

# ALOCAÇÃO ÓTIMA DE ESPAÇO CANAL RODOVIÁRIO A DIFERENTES MODOS: NOVAS FERRAMENTAS DE ANÁLISE

Luís Coimbra<sup>1</sup>, Álvaro Seco<sup>2</sup>

<sup>1</sup>Centro de Investigação do Território, Transportes e Ambiente (CITTA), Universidade de Coimbra, Departamento de Engenharia Civil, Rua Luís Reis Santos – Pólo II, 3030-788 Coimbra, Portugal

Email: [msimoes@uc.pt](mailto:msimoes@uc.pt) <http://www.uc.pt/fctuc/dec>

<sup>2</sup>Centro de Investigação do Território, Transportes e Ambiente (CITTA), Universidade de Coimbra, Departamento de Engenharia Civil, Rua Luís Reis Santos – Pólo II, 3030-788 Coimbra, Portugal

---

## Sumário

*A implementação de estratégias de ordenamento de tráfego deve ser feita tendo por base políticas que promovam um uso eficiente do espaço urbano. Já existem diversas recomendações para boas práticas na aplicação destas estratégias, mas ainda carecem de uma visão mais holística sobre o problema. Neste artigo é apresentada uma metodologia baseada na combinação de técnicas de simulação de tráfego com ferramentas de machine-learning. Esta metodologia é aplicada num caso representativo, que apresenta resultados promissores para a aplicação destas ferramentas em problemas de alocação segmentada de espaço canal rodoviário, e para estabelecer recomendações para a implementação de estratégias de ordenamento.*

**Palavras-chave:** Simulação, Transportes Públicos, Machine-Learning, Geração de Cenários

---

## 1 INTRODUÇÃO

Atualmente nos ambientes urbanos vive-se um clima de crescente cosmopolitismo e heterogeneidade. Isto também pode ser dito sobre os usos e funções que decorrem nestes ambientes, que também tem evoluído em termos de diversidade e complexidade. Os sistemas de transportes não são exceção, tendo havido uma crescente aplicação de soluções de mobilidade inovadoras que muitas vezes não são perfeitamente acomodadas na infraestrutura de transportes existente. A este facto acrescem as relações de intermodalidade, que têm tido atenção crescente por parte dos planeadores urbanos e gestores de transporte, aliadas a um crescimento das novas tecnologias de informação criadas para potenciar essas mesmas relações.

Estes desafios obrigam a acomodar as necessidades de diversos modos de transporte, sujeitas a condicionantes cada vez mais exigentes. Uma das principais ferramentas para gerir esta problemática é o desenho de infraestruturas de transporte e regulação de tráfego baseadas em políticas que assentam no tratamento privilegiado de certos modos de transporte, que são percecionados como mais eficientes ou cujo uso se pretenda incentivar. Esta discriminação de modos cria relações de *trade-off* complexas, uma vez que o benefício para uns vem muitas vezes a custo de um efeito negativo nos demais, nem sempre sendo claro em que medida que leva a um desempenho global melhorado [1].

A alteração da infraestrutura ou regulação de tráfego para implementar estas medidas é traduzida através de Estratégias Integradas de Ordenamento Viário e de Tráfego. A aplicabilidade de cada uma destas estratégias é extremamente dependente do ambiente rodoviário em que está inserida, existindo um conjunto alargado de parâmetros que podem afetar o desempenho de cada solução o que, aliado às relações complexas de *trade-off* entre os diversos modos de transporte, dificulta a generalização de recomendações de aplicação de cada estratégia. Esta dificuldade impossibilita a utilização exclusiva de modelos de simulação de tráfego, uma vez que a combinação de todos estes fatores não permite testar extensivamente todas as estratégias em todos os ambientes possíveis.

