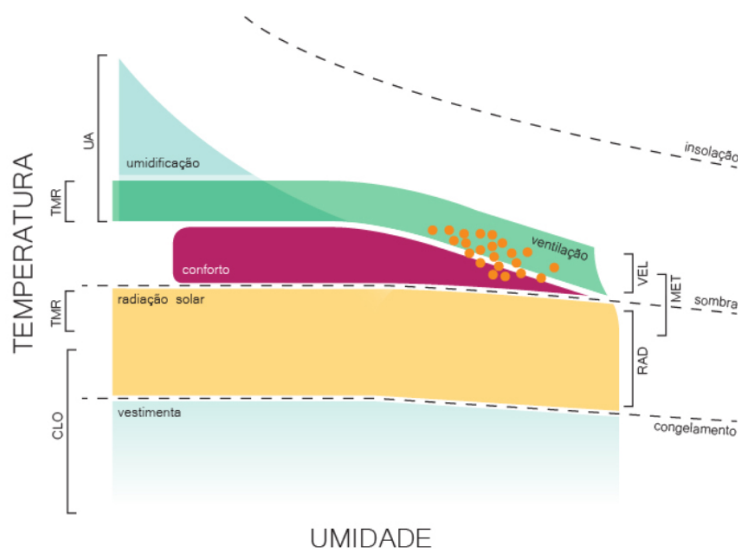


Fig. 2: Carta de Olgay, para a cidade de Fortaleza. Fonte: Autores, 2019.

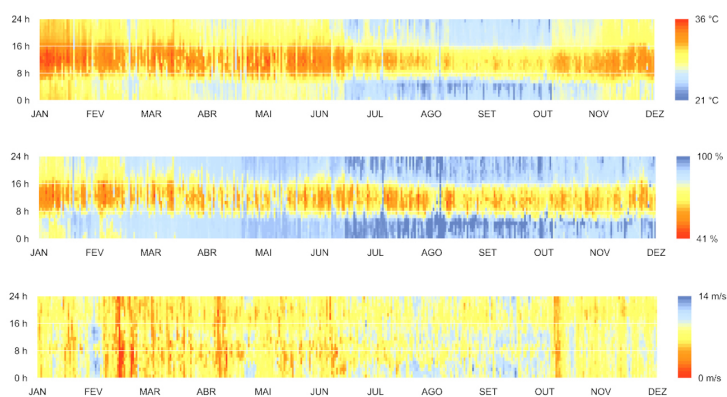


Fig. 3: Histogramas anuais de temperatura de bulbo seco, umidade relativa do ar e velocidade do vento, para a cidade de Fortaleza. Fonte: Autores, 2019.

Uma vez determinada a possibilidade de se corrigir um ponto do histograma fora das condições de conforto determinadas pela carta de Olgay, resta saber se a forma urbana no entorno do espaço analisado permite que a velocidade obtida no arquivo climático (normalmente medida em instrumentos localizados em aeroportos da cidade referente) seja mantida. É então que as simulações de *Computational Fluid Dynamics* são implementadas. Um dos *software* indicados para essa tarefa é o *Ansys CFX*, comumente usado na engenharia em análises estruturais (WILKINSON *et al.*, 2013) mas aplicado aqui para análise de conforto segundo metodologia apropriada (LEITE, 2015).

Assim, uma simulação do tipo *Reynolds Averaged Navier-Stokes* (RANS) é realizada seguindo a metodologia apresentada em Leite (2015), utilizando o modelo de turbulência *k-ε* e está definida em 5%. A simulação é configurada de forma isotérmica de acordo com a temperatura de bulbo seco, sem levar em consideração forças convectivas, com o critério de convergência definido em 10^{-4} , que pode ser considerado razoavelmente convergido. A malha é modelada de forma desestruturada, utilizada em conjunto com uma camada de células prismáticas no piso e nas faces das edificações dentro de um domínio cilíndrico, observando as devidas proporções mínimas para a redução do efeito de bloqueio (Figura 4).




Fig. 4: Visualização da malha e dos resultados da simulação de *Computational Fluid Dynamics*. Fonte: Leite, 2015.

