

USO DE METAHEURÍSTICAS E FERRAMENTAS DE INTELIGÊNCIA ARTIFICIAL EM PROBLEMAS DE ROTEIRIZAÇÃO DE VEÍCULOS

Jin Uema e Arnaldo Rabello de Aguiar Vallim Filho

Apoio: PIVIC Mackenzie

RESUMO

Neste projeto, foi realizado uma pesquisa sobre o uso de uma metaheurística no problema de roteirização de veículos – PRV, que é um problema clássico de otimização combinatória. Foi utilizada uma ferramenta computacional normalmente utilizada em inteligência artificial/aprendizado de máquina, e que se mostrou muito eficaz para resolver problemas combinatórios de otimização. Com base na literatura, foi visto que as metaheurísticas têm uma boa performance ao se tratar de problemas de solução NP-difícil, onde se enquadram problemas de otimização combinatória e aplicamos as suas propriedades em um modelo para realizar otimizações em rotas veiculares urbanas, especialmente voltadas para as distribuições de carga em múltiplos pontos de entrega. O modelo foi ajustado para trabalhar com frotas homogêneas e heterogêneas de veículos, podendo assim otimizar as rotas com base em sua capacidade e distância. Existe também um cálculo de penalidade caso o veículo ultrapasse sua capacidade máxima ou fique abaixo de seu nível de carga mínimo. Após isto, realizamos o treinamento do modelo e mensuramos os seus ganhos durante as interações do algoritmo e gravamos sua distância global, as distâncias de cada rota e trechos, seus pesos e pontos em cada rota. Ao final de sua execução, tivemos uma porcentagem de redução que varia entre 74% e 94% em média na distância das rotas em comparação com sua distância inicial e com isso podemos ajudar aplicações existentes nas áreas de logística de múltiplas paradas.

Palavras-chave: Metaheurísticas, Inteligência Artificial, Roteirização de Veículos, Otimização,

ABSTRACT

In this project, a research was carried out on the use of a metaheuristic in the vehicle routing problem – VRP, which is a classic combinatorial optimization problem. A computational tool commonly used in artificial intelligence/machine learning was used, which proved to be very effective in solving combinatorial optimization problems. Based on the literature, it was seen that metaheuristics have a good performance when dealing with NP-hard solution problems, where combinatorial optimization problems are included, and we apply their properties in a model to perform optimizations in urban vehicular routes, especially aimed at for load distributions at multiple delivery points. The model was adjusted to work with homogeneous and heterogeneous vehicle fleets, thus being able to optimize routes based on their capacity and distance. The objective function to be optimized, considers also a penalty if the vehicle

exceeds its maximum capacity or falls below its minimum load level. After that, we train the model and measure its gains during the algorithm's interactions and record its global distance, the distances of each route and segments, its weights and points in each route. At the end of its execution, we had a percentage reduction that varies between 74% and 94% on average in the distance of the routes compared to its initial distance and with this we can help existing applications in the areas of multi-stop logistics.

Keywords: *Metaheuristics, Artificial Intelligence, Vehicle Routing, Optimization*

1. INTRODUÇÃO

Um dos grandes problemas para as cidades de porte é o aumento constante na quantidade de veículos, o que gera uma enorme demanda das ruas e avenidas para comportar tamanho volume, e que geralmente leva a um trânsito lento em muitas de suas vias. Nessas cidades, em todo o mundo, existem grandes empresas de distribuição urbana de produtos, para as quais é crucial a entrega do produto correto, no local correto e no prazo correto, consumindo a menor quantidade de tempo e recursos possível. É o que se chama de eficácia e eficiência. Problemas logísticos geralmente entram em um contexto de uma multiplicidade de soluções, não sendo possível determinar uma solução única para uma dada situação. Os problemas são de alta complexidade em que uma alternativa muito usada para a solução se dá pelo emprego de metaheurísticas, que apesar de não oferecerem a garantia da solução ótima, fornecem soluções de boa qualidade.

Neste projeto tomou-se por base a ideia de um contexto urbano, com um desses problemas de alta complexidade que é o Problema da Roterização de Veículos (PRV), e que por ser em contexto urbano, se situa na chamada área de pesquisa “*city logistics*” segundo CATTARUZA (2015). O PRV é um conhecido problema logístico de otimização combinatória que em geral, é resolvido com o uso de heurísticas ou metaheurísticas, por ser um problema NP-Difícil. Lembrando, que esta é a mais alta classe de complexidade, e que problemas desta classe têm um tempo computacional de solução tendendo a infinito, à medida que a dimensão do problema cresce. O PRV acaba sendo uma aplicação clássica de Pesquisa Operacional e de Inteligência Artificial. Problemas semelhantes ao PRV, que também estão na classe NP-Difícil, são clássicos da literatura, como por exemplo o Problema do Caixeiro Viajante (PCV) e o Problema do Carteiro Chinês (PCC).