Neste artigo, é proposta uma metodologia inovadora que combina modelos de microsimulação de tráfego de referência, implementados através do software AIMSUN 8.1, com métodos de geração inteligente de cenários. Com base nesta combinação de técnicas, são extrapoladas conclusões sobre o desempenho de cada estratégia de

ordenamento para um conjunto representativo de cenários. Para a geração de cenários, foram utilizados dois métodos, o primeiro baseado em Árvores de Classificação e um segundo assente no algoritmo *Patient Rule Induction Method*.

Esta metodologia foi testada num caso representativo de uma avenida urbana, com 3 vias em cada sentido e com interseções semaforizadas com vias secundárias espaçadas homogeneamente. Esta rede viária é utilizada como base para testar várias estratégias de ordenamento baseadas em soluções do tipo via reservada a Transporte Público e Veículos de Alta Ocupação, num conjunto alargado de cenários representativos. O algoritmo de geração de cenários é utilizado para a alocação ótima das estratégias que apresentam melhor desempenho para cada cenário em tempo útil, permitindo evitar a simulação extensiva de todas as combinações estratégia-cenário.

No capítulo 2 do presente artigo é apresentada uma revisão de abordagens para a recomendação de estratégias de ordenamento, seguindo-se a apresentação do enquadramento da metodologia no capítulo 3. No capítulo 4 é apresentada a aplicação prática para a metodologia, cujos resultados são apresentados no capítulo 5. No capítulo 6 são discutidas algumas conclusões e dadas recomendações para trabalhos futuros.

## **2 A relação do espaço com as estratégias de ordenamento**

Relativamente ao estudo da alocação de espaço canal rodoviário aos transportes, já têm existido diversas abordagens para o problema. Particularmente, a alocação de espaço aos diversos usos, no contexto rodoviário, é normalmente feita através de estratégias de ordenamento, cujo o sucesso está muito dependente dos ambientes em que são implementadas.

Uma das preocupações primordiais para alocação de espaço estava relacionado com a expansão da rede viária, criando ou expandindo vias existentes, aumentando a capacidade disponível para a circulação de todos os veículos [2]. Este aumento de capacidade tinha como objetivo aumentar a acessibilidade ou para resolver problemas de congestionamento [3], constituindo o foco desta abordagem a filosofia de “servir toda a procura”, tendo uma forte preocupação com o nível de serviço dos veículos ligeiros [2], sendo que os restantes modos de transporte não eram considerados de maneira diferenciada na modelação [4]. Tendencialmente, esta abordagem apenas permitiu resolver os problemas de congestionamento temporariamente, uma vez que, devido ao aumento do nível de serviço e atratividade das vias, a procura apresenta um comportamento elástico, levando os níveis de congestionamento a retornarem aos verificados antes da expansão da rede [5].

Para contrariar a concentração excessiva no serviço de veículos ligeiros, foram propostas novas abordagens que expandiram os modelos anteriores para considerarem a rede de transportes públicos. Para além da definição do desenho da rede em si, há modelos que consideram explicitamente a implantação de estratégias de ordenamento que alocam o espaço disponível para a circulação rodoviária privilegiando certos modos de transporte, como o Transporte Público (TP). Ao ter uma maior e mais eficiente capacidade de transporte passageiros, numa situação em que não é possível aumentar a capacidade construindo novos arruamentos ou aumentando número de vias, a realocação de espaço entre os veículos ligeiros e veículos de transporte público pode oferecer soluções para mitigar o problema [6]. Por outro lado, este tipo de estratégias de ordenamento permite aos TP aumentar o seu nível de serviço, aumentando as velocidades comerciais praticadas e a fiabilidade do serviço, tornando-os mais competitivos e atrativos [1, 7–9]). Adicionalmente, quando são considerados outros critérios, é uma solução que contribui positivamente para a segurança rodoviárias, uma vez que reduz os conflitos entre veículos nos cruzamentos e com veículos estacionados [10] e que tem um efeito positivo no ambiente ao contribuir para a diminuição na emissão de poluentes [11]. Estas vias reservadas podem também permitir o uso por parte de outros tipos de veículos, como os Veículos de Alta Ocupação (VAO), veículos ligeiros que transportam 2 ou mais passageiros, que utilizam o mesmo espaço que um veículo ligeiro, mas têm o dobro da capacidade de transporte. Esta estratégia apresenta ainda outros benefícios na sua aplicação, como promover o *carpooling* e reduzir o tempo de atraso por passageiro [12].