Dessa forma, obtém-se um percentual da área analisada que compreende regiões do domínio simulado onde a velocidade do vento atende o requisito mínimo para atuar como estratégia corretiva, restando apenas descontar a parte dessas regiões onde não ocorrem sombras ao longo do ano, mediante os cálculos de geometria solar e gráficos de sombra acumulada, realizados pela mesma ferramenta *Ladybug*, do *Grasshopper* (Figura 5). Finaliza-se, então, uma análise com a abordagem convencional, lenta e de maior exigência do especialista que a realize.




Fig. 5: Exemplos de gráficos de sombras acumuladas. Fonte: Autores, 2019.

A partir do uso de *Machine Learning*, no entanto, é possível treinar o computador para gerar um modelo mais simples que descreva o fenômeno do conforto térmico, referente especificamente às condições de clima do espaço urbano analisado, nos mesmos termos utilizados na abordagem convencional já descrita, ou seja, através de um indicador percentual que mostre o quão expressiva é a porção confortável do espaço estudado. Porém, os algoritmos de *Machine Learning* definiriam o novo modelo de conforto em função de variáveis mais simples, como dimensões predominantes de edifícios e orientações azimutais de eixos de vias.

Como sugere Moreira (2018), fazendo-se uso de um Sistema Gerenciador de Banco de Dados (SGBD) e com a aplicação de um Sistema de Informação Geográfica/Desenho Auxiliado por Computador (SIG/CAD), é possível descarregar as geometrias da forma urbana para que sejam analisadas em larga escala. Seguindo, então, da aplicação da abordagem convencional de análise de conforto sobre espaços urbanos suficientes para a formação de um conjunto de treino, teremos uma matriz cujas tuplas³ correlacionam apenas as variáveis de fácil obtenção (dimensões de edifícios e orientações de vias) com os resultados das análises. Tamke, Nicholas e Zwierzycki (2018) se refere a esse tipo de prática emergente como um curto-circuito por sobre as simulações ("*short-circuiting simulations*"). Redes neurais artificiais poderão, enfim, extrapolar os padrões aprendidos entre as variáveis simples, ou *features*, e os seus resultados, para novos casos, além do conjunto de treino, sem que a aplicação da abordagem convencional seja necessária (Figura 6).




Fig. 6: Abordagem convencional e *Machine Learning*, onde: 1) Análise climática; 2) Forma urbana; 3) Simulações computacionais; 4) Modelos complexos de conforto; 5) Indicadores de conforto; 6) Dimensões dos edifícios no entorno; 7) Orientação dos eixos das vias; A) Modelo simplificado de correlação conforto-forma; B) Dimensões de edifícios e orientação dos eixos das vias de novos casos; C) Indicadores estimados de conforto. Fonte: Autores, 2019.

Em estágios de desenvolvimento, esta pesquisa se encontra nas etapas de construção do conjunto de treino dos algoritmos de *machine learning*, que envolve uma quantidade considerável de simulações a serem feitas. Em um trabalho semelhante, focado apenas nas simulações de ventilação natural com *Computational Fluid Dynamics*, sem cálculos de geometria solar e com vista ao desempenho estrutural do edifício, ao invés de desempenho térmico, Wilkinson, Hanna, Hesselgren e Mueller (2013) chega a resultados com cerca de 600 simulações. No entanto, fica claro, como comprovação do método semelhante, a marca de menos de 6,1% de erro para as leituras de coeficientes de pressão ao longo das superfícies complexas dos edifícios testados. Ao trabalhar com geometrias mais simples, com baixo nível de detalhamento em extrusões perpendiculares das poligonais dos edifícios, a presente pesquisa espera encontrar resultados dentro de margens de erro semelhantes.

8 Conclusões

O uso de *Machine Learning* como método de solução de problemas complexos tem sido uma realidade da ciência da computação desde os anos 1950, com os seus primeiros exemplos, como o modelo do jogo de Damas de 1952 de Arthur Samuel, provando, pela primeira vez, que uma máquina poderia aprender a jogar melhor que seu criador em um curto período de tempo (SAMUEL, 1959). De acordo com Sjoberg, Charlotte, Beorkrem e Ellinger (2017), é concebível que tal momento também possa ocorrer no campo do projeto e planejamento, onde uma ferramenta poderia eclipsar a capacidade de humanos em considerar e responder ao vasto número de variáveis e relacionamentos de um sistema complexo.