De acordo com BALLOU (2006) e NOVAES (2007), os problemas chamados de “capacitados”, consideram, em geral, que os veículos têm uma capacidade de carga, que pode ser a mesma para todos ou cada um pode ter sua capacidade própria (frota homogênea ou heterogênea). Na maioria dos casos, considera-se que os veículos partem de um único ponto (um Depósito), atendem os pontos de demanda e retornam à origem.

Há muitas possibilidades de restrições operacionais a considerar neste tipo de problema, principalmente, em aplicações práticas reais, como é o caso de um contexto urbano. Basta se pensar no caso de São Paulo, em que se tem restrições de circulação

de veículos de carga em diferentes situações. Além daquelas que podem ocorrer nos próprios pontos de demanda, como limitação de acesso de veículos de determinado porte, horários para entrega e recebimento e outras.

Para LAPORTE (2009), A modelagem do PRV tem flexibilidade suficiente para que cada tipo de restrição operacional possa receber tratamento específico nos seus algoritmos de solução. E as variáveis de decisão do problema correspondem à definição das rotas a percorrer por cada veículo, tendo como objetivo clássico da otimização, a minimização da distância total da operação.

1.1 PROBLEMA DE PESQUISA

No caso desta pesquisa foram explorados algoritmos de roteirização baseados em metaheurísticas, especificamente com o algoritmo de enxame de abelhas (*Artificial Bee Colony* - ABC). A ideia do projeto foi testar a otimização de rotas utilizando o ABC dado um conjunto de dados, buscando-se a otimização de uma função objetivo.

Outro aspecto importante a considerar é a questão das técnicas de Aprendizado de Máquina e de visualização dos resultados. A Ciência de Dados tem trazido hoje, uma série de recursos computacionais que permitem a solução de problemas complexos, como as linguagens R e Python, de forma que se possa utilizar bibliotecas para aplicação de algoritmos e visualização de resultados de forma muito mais ágil que em passado recente, para tratamentos de massas de dados, como utilizadas por SILVA et al. (2016), DE CASTRO e FERRARI (2016). Os processos de solução do PRV poderão se beneficiar dessas ferramentas. Experimentos com estes objetivos deverão ser desenvolvidos com o uso de bases de dados disponíveis em sites científicos, e os resultados poderão ser comparados entre si.

Dentro desse quadro, foi definida a seguinte pergunta de pesquisa para este projeto:

“Como se comportariam as soluções de um PRV obtidas pelo algoritmo ABC associadas a ferramentas tecnológicas atuais de aprendizado de máquina, considerando-se estratégias diferenciadas de construção e rearranjos dessas rotas e de apresentação dos resultados?”

1.2 JUSTIFICATIVA

O problema de pesquisa proposto neste projeto, é de ampla aplicação prática nos mais diversos tipos de operações (BALLOU, 2006; BODIN et al., 1983; NOVAES, 2007), como logística urbana para coleta e entrega de carga, coleta de lixo, serviços de manutenção de equipamentos públicos, serviços de atendimento a consumidores,

etc. E, ainda do ponto de vista prático, considere-se que o transporte é o mais alto componente do custo logístico, (BALLOU, 2006), e de acordo com LIMA (2006), no Brasil corresponde a cerca de 60% custo logístico total, que é de 12,6% do PIB do país. Considere-se também, que em cidades como São Paulo, que é considerada aquela com o quinto pior tráfego urbano do mundo segundo o INRIX (2019), e que é similar a praticamente todas as grandes cidades do país, aplicar a problemas logísticos metaheurísticas e/ou técnicas de aprendizado de máquina, otimizando grandes rotas de distribuição, poderia trazer benefícios relevantes, para essas grandes cidades brasileiras.

Outro motivo importante identificado é a questão da urgência para entrega de uma grande variedade de produtos, que por diferentes razões necessitam de prazos muito restritos, como é o caso de determinados remédios e de outros produtos de saúde, onde o tempo pode ser um fator decisivo. Rotas otimizadas, contribuiriam para a redução desses tempos. Assim, um trabalho como este poderá contribuir para que se encontre soluções que promovam redução nesses custos de transporte, contribuindo para a competitividade do país, com ganhos para toda a sociedade, de forma geral.