Esta perspetiva cria relações complexas de *trade-off* entre modos de transporte, uma vez que se está, tendencialmente, a diminuir o nível de serviço dos veículos ligeiros para aumentar o nível de serviço dos TP, com o objetivo de melhorar o desempenho global em termos de pessoas transportadas. Este efeito pode ter um impacto significativo nos percursos e modos transporte escolhidos pelos utilizadores, pelo que alguns autores têm desenvolvido métodos que têm intrinsecamente considerados modelos de escolha de rotas [4, 6] e que tenham em conta a transferência modal [13].

Uma outra perspectiva para a alocação de espaço, mais do que estabelecer a localização ótima numa determinada rede, concentra-se na avaliação das estratégias de ordenamento em ambientes representativos e com isso procura propor recomendações para aplicação de cada estratégia de ordenamento. Para as estratégias de ordenamento com uma prática consolidada com vários anos de aplicação, já existem diversas recomendações elaboradas por autoridades de transportes baseadas na avaliação dessas implementações [14, 15]. Por outro lado, para práticas inovadoras, é comum utilizar modelos de simulação de tráfego para testar as estratégias em ambientes diversos e com essa informação elaborar recomendações para aplicação das mesmas [1, 9].

O enquadramento de análise utilizando estas técnicas normalmente envolve três fatores importantes: as estratégias que se pretendem analisar e como são implementadas, os critérios de análise que se irão ter em conta para avaliar o desempenho de cada solução e os cenários em que são testadas [1].

As estratégias que são consideradas mais frequentemente são baseadas em soluções do tipo via reservada, normalmente para transporte público rodoviário, mas também para VAO [1, 7, 9, 16]. As justificações para a consideração destas soluções prende-se com a experiência resultante da sua implementação generalizada [9], com a facilidade de implementação [16] e com o seu potencial para incentivo do uso de transportes coletivos [17].

Para a avaliação do desempenho é comum utilizar critérios relacionado com o nível de serviço da rede, ou apenas com o serviço de TP, que são considerados através de indicadores de desempenho habitualmente baseados nos tempos de percurso na rede, por veículo ou por pessoa transportada, ou nas velocidades médias praticadas [7, 8, 18, 19].

Os cenários de teste que são considerados são estabelecidos com o objetivo de serem representativos de estados críticos do sistema, em que o desempenho das estratégias apresenta um determinado comportamento característico. Deste modo, as conclusões obtidas permitem estabelecer os limites para a aplicabilidade de cada estratégia, enumerando para que ambientes em que estas são recomendadas, ou se devem ser evitadas. Esta abordagem por vezes resulta na definição de valores limite para a aplicabilidade das estratégias de ordenamento, que estabelecem a partir de que valor para um determinado parâmetro uma estratégia é recomendável ou desaconselhável [1, 7, 9].

Tipicamente, os cenários considerados são construídos à volta do volume de veículos na rede, expresso em valor absoluto ou como quociente da capacidade disponível. Estudos mais detalhados consideram também o número de passageiros transportados [9, 19], a repartição direcional nos cruzamentos [1] ou a repartição modal. Todavia, o número de cenários utilizado é bastante limitado, por vezes apenas 3 ou 4, que são estabelecidos em função de critérios nem sempre totalmente claros, decorrendo por vezes de pouco mais do que a experiência do autor.