No entanto, mesmo antes que tal momento chegue, a capacidade do arquiteto e urbanista de obter resultados necessários e suficientes em análises aprofundadas envolvendo simulações de fenômenos complexos, como o conforto térmico a nível urbano, já pode ser capaz de ser aumentada através de *Machine Learning*, ainda que a máquina não possua total autonomia.

Custo computacional e tempo reduzidos contribuem com a atuação de profissionais menos aprofundados teórica e tecnicamente em aspectos específicos da arquitetura e urbanismo, sem a necessidade de uma compreensão completa de todas as variáveis envolvidas. Segundo Tamke, Zwierzycki, Deleuran e Baranovskaya:

A habilidade de trabalhar permitindo a exploração sistemática de opções, com a abordagem computacional, pode construir uma intuição sobre direções promissoras no projeto, e explorá-las rapidamente. Essas explorações podem também acontecer através da geração automática de opções de projeto e subseqüentes avaliações e reiterações das soluções de acordo com objetivos dados. (TAMKE, et al., 2017, p. 100, tradução nossa.)

Como colocam Tamke, Zwierzycki, Deleuran e Baranovskaya (2017), o *Machine Learning* foi introduzido na engenharia para acelerar simulações complexas, fornecendo aproximações rápidas, confiáveis e precisas de resultados para informar o projetista, deixando os cálculos de 200 a 500 vezes mais rápidos que em métodos tradicionais. Alinhado ao mesmo pensamento, está o que é colocado por uma série de autores (CHRONIS, et al., 2012; LOMAX, et al., 2001; LU, et al., 1991; SAMARASINGHE, 2007) a respeito do *trade-off* entre velocidade e precisão, que afirmam existir a necessidade de ajustar o nível de precisão de simulações de acordo com o tempo de resposta ideal em aplicações específicas.

Com a remodelagem do problema por *Machine Learning*, portanto, em função de variáveis mais simples, busca-se uma aproximação dos profissionais de planejamento urbano de diversas áreas e níveis de aprofundamento técnico que tenham em comum o tema do conforto térmico. Ao extrapolar a proposta para outros temas, poderá se pensar nesta tecnologia como uma forma de facilitar e aumentar o alcance dos profissionais a assuntos que dependem de um arcabouço teórico e técnico mais aprofundado para sua compreensão, pertinentes a áreas correlatas ao planejamento, de modo tanto a torná-los mais autônomos, capazes de interagir de forma mais produtiva com especialistas. Melhorar, assim, a compreensão das implicações diretas que as edificações têm no ambiente urbano, através da construção da informação, visa contribuir com a produção da cidade contemporânea segundo uma perspectiva tecnológica, política e ambiental.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Referencias

ABNT. NBR 15220-1: **Desempenho térmico de edificações**. Parte 1: Definições, símbolos e unidades. Rio de Janeiro: ABNT, 2003.

ASCHER, F. **Os novos princípios do urbanismo**. São Paulo: Romano Guerra, 2010.

BEHERA, R. N.; DAS, K. A Survey on Machine Learning: Concept, Algorithm and Applications. **International Journal of Innovative Research in Computer and Communication Engineering**, v. 5, n. 2, 2017.

BELÉM, C.; SANTOS, L.; LEITÃO A. On the Impact of Machine Learning: Architecture without Architects? In: INTERNATIONAL CONFERENCE, CAAD FUTURES 2019, 18., 2019, Daejeon, Korea. **Anais...** Disponível em: <http://papers.cumincad.org/data/works/att/cf2019_020.pdf>. Acesso em: 17 Ago. 2019.

BISHOP, C. M. **Pattern Recognition and Machine Learning**: Information Science and Statistics. Nova Iorque: Springer-Verlag, 2006.

BOLTON, R. J.; HAND, D. J. Statistical Fraud Detection: A review. **Statistical Science**, v. 17, n. 3, p. 235-255, 2002.

BRYNJOLFSSON, E.; MCAFEE, A. **Machine, Platform, Crowd**: Harnessing our Digital Future. Nova Iorque: W. Norton & Company, 2017.

BURNS, J.G. Impulsive bees forage better: the advantage of quick, sometimes inaccurate foraging decisions. **Animal Behaviour**, v. 70, n. 6, 2005.