Do ponto de vista técnico-científico, tem-se um desafio técnico que o domínio da tecnologia de construção de algoritmos baseados em metaheurísticas com desempenho adequado e com o uso de ferramentas computacionais de livre acesso, que é o que se pretende neste projeto. A construção e implementação desse algoritmo, considerando-se variantes em relação a outras implementações, com novas estratégias de construção e de rearranjo de rotas ao longo do processo de otimização, poderá se constituir em contribuição relevante do projeto.

Com este projeto pretende-se assim, adquirir e gerar mais conhecimento sobre o problema e sobre os métodos heurísticos de solução. Entende-se assim, que é possível se verificar que esta pesquisa se justifica pelo seu potencial prático e científico, dado o desafio técnico que se coloca.

1.3 OBJETIVOS

O objetivo genérico, mais amplo, deste projeto é contribuir com a logística de transportes e entregas em cidades. De forma mais técnica, pretende-se por meio do uso de uma metaheurística, que é uma técnica de inteligência artificial, identificar as melhores rotas em um contexto de transporte urbano, dadas diversas opções de rotas e vias. Pretende-se com o estudo, implementar um modelo que incorpore ferramentas computacionais de *machine learning* associadas a metaheurísticas, para apoiar a

solução do PRV e, ainda testar diferentes abordagens de construção das rotas ao longo do processo de otimização.

Assim, pode-se colocar que o objetivo geral deste projeto é a implementação de um algoritmo de otimização de rotas baseado em metaheurísticas e em uma ferramenta computacional de aprendizado de máquina para solução do PRV. A partir dessa implementação uma série de experimentos deverão ser desenvolvidos de forma a comparar os resultados obtidos.

Sobre os objetivos específicos, o estudo buscará atender aos seguintes pontos:

- Implementar um algoritmo de otimização para solução do PRV, com metaheurísticas baseadas em população de soluções, como é o caso da técnica de enxame de abelhas e de outras (COLORNI et al., 1997; D'AMICO et al., 2002; BOUSSAID et al., 2013).
- Aplicar esse algoritmo com o apoio de uma ferramenta computacional largamente utilizada em aprendizado de máquina;
- Desenvolver experimentos com o algoritmo para diferentes cenários utilizando bases de dados de testes disponíveis.

2. REFERENCIAL TEÓRICO

Neste referencial teórico procurou-se desenvolver um levantamento da literatura no que diz respeito a fundamentação do tema deste projeto, assim como, de trabalhos correlatos. A seção está subdividida segundo os tópicos de interesse do trabalho, quais sejam: heurísticas e metaheurísticas, aprendizado de máquina e o problema de roteirização de veículos.

2.1 HEURÍSTICAS E METAHEURÍSTICAS

Quando não existem algoritmos matematicamente exatos para se encontrar a melhor solução de um problema em um tempo computacional finito, têm-se algoritmos de busca e otimização baseados em procedimentos heurísticos que, embora carecem de fortes fundamentos matemáticos, ainda assim são eficazes em atingir uma solução de boa qualidade em um período de tempo razoável (BANDARUA e DEBB, 2012).

O termo Heurística tem uma raiz grega que significa achado, descoberta. O método Heurístico está associado a uma hipótese (provisória), a uma ideia diretriz que na verdade é uma percepção do autor (um *insight*) sobre o caminho (o direcionamento) a ser seguido para se atingir a solução. Heurística é o resultado desta mescla de

insights e técnicas matemáticas. BODIN et al. (1983) afirmam que heurística é um procedimento que estrutura o problema em uma forma matemática (e normalmente, também intuitiva) para possibilitar uma solução viável ou próxima da ótima. De acordo com BALLOU (2006), As heurísticas sempre incorporam certos princípios lógicos associados ao problema em estudo.

Note-se que uma Heurística se aplica a um único tipo de problema (por exemplo: roteirização, clusterização, etc.). Metaheurísticas, por outro lado, são técnicas que abrangem classes mais amplas de problemas, por exemplo: uma mesma metaheurística pode ser usada para resolver problemas de roteirização e também de localização de instalações. Um metaheurística, na verdade, não é um método pronto para resolver um problema, podendo ser considerada como uma estratégia geral de solução de uma classe de problemas. Esta é na verdade, uma área de fronteira entre Pesquisa Operacional e Inteligência Artificial (COLORNI et al., 1997).

A implementação computacional de uma metaheurística seria o que se denomina em computação de “*framework*”.