### 3 Metodologia

Este trabalho apresenta um enquadramento para avaliação de estratégias de ordenamento de tráfego, com o objetivo de acrescentar às boas práticas para a implementação de cada uma. A base desta metodologia está firmada na conjunção de modelos de microssimulação de tráfego de referência, implementados a partir do pacote de software AIMSUN 8.1 [20], com algoritmos de geração inteligente de cenários de análise.

Estes algoritmos de pesquisa são baseados em técnicas de *machine-learning* de referência na literatura, nomeadamente em Árvores de Classificação (AC) [21] e no *Patient Rule Induction Method* (PRIM) [22, 23] com adaptações para a aplicação no problema. Estes dois algoritmos são implementados e comparados entre si, utilizando os valores do desempenho de cada estratégia de ordenamento de tráfego determinados por um modelo de microssimulação, que inicialmente é devidamente calibrado e validado. A estrutura da metodologia é assente num processo iterativo, onde o desempenho de cenários simulados é usado para direcionar a escolha dos cenários a testar na próxima iteração, limitando a avaliação de soluções apenas para os cenários mais representativos, e permitir uma indução de desempenho para todo o espaço dos cenários, sem ter de testar exaustivamente todas as soluções em todos os cenários possíveis.

No enquadramento proposto, em primeiro lugar são definidos os horizontes do problema, definindo as estratégias de ordenamento de tráfego que se pretendem avaliar (estratégias), em que ambientes serão testadas (cenários) e que critérios de avaliação irão ser usados. Inicialmente, as estratégias são definidas com base em políticas de ordenamento baseadas no incentivo a modos de transporte mais eficientes, e implementadas através da alteração da infraestrutura rodoviária e da regulação de tráfego. Dependendo da estratégia a testar, pode ser necessário desenvolver pequenas sub-rotinas que servirão de pré-tratamento das estratégias, antes de as transmitir ao modelo de simulação. De seguida, a definição dos cenários deve conter informação sobre os fatores externos à

infraestrutura que podem condicionar o desempenho de cada solução. Estes parâmetros devem ser suficientes para caracterizar adequadamente a procura na rede, escolha de rotas, repartição modal, assim como outros fatores que possam ser considerados importantes para a avaliação em causa. Deste modo, um cenário é definido por uma combinação de valores desses parâmetros e o espaço de cenários é constituído por todos os cenários possíveis de construir a partir dos parâmetros definidos. Finalmente, os critérios de avaliação devem transmitir as preocupações dos decisores, definindo os indicadores de desempenho mais pertinentes para a análise, permitindo avaliar se uma determinada solução cumpre os objetivos definidos ou não.

### 3.1 Geração de cenários

O processo de geração de cenários proposto tem como objetivo permitir a indução do comportamento de cada estratégia para todo o espaço de cenários, sem ser necessária a simulação extensiva para todas as combinações estratégia-cenário. Na prática, isto é feito através de algoritmos que usam a informação sobre o desempenho para os cenários simulados, para prever qual será a melhor estratégia para o restante espaço de cenários.

O processo é feito utilizando uma abordagem exploratória para a geração de cenários, implementada através de um processo iterativo. Nesta abordagem, em vez de simular todos os cenários, em cada iteração é escolhido um conjunto de cenários para serem usados para testar as estratégias no modelo de simulação. A inicialização do algoritmo é feita aleatoriamente, gerando um grupo inicial que corresponde a 5% do número total de combinações possíveis. De seguida, para cada iteração, são selecionados 10 cenários adicionais, mas apenas dentro do subconjunto de cenários cujas atribuições da melhor estratégia diferem significativamente das iterações anteriores.

Em cada iteração, o conjunto dos cenários escolhido é usado para simular as Estratégias definidas, sendo que, para cada um deles é escolhida a estratégia com o melhor desempenho. Com esta informação, são construídos os modelos de previsão baseados em Árvores de Classificação e PRIM, que irão ser usados para prever quais são as melhores estratégias para os cenários que não foram simulados, utilizando critérios específicos para cada método. A geração de cenários é interrompida quando iterações adicionais não alterem significativamente os grupos definidos, isto é, menos de 5 cenários mudam de melhor Estratégia. Estes algoritmos foram escolhidos por serem a referência na área, mas a estrutura proposta poderá incluir qualquer algoritmo ou modelo para a geração dos cenários.