CHRONIS, A.; TSIGKARI, M.; DAVID, A.; AISH, F. Design Systems, Ecology and Time. In: ACADIA, 2012. **Anais...** Disponível em: <https://www.researchgate.net/profile/Angelos_Chronis/publication/272886939_Design_Systems_Ecology_and_Time_Systems-Ecology-and-Time.pdf>. Acesso em: 17 Ago. 2019.

CUDZIK, J.; RADZISZEWSKI, K. **Artificial Intelligence Aided Architectural Design**. In: eCAADe - AI for design and built environment, 2018. Disponível em: <https://www.researchgate.net/profile/Jan_Cudzik/publication/328018944_Artificial_Intelligence_Aided_Architectur_Intelligence-Aided-Architectural-Design.pdf>. Acesso em: 17 Ago. 2019.

CHITTKA, L.; SKORUPSKO, P; RAINE, N. E. Speed-Accuracy Tradeoffs in Animal Decision Making. **Trends in Ecology and Evolution**, v. 24, n. 7, 2009.

DEO, R. C. Machine Learning in Medicine. **Circulation**, v. 132, p. 1920-1930, 2015. DOI: 10.1161/CIRCULATIONAHA.115.001593. Disponível em: <<https://www.ahajournals.org/doi/pdf/10.1161/CIRCULATIONAHA.115.001593>>. Acesso em: 17 Ago. 2019.

ELSAWY, I.; HOSNY, H.; RAZEK, M. A. A Neural Network Model for Construction Projects Site Overhead Cost Estimating in Egypt. **International Journal of Computer Science Issues**, v. 8, n. 3, p. 273-283, 2011. Disponível em: <<https://arxiv.org/abs/1106.1570>>. Acesso em: 17 Ago. 2019.

FERREIRA, D. R. **Applications of Deep Learning to Nuclear Fusion Research**. 2018. Disponível em: <<https://arxiv.org/pdf/1811.00333.pdf>>. Acesso em: 17 Ago. 2019.

IBGE. **Sinopse do censo demográfico 2010**. Rio de Janeiro: IBGE, 2010.

KHEAN, N.; FABBRI, A.; HAEUSLER, M. H. Learning Machine Learning as an Architect, How to? In: ECAADE - Computing for a better tomorrow, 2018, Łódź, Poland. **Anais...** Disponível em: <http://papers.cumincad.org/data/works/att/ecaade2018_111.pdf>. Acesso em: 17 Ago. 2019.

KHEAN, N.; KIM L.; MARTINEZ, J.; DOHERTY, B.; FABBRI, A.; GARDNER, N.; HAEUSLER, M. H. The Introspection of Deep Neural Networks - Towards Illuminating the Black Box: Training Architects Machine Learning via Grasshopper Definitions. In: CAADRIA, 23., 2018, Beijing, China. **Anais...** Disponível em: <http://papers.cumincad.org/data/works/att/caadria2018_126.pdf>. Acesso em: 17 Ago. 2019.

LEITE, R. C. V. **Cidade, Vento, Energia**: Limites de Aplicação da Ventilação Natural para o Conforto Térmico Face à Densificação Urbana em Clima Tropical Úmido. Tese (Doutorado em Arquitetura e Urbanismo) - Universidade de São Paulo, São Paulo, 2015.

LOMAX, H.; PULLIAM, T. H.; ZINGG, D. W. **Fundamentals of computational fluid dynamics**. Berlim: Springer, 2001.

LU, S. C.-Y.; TCHENG, D. K.; YERRAMAREDDY, S. Integration of Simulation, Learning and Optimization to Support Engineering Design. **Annals of the CIRP**, v. 40, n. 1, 1991.

LUU, V. T.; KIM, S. Y. Neural Network Model for Construction Cost Prediction of Apartment Projects in Vietnam. **Korean Journal of Construction Engineering and Management**, v. 10, 2009. Disponível em: <https://www.researchgate.net/publication/264113646_Neural_Network_Model_for_Construction_Cost_Prediction_c>. Acesso em: 17 Ago. 2019.

MAGOULAS, G. D. **Machine Learning and Its Applications**. Berlim/Heidelberg: Springer Berlin Heidelberg, 2001.

MAGOULAS, G. D.; PRENTZA, A. **Machine Learning in Medical Applications**. Berlim/Heidelberg: Springer Berlin Heidelberg, 2001.

MENA, J. **Machine Learning Forensics for Law Enforcement, Security, and Intelligence**. London: CRC, 2011.