As metaheurísticas são categorizadas em diferentes grupos, dos quais os principais são (BOUSSAID et al. 2013):

- Metaheurísticas baseadas em uma solução, que são aquelas que partem de uma única solução e buscam melhorar essa solução inicial com base em suas espaços de pesquisa;
- Metaheurísticas baseadas em população, que são aquelas que iniciam com múltiplas soluções, e com base nas respostas de cada solução, executam combinações de soluções, e/ou reforçam soluções mais promissoras.

Metaheurística é um método poderoso para resolver problemas de otimização difíceis, e tem sido usado em quase todas as áreas da engenharia e ciência (AYUMI et al., 2016).

No caso do PRV, heurísticas e metaheurísticas têm sido amplamente utilizadas. Há métodos clássicos, como: heurística de Ganhos proposta por CLARKE e WRIGHT (1963) e a heurística de Varredura (GILLET e MILLER, 1974), cujos artigos originais foram levantados. As metaheurísticas simulated annealing e busca tabu têm sido bem utilizadas (BELFIORE e FÁVERO, 2006; LAPORTE, 2009). A literatura apresenta também a ideia de “hibridização de metaheurísticas”, quando a solução não está otimizada, e uma maneira de melhorar sua performance seria mesclar elementos de

diversos algoritmos. EHMKE (2012) sugere experimentos computacionais com diferentes heurísticas, para melhorar a performance de rotas, assim, ao invés de se determinar a melhor rota para uma determinada solução, a máquina poderia processar diversas rotas para diversas situações.

2.2 APRENDIZADO DE MÁQUINA

O aprendizado de Máquina (do inglês *machine learning*) é uma forma de análise de dados, onde os próprios computadores aprendem por conta própria. Na verdade, são algoritmos que são projetados para se auto-ajustar, e isto é chamado de aprendizado.

Aprendizado de Máquina (*machine learning*), segundo CHOLLET (2018) é uma forma de Inteligência Artificial (IA) que permite que um sistema aprenda com os dados, e não através de programação explícita, como é o caso do ramo da IA simbólica. Tem-se dois tipos de aprendizado: supervisionado e não supervisionado. O objetivo do aprendizado supervisionado (AS) é encontrar padrões nos dados, que posteriormente, podem ser aplicados a outros dados. O AS parte de um conjunto de dados em que já exista uma classificação das observações, e com isto, calibra (“treina”) o algoritmo. Ao contrário do aprendizado não supervisionado (AnS), onde não há qualquer tipo de classificação ou organização dos dados. Há ainda algoritmos semi-supervisionados, que utilizam tanto dados rotulados quanto não-rotulados. Geralmente são criados para melhorar a precisão do aprendizado; e algoritmos de reforço, que é um método que interage com o seu próprio ambiente, produzindo ações e descobrindo erros ou recompensas. Pesquisa por tentativa e erro e recompensa atrasada são as características principais do aprendizado por reforço (SILVA et al., 2016; CASTRO et al., 2016).

Com o uso de ferramentas computacionais de aprendizado de máquina implementando-se algoritmos metaheurísticos, é possível solucionar problemas com uma complexidade elevada, dando uma ou mais possíveis soluções para determinados casos. Para isso é demandada uma alta capacidade computacional devido a quantidade de dados necessária para o algoritmo processar e “aprender”.

Em termos de ferramentas computacionais para aplicação de técnicas de Inteligência Artificial e *Machine Learning* existem diversas opções, sendo R e Python, as mais utilizadas (ZHANG, 2016).

NAZARI et al. (2018) apresentam uma aplicação de aprendizado por reforço para solucionar o PRV. Os autores mostram como a abordagem pode lidar com o PRV

explorando o efeito de entregas parceladas na qualidade da solução. Segundo os autores, o *framework* proposto pode ser aplicado a outras variantes do VRP, e tem o potencial de ser aplicado de maneira mais geral a problemas de otimização combinatória.

2.3 PROBLEMA DE ROTEIRIZAÇÃO DE VEÍCULOS - PRV

O problema do caixeiro viajante (PCV) foi o primeiro problema de rotas a ser estudado e, ainda hoje, é um dos mais conhecidos, tendo várias aplicações práticas e computacionais. O PCV é o problema em que um vendedor deseja visitar um conjunto de cidades, passando exatamente uma vez por cada uma e voltando ao ponto de partida no final do seu percurso (GOMES, 2008).