#### Árvores de Classificação (AC)

O primeiro algoritmo utilizado foi baseado no método proposto por originalmente por [21], e tem sido utilizado para a geração de cenários, apresentando os resultados sob a forma de uma árvore de decisão que organiza hierarquicamente a divisão em classes dos dados de *input*. A forma generalizada como este algoritmo funciona começa com a seleção de um determinado valor de *input*, neste caso um parâmetro de cenário, e divide-o em dois valores, efetivamente dividindo o espaço dos cenários em duas regiões. Este processo de repartição é feito num “nó de decisão” da árvore, que resulta em novos “ramos”. O processo é sucessivamente repetido até o espaço dos cenários estar dividido em regiões homogéneas [24].

A implementação desta técnica é feita com recurso ao pacote *Classification Learner Toolbox* disponibilizado pelo *software* Matlab 2018b [25] que permite selecionar e treinar Árvores de Classificação, sendo possível definir alguns parâmetros que podem melhorar a capacidade de previsão do algoritmo. Para esta metodologia, foi selecionada a tipologia de Árvores Finas, uma vez que permite o maior número de repartições nos nós de decisão (100), permitindo a construção de modelos mais flexíveis.

A cada momento que a Árvore de Classificação é treinada, foi definido um procedimento de validação do modelo para prevenir o *overfitting*, ao dividir o conjunto de treino em cada momento em 5 grupos. Para cada grupo, o modelo treina uma árvore com os elementos dos restantes grupos, usando os elementos desse mesmo grupo para a validação, calculando o erro para cada grupo. O erro do modelo completo é a calculado a partir da média dos erros de todos os grupos. De notar que o erro aqui calculado não corresponde ao erro de previsão para os cenários não simulados, mas é relativo ao processo de treino de cada árvore de classificação. Relativamente ao processo para calcular repartições nos nós, o critério utilizado foi o Índice de Diversidade de Gini (IDG), que é baseado numa métrica que transmite o nível de heterogeneidade nos nós, em termos de pontos atribuídos a classes diferentes. Nestas repartições é privilegiada a escolha de repartições que levem a ramos com a maior uniformidade de classe possíveis, isto é, em cada nó é escolhida a repartição com o maior valor para IDG, definido de acordo com a equação 1, com base no valor da fração de pontos atribuídos à classe  $i$ ,  $p(i)$ :

$$1 - \sum_i p^2(i) \quad (1)$$

### Patient Rule Induction Method (PRIM)

O segundo algoritmo utilizado, o PRIM, foi inicialmente proposto por [23] e adaptado por [22, 24]. Este algoritmo consiste na divisão do espaço dos cenários em “caixas” que englobam zonas em que uma determinada política é recomendada ou não. Na prática, esta divisão é feita atribuindo a cada cenário o valor de 1 ou 0, consoante o desempenho da estratégia em análise é o melhor ou não, sendo que o algoritmo vai procurar as zonas em que o conjunto dos cenários tenha média próxima de 1. Todavia, uma das principais limitações do PRIM é que não é possível avaliar mais do que uma estratégia em simultâneo, o que obrigou a uma transformação na codificação do problema. Os autores de [26] recomendam que seja desenvolvido um PRIM para cada estratégia, e que as soluções sejam classificadas com 1 se a estratégia for a melhor para esse cenário, e 0 em caso contrário. Assim, para cada Estratégia o algoritmo é aplicado individualmente, sendo que, para cada cenário, é selecionada aquela cujo *output* PRIM associado apresenta média mais próxima de 1.