MOREIRA, E. **Modelando a percepção: o ambiente do patrimônio cultural edificado na regulação da forma urbana**. Dissertação (Mestrado em Arquitetura, Urbanismo e Design) – Universidade Federal do Ceará, Fortaleza, 2018.

OLGYAY, V. **Design with Climate**. New Jersey: Princeton University Press, 1963.

ORACLE CORPORATION. **The Java Tutorials**, c2019. A Relational Database Overview. Disponível em: <<https://docs.oracle.com/javase/tutorial/jdbc/overview/database.html>>. Acesso em: 4 nov. 2019.

SAMARASINGHE, S. **Neural Networks for Applied Sciences and Engineering: From Fundamentals to Complex Pattern Recognition**. Nova Iorque: Auerbach, 2007.

SAMUEL, A. L. Some Studies in Machine Learning Using the Game of Checkers. **IBM Journal of Research and Development**, v. 3, n. 3, 1959.

SJOBERG, C.; CHARLOTTE, U.; BEORKREM, C.; ELLINGER, J. Emergent Syntax: Machine Learning for the Curation of Design Solution Space. In: ACADIA, 37., 2017, Cambridge, USA. **Anais...** Disponível em: <http://papers.cumincad.org/data/works/att/acadia17_552.pdf>. Acesso em: 17 Ago. 2019.

TAMKE, M.; NICHOLAS, P.; ZWIERZYCKI, M. Machine learning for architectural design: Practices and infrastructure. **International Journal of Architectural Computing**, v. 16, n. 2, 2018.

TAMKE, M.; ZWIERZYCKI, M.; DELEURAN, A. H.; BARANOVSKAYA, Y. S.; TINNING, I. F.; THOMSEN, M. R. Lace Wall - Extending design intuition through Machine Learning. In: MENGES, A.; SHEIL, B.; GLYNN, R.; SKAVARA, M. (Org.). **Fabricate 2017**. Londres: UCL Press, 2017.

UNIVERSIDADE Federal de Santa Catarina. Laboratório de Eficiência Energética em Edificações. **Arquivos climáticos em formato TRY, SWERA, CSV e BIN**. 2019. [online] Disponível em: <<http://www.labeee.ufsc.br/downloads/arquivos-climaticos/formato-try-swera-csv-bin>>. Acesso em: 17 de Ago. 2019.

WILKINSON, S.; BRADBURY, G.; HANNA, S. Approximating Urban Wind Interference. In: SYMPOSIUM ON SIMULATION FOR ARCHITECTURE & URBAN DESIGN, 2014, San Diego, USA. **Anais...** Disponível em: <https://www.researchgate.net/profile/Samuel_Wilkinson3/publication/303810741_Approximating_Urban_Wind_Int_Urban-Wind-Interference.pdf>. Acesso em: 17 Ago. 2019.

WILKINSON, S.; HANNA, S.; HESSELGREN, L.; MUELLER, V. Inductive Aerodynamics. In: ECAADE - Computation and Performance, 2013, Delft, the Netherlands. **Anais...** Disponível em: <https://www.researchgate.net/profile/Samuel_Wilkinson3/publication/303810587_Inductive_aerodynamics/links/5aerodynamics.pdf>. Acesso em: 17 Ago. 2019.

ZHAO, C.; FU, G.; LIU, X.; FU, F. Urban planning indicators, morphology and climate indicators: A case study for a north-south transect of Beijing, China. **Building and Environment**, n. 46, p. 1174-1183, 2011.

1 Redes Neurais Artificiais são um paradigma de *Machine Learning* inspirado na biologia, capaz de resolver problemas de processamento de sinais complexos e reconhecimento de padrões. Seu conceito toma emprestado a compreensão de como o sistema nervoso central humano opera através de caminhos e conexões neurais, e traduz isso em um sistema computacional (KHEAN, et al., 2018).

2 Aprendizado supervisionado é um método de aprendizado em *Machine Learning* que usa um conjunto de treinamento de dados contendo as entradas e as saídas correspondentes, ou seja, os rótulos associados. As saídas são usadas para guiar o processo de aprendizado (Belém, et al., 2019).

3 No contexto de banco de dados relacionais, uma linha ou tupla é uma estrutura de dados que corresponde a um registro de informações de campos ou atributos correlacionados no tema de uma matriz (ORACLE, 2019).