Já a roteirização de veículos pode ser definida como o atendimento de nós de demanda geograficamente dispersos, sendo que, para cada ligação entre um par de nós, há distâncias e custos associados. A fim de atendê-los, utiliza-se uma frota de veículos que partem e retornam a um depósito central. O objetivo é determinar o conjunto de rotas de menor custo que atenda às necessidades dos nós, respeitando restrições operacionais, tais como capacidade dos veículos, duração das rotas, janelas de tempo, duração da jornada de trabalho, entre outros. (WU, 2007). Este é o caso do PRV (em inglês, VRP - *vehicle routing problem*) que é um problema que envolve técnicas de otimização combinatória e programação linear. O problema busca encontrar as melhores rotas para uma frota de veículos que precisam atender um conjunto de pontos de demanda (CUNHA, 1997).

O interesse pelo PRV é crescente em face dos grandes centros urbanos, que geram necessidade de se desenvolver soluções de transporte para agilizar o fluxo de veículos, a chamada "*City Logistics*", (KIM et al., 2015). Estes autores levantaram os principais problemas relacionados ao PRV neste contexto específico. Identificaram que existem muitas variáveis ocultas em PRV's, gerando diferentes tipos de complexidade. Algumas de suas principais variantes, utilizando as siglas em inglês por serem mais conhecidas, são: VRP *with Time Windows* (VRPTW) em que os pedidos têm um intervalo de tempo pré-definido; VRP *with Heterogeneous Fleet* (HFVRP), em que os veículos não são do mesmo tipo; *Open VRP* (OVRP), quando os veículos não voltam para o ponto inicial; VRP *with pick-up and delivery* (VRP-pd) em que se tem coletas e entregas simultâneas.

Devido a sua alta complexidade e grande quantidade de variáveis, não há solução exata para este tipo de problema, sendo considerado um problema com tempo

polinomial não determinístico (NP-Difícil). Por isso, há muitas aplicações com diferentes técnicas, em que as metaheurísticas e heurísticas prevalecem.

Também têm sido desenvolvidos tentados outros métodos de solução com bons resultados. CUNHA e GUALDA (1997) apresentam uma heurística que é desenvolvida a partir da formulação de um modelo de programação inteira que é relaxado em algumas restrições. No que tange a metaheurísticas, os autores mostram que têm sido utilizadas, principalmente: Busca Tabu (*Tabu Search*); GRASP – *Greedy Randomized Adaptive Search Procedure* (Procedimento de Busca Adaptativa, Aleatória e Gulosa) e Algoritmos Genéticos.

PERBOLI, et al. (2017), por exemplo, realizam um estudo envolvendo um PRV baseado em um *framework* de simulação e otimização para entregas na região de Turin (Itália). O estudo mostrou diferentes abordagens de solução. CATTARUZZA, et al. (2015), por outro lado, identificaram e classificaram o PRV referente a distribuição de medicamentos na Europa e propuseram algumas metodologias de identificação para otimização de entrega de fármacos. Neste mesmo estudo é possível identificar que nem sempre os principais indicadores de performance do algoritmo são medidos em distância ou em tempo, e sim em uma mescla de problemas relacionados a VRPTW e VRP-pd.

Há, portanto, uma ampla gama de trabalhos relacionados ao assunto. LAPORTE (2009) apresenta uma ampla revisão de 50 anos de estudo da roteirização de veículos, demonstrando que há muita literatura disponível.

3. METODOLOGIA

O presente estudo teve uma abordagem quantitativa para seu desenvolvimento, sendo o seu principal objetivo criar uma metodologia, utilizando uma metaheurística em conjunto com técnicas de aprendizado de máquina (*machine learning*), podendo tornar a solução dinâmica para diferentes problemas de roteirização. Em termos de meios a utilizar no estudo, foi feita uma revisão bibliográfica do tema e serão usadas bases de dados disponíveis que são usadas para comparação de algoritmos. Num primeiro momento, realizamos o mapeamento dos principais problemas de roteirização existentes e classificamos suas complexidades.

Os dados utilizados para os experimentos foram selecionados a partir de bases de acesso público presentes na literatura (UCHOA et al. 2014). Após isto, foi feita uma adaptação dos dados a tecnologia utilizada na pesquisa com base nos parâmetros recebidos pelo modelo de aprendizado de máquina. No que tange aos modelo que foi

desenvolvido, o mesmo foi treinado para a otimização das rotas com base em uma frota com diferentes capacidades.

Os principais indicadores que foram utilizados para realizar o *benchmarking* do modelo são o desvio padrão, a variância e a distância final em comparação com a inicial, sendo uma taxa de redução da solução inicial. Também mensuramos os seus valores médios em cada conjunto de instâncias.