De uma maneira geral, o algoritmo é inicializado com a definição de uma “caixa” que envolve todas as soluções, que será sucessivamente dividida em “caixas” menores, incrementando sucessivamente o grau de homogeneidade em cada uma. A divisão é feita retirando “cascas” nas extremidades da caixa inicial definindo uma “trajetória de descasque”, que define a sucessão de reduções feitas às “caixas”. Este processo é controlado por dois parâmetros, *alphapeel* e *alphapaste*, responsáveis por definir o quantil de dados que são retirados a cada momento, e um fator de correção para evitar a remoção de demasiados dados, respetivamente. Na metodologia foi definido o valor de 5% para ambos os parâmetros. Para fazer a redução da caixa, o algoritmo enumera todas as “cascas” possíveis, escolhendo aquela que resulte numa nova caixa com a média mais elevada, ou seja, aquela que tenha o maior número de pontos em que a Estratégia em análise é a melhor. O processo é repetido até que não seja possível gerar mais “caixas” ou que o nível de desempenho atinja um determinado valor pré-definido.

A implementação do PRIM é feita recorrendo ao Matlab 2018b, utilizando um *script* feito por [26]. Como critério de paragem foi definido como limites um valor mínimo de valores dentro da “caixa”, estabelecido como 10% do número total de casos, para evitar “caixas” demasiado pequenas.

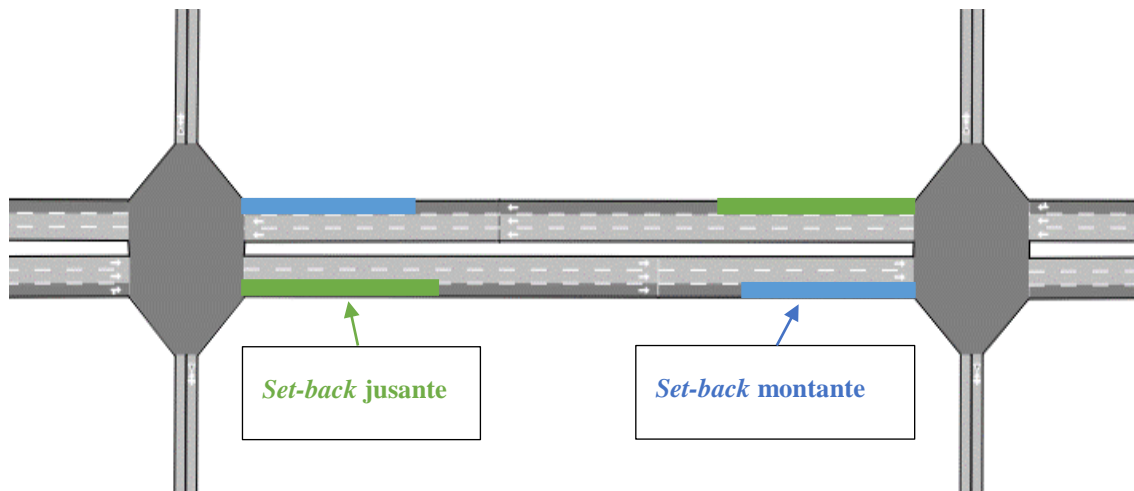
## 4 Aplicação prática

A aplicabilidade e eficiência da metodologia foi testada através um pequeno exercício de teste, onde é estudada uma rede representativa de uma avenida urbana comum. As estratégias selecionadas foram baseadas em soluções do tipo Via Reservada a Autocarro (Via BUS), e a Veículos de Alta Ocupação (Via VAO), que são comparadas com uma estratégia de base sem vias reservadas. Para além disso, para cada estratégia de Via Reservada, são definidas duas zonas a montante e a jusante de cada cruzamento, designadas por *set-backs*, em que é permitido o uso da via reservada por todos os veículos. A primeira zona, imediatamente depois de cada cruzamento, tem uma extensão de 90 m, para permitir que a saída do cruzamento não seja impedida a nenhum tipo de veículo [27]. A segunda zona *set-back* tem a extensão de 80 m e é usada exclusivamente para os movimentos de viragem à direita nos cruzamentos nas estratégias 2 e 4, e para os movimentos em frente e viragem à direita nas estratégias 3 e 5. A estrutura de todas as estratégias é apresentada no quadro 1.