Em termos de principais etapas do estudo, tem-se:

1. Pesquisa Bibliográfica
2. Levantamento das Bases de Dados
3. Estudo das Ferramentas Computacionais
4. Estudo de Algoritmos em R da Metaheurística ABC
5. Desenvolvimento de Aprimoramentos no Algoritmo
6. Experimentos com as Bases de Dados
7. Análise de Resultados e Documentação

4. RESULTADO E DISCUSSÃO

Esta seção descreve o desenvolvimento da fase de aplicação do algoritmo, os experimentos desenvolvidos e os resultados obtidos, acompanhados de uma discussão sobre os pontos relevantes.

4.1 Desenvolvimento do Estudo

Neste estudo foi trabalhado a adaptação do algoritmo de enxame de abelhas (ou Artificial Bee Colony ABC) para o seu uso em um modelo de aprendizado de máquina. O ABC é um algoritmo genérico para solução de problemas de otimização (também conhecidos por NP-difícil). Suas características são baseadas no comportamento de abelhas para encontrar novas fontes de comida em um determinado espaço. Com base na otimização, o algoritmo ABC se resume em três etapas:

- Etapa das Abelhas operárias: Nesta etapa, cada operária irá procurar uma nova fonte de alimento na vizinhança da fonte atual, caso uma fonte melhor que a atual seja encontrada, ela se torna a nova fonte de alimento.
- Etapa das Abelhas observadoras: Nessa etapa, as abelhas observam a dança das operárias e escolhem uma delas para seguir, após definido o mesmo processo das abelhas operárias se repete. A diferença com relação

à etapa anterior é que existe um processo seletivo, sendo possível uma fonte de alimento ser explorada por mais de uma abelha. A ideia desta etapa é encontrar fontes de alimento de maior qualidade para intensificar as buscas em regiões promissoras.

- Etapa das Abelhas exploradoras: Caso a fonte de uma abelha operária não seja aprimorada por uma quantidade n de iterações, a abelha pode se tornar uma abelha exploradora, abandonando sua fonte de alimento atual e buscando aleatoriamente uma nova.




Figura 1. Fluxograma do algoritmo ABC

Com base nestas características, buscamos aplicar esta heurística a nossa modelagem de rotas a partir de vetores, onde se tem em um único vetor os pontos de demanda de uma região e o número dos veículos de uma frota que irão atender estes pontos. O conteúdo de cada posição do vetor, representa a sequência de Pontos e veículos.

PONTOS										Veículos		
1	2	3	4	5	6	7	8	9	10	11	12	13
3	2	4	12	10	7	9	8	11	5	6	13	1

Figura 2. Modelagem inicial das rotas baseadas em um vetor de 13 posições.

Em um exemplo de uma modelagem inicial com 10 pontos de distribuição e 3 veículos que irão percorrer as rotas determinadas, observando a sequência dos conteúdos, o veículo 11, irá atender os pontos 5 e 6, o veículo 13 irá atender os pontos 3, 2 e 4 e o veículo 12 irá atender os pontos 10, 7, 9 e 8.

Nesta modelagem inicial, o algoritmo proposto é inicializado a partir de um vetor obtido pelo resultado do ABC, depois cria-se um vetor de rotas onde no mesmo é identificado a posição de início de cada rota e o número de pontos para aquele veículo. Em seguida, acrescenta-se o Ponto de Origem de cada rota a fim de formar um circuito, no final as distâncias de cada ponto são consultados em um vetor auxiliar e sua distância global da rota é calculada com base no valor dos pontos dentro do circuito.

4.2 Tecnologias Utilizadas

Foram utilizados a Linguagem de programação R, no ambiente *R Studio*, junto com a biblioteca *MetaheuristicOpt* para o desenvolvimento do modelo de *machine learning* e o *script* de execução final. Os dados foram disponibilizados em bases no *Microsoft Excel* e para realizar seu tratamento, foi utilizada a linguagem de programação *Python* no ambiente *Jupyter Notebook*.

4.3 Execução dos Experimentos

Ao realizar a execução e o treinamento do nosso modelo, utilizamos a base de dados (UCHOA et al. 2014) e a adaptamos para o seu uso em vetores através de *scripts* de execução auxiliares. Após o seu tratamento, as bases estavam divididas em 101 instâncias com números distintos de pontos e veículos. Em cada instância executamos 10 rodadas para que o modelo tenha mais dados para otimizar a função objetivo do problema que é a redução da distância. Iniciamos os experimentos com a biblioteca *MetaheuristicOpt* onde contém a função de otimização ABC. Após isto, inicializamos a função objetivo, junto com a modelagem de vetores utilizados no projeto. Definimos as variáveis de ambiente, e carregamos as listas das instâncias das bases, contendo os pontos, posição x & y e distância (capacidade para os veículos). Depois definimos com base na instância carregada, quais são suas características para que o modelo entenda quais são os pontos e quais serão os veículos.

Após a inicialização do projeto, começa a etapa de treinamento, onde o modelo realiza uma repetição para um determinado número k de instâncias, e ao ser executado, podemos verificar o seu progresso nos arquivos que são salvos em cada execução, caso a instância atinja k , o sumário é salvo e a execução é finalizada.




Figura 3. Fluxograma de execução do experimento

4.4 Discussão dos Experimentos

Ao final do experimento, nota-se que houve uma redução no valor da distância original, obtida pela solução inicial do ABC, o modelo nos traz resultados melhores quando executados em menores conjuntos de dados, embora tenha uma variância maior.

Nome da Instância	Nº de Pontos	Distância Inicial	Distância Final	Variância (%)	Redução (%)
X-n101-k25	100	88.213,1	65.975,4	9,89%	25,21%
X-n148-k46	147	138.405,7	108.223,1	7,06%	21,81%
X-n195-k51	194	179.744,9	147.055,0	5,78%	18,19%
X-n242-k48	241	246.733,4	209.133,6	4,98%	15,24%
X-n289-k60	288	293.289,7	248.543,0	4,73%	15,26%
X-n336-k84	335	348.750,9	306.554,3	3,67%	12,10%
X-n420-k130	419	390.711,7	343.534,0	3,74%	12,07%
X-n524-k137	523	535.629,7	484.169,8	2,70%	9,61%
X-n655-k131	654	371.017,3	338.207,5	2,63%	8,84%
X-n819-k171	818	855.309,8	787.242,5	2,32%	7,96%

Tabela 1. Amostra dos valores médios de execução ($k = 10$)

Com base nos resultados obtidos, podemos verificar que a variância está correlacionada com a taxa de redução da distância final. Isso pode se dar devido a limitação da quantidade de dados nos pequenos conjuntos para o treinamento do modelo sendo que quanto mais pontos e veículos, mais possibilidades de permutações o algoritmo tem, existindo assim mais chances de encontrar uma rota com uma menor distância do que a atual.




Figura 4. Relação entre a redução e a variância com o número de pontos entre instâncias

5. CONSIDERAÇÕES FINAIS

Ao final destes experimentos, podemos concluir que com a utilização da heurística ABC adaptada à problemas de roteamento, conseguimos uma melhor distribuição de rotas dada uma frota veicular heterogênea, atingindo o objetivo de otimizar e reduzir distâncias. Embora este projeto não tenha abordado outros algoritmos, ainda é possível realizar um *benchmarking* com outras heurísticas existentes na literatura, para verificar se existe uma diferença de performance entre algoritmos, ou se uma abordagem híbrida com uma adaptação do algoritmo de *Dijkstra* realizaria uma melhor otimização em menor tempo.

6. REFERÊNCIAS

AYUMI, V. *et al.* Optimization of convolutional neural network using microcanonical annealing algorithm. **2016 International Conference on Advanced Computer Science and Information Systems (ICACSIS)**, [S.l], v. 1, n. 2016, p. 506-511, 2016.

BALLOU, Ronald H.. **Gerenciamento da cadeia de suprimentos / Logística empresarial**. 5. ed. Porto Alegre, RS: Bookman Editora, 2006.

BANDARU, Sunith; DEB, Kalyanmoy. Metaheuristic Techniques. **Decision Sciences**, Suécia, v. 1, n. 1, p. 693-750, 2016.

BELFIORE, Patrícia Prado; FÁVERO, L. P. L. Problema de Roteirização de veículos com janelas de tempo: revisão da literatura. **XIII SIMPEP**, Bauru, São Paulo, 2006. Disponível em: https://simpep.feb.unesp.br/anais/anais_13/artigos/675.pdf. Acesso em: 22 mar. 2020.

BODIN, L. D. *et al.* Routing and scheduling of vehicles and crews: Routing and scheduling of vehicles and crews. **Computers & Operations Research**, v. 10, n. 2, p. 63-211, 1983.

BOUSSAÏD, Ilhem; LEPAGNOT, Julien; SIARRY, Patrick. A survey on optimization metaheuristics. **Information Sciences**, [S.l.], v. 237, n. 10, p. 82-117, 2013.