Quadro 1. Estratégias de Ordenamento

Estratégia	Designação	Veículos Permitidos
1	Via Generalizada	Todos
2	Via Bus	Autocarros
3	Via Bus + →	Autocarros
4	Via VAO	Autocarros e VAO
5	Via VAO + →	Autocarros e VAO

A rede em si é composta por um eixo central com 3 vias em cada sentido, que cruza com duas intersecções com vias secundárias com 1 via por sentido, e espaçadas 250 metros entre si. A regulação das intersecções é feita através de sinais luminosos cujos tempos foram dimensionados para a estratégia 1, considerando o cenário em que a taxa de saturação no eixo principal é de 100 %. Para as estratégias 2 a 5, a via que é reservada aos veículos permitidos é sempre a via mais à direita por cada sentido, com as zonas de *set-back* que foram definidas no parágrafo anterior, e de acordo com o diagrama apresentado na Fig. 1.



**Fig.1. Estrutura da rede de teste.**

Para os cenários, foram estabelecidos 4 parâmetros diferentes para a construção de cenários: 1) taxa de saturação no eixo principal (TxS), que representa o rácio em percentagem entre o volume de tráfego e a capacidade existente no eixo principal, 2) a percentagem de veículos que viram à direita no eixo principal, relativamente ao total de veículos que entra em cada cruzamento, 3) a percentagem de autocarros relativamente ao volume total de veículos ligeiros equivalentes e 4) a percentagem de VAO relativamente ao volume total de veículos ligeiros equivalentes. Todos os parâmetros foram definidos como valores discretos para facilitar a organização de resultados, sendo os valores mínimo e intervalos apresentados no quadro 2, totalizando uma combinação de todos os valores possíveis um espaço de cenários de 1250 cenários.

**Quadro 2. Parâmetros para construção de Cenários.**

Parâmetro	Designação	Valor mínimo	Valor máximo	Intervalo
TxS	Taxa de saturação	30 %	120 %	10%
Turn	Percentagem de viragens à direita	5 %	25%	5 %
BUS	Percentagem de autocarros	3 %	12%	3 %
VAO	Percentagem de VAO	5 %	25%	5 %

Para cada cenário, a estratégia com o melhor desempenho é aquela que apresenta o menor tempo médio de atraso por pessoa transportada, em segundos. Este indicador é calculado com base na capacidade de transporte de passageiros para cada tipo de veículo, como demonstrado na equação 2, onde  $D$  é o tempo de atraso médio por passageiro e  $D_{veí}$ ,  $V_{veí}$  e  $Occ_{veí}$  é o tempo de atraso, volume e capacidade de transporte para cada tipo de veículo, respetivamente. Esta redução dos tempos de atrasos dos diversos modos de transporte num único valor permite comparar fácil e diretamente as estratégias, com um foco claro na maximização do nível de serviço para todos os usuários, sem favorecer um modo específico. Todavia, pode ser difícil avaliar a relação de *trade-off* entre os veículos que sofrem tratamento privilegiado e os restantes, uma vez que não há indicação do desempenho individual por cada modo.

$$D = \frac{\sum_{veí} D_{veí} \times V_{veí} \times Occ_{veí}}{\sum_{veí} V_{veí} \times Occ_{veí}} \quad (2)$$

As capacidades de transporte consideradas foram de 2 e 80 passageiros para os VAO e para os autocarros, respetivamente, e 1 para os restantes veículos, correspondendo ao número médio de pessoas transportadas por cada modo de transporte. Para avaliar e comparar a capacidade de previsão para as AC e o PRIM