CASTRO, L. N. D; FERRARI, Daniel Gomes. **Introdução à mineração de dados: Conceitos básicos, algoritmos e aplicações**. 1. ed. São Paulo: Saraiva, 2016.

CATTARUZZA, Diego; ABSI, Nabil; GONZALES-FELIU, Jesus. Vehicle routing problems for city logistics. **EURO Journal on Transportation and Logistics**, Ecole des Mines de Saint-Etienne and LIMOS UMR CNRS, Gardanne, França, v. 6, n. 1, p. 51-79, 2015.

CHOLLET, François. **Deep Learning with Python**. 1. ed. [S.l.]: Manning Publications, 2017.

CLARKE, G.; WRIGHT, J. W.. Scheduling of Vehicles from a Central Depot to a Number of Delivery Points. **Operations Research**, [S.l.], v. 12, n. 4, p. 568-581, 1964.

COLORNI, A. *et al.* Heuristics from nature for hard combinatorial optimization problems. **International Transactions in Operational Research**, [S.l.], v. 3, n. 1, p. 1-12, 1996.

CUNHA, C. B. D. Aspectos práticos da aplicação de modelos de roteirização de veículos a problemas reais. **Transportes**, São Paulo, v. 2000, n. 2, p. 51-74, 2000.

CUNHA, C. B. D; GUALDA, N. D. F. Uma contribuição para o problema de roteirização de veículos com restrições operacionais. **Universidade de São Paulo**, São Paulo, 1997.

D'AMICO, S. J. *et al.* A simulated annealing approach to police district design.

Computers & Operations Research, [S.l], v. 1, n. 29, p. 667-684, 2002.

EHMKE, Jan Fabian; MATTFELD, André; DIRK, Christian. Advanced routing for city logistics service providers based on time-dependent travel times. **Journal of Computational Science**, [S.l], v. 3, n. 4, p. 193-205, jul./2012.

GOMES, C. S. D. A. Problema do caixeiro viajante - resolução e depuração. **Dissertação (Mestrado em Matemática e Aplicações)**, Universidade de Aveiro, Portugal, jan./2008.

INRIX (2019). **Global Traffic Scoreboard**. Disponível em: <https://inrix.com/scorecard/>. Acesso em: 10 mar. 2020.

KIM, G. *et al.* City Vehicle Routing Problem (City VRP): A Review. **IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS**, Seoul, Coréia do Sul, v. 16, n. 4, p. 1654-1666, ago./2015.

LAPORTE, Gilbert. Fifty Years of Vehicle Routing. **Transportation Science**, [S.l], v. 43, n. 4, p. 407-548, nov./2019.

LIMA, Maurício Pimenta. Custos Logísticos na Economia Brasileira. **Revista Tecnológica**, [S.l], v. 11, n. 122, p. 64-69, 2006.

NAZARI, M. *et al.* Reinforcement Learning for Solving the Vehicle Routing Problem. **32nd Conference on Neural Information Processing Systems (NeurIPS 2018)**, [S.l], 2018.

NOVAES, Antonio Galvão. **Logística e gerenciamento da cadeia de distribuição**. 3. ed. Rio de Janeiro: Elsevier, 2007.

PERBOLI, G. *et al.* Simulation-optimisation framework for City Logistics: an application on multimodal last-mile delivery. **IET Intelligent Transport Systems**, Turin, Italia, v. 12, n. 4, p. 262-269, 2018. Disponível em: <https://digitallibrary.theiet.org/content/journals/10.1049/iet-its.2017.0357>. Acesso em: 25 fev. 2020.

SILVA, L. A. D; PERES, Sarajame Marques; BOSCARIOLI, Clodis. **Introdução à Mineração de Dados**: Com aplicações em R. 1. ed. Rio de Janeiro: Elsevier, 2016.

UCHOA, E. *et al.* New benchmark instances for the Capacitated Vehicle Routing Problem. **European Journal of Operational Research**, [S.l], v. 257, n. 3, p. 845858, mar./2017.

WU, Luciele. O Problema de Roteirização Periódica de Veículos. **Dissertação (Mestrado) - Escola Politécnica, Universidade de São Paulo**, São Paulo, 2007.

ZHANG, Nailong. **A Tour of Data Science**: Learn R and Python in Parallel. 1. ed. Nova Iorque, EUA: CRC Press, 2021. p. 1-205.

Contatos: uemajin@outlook.com e aavallim@mackenzie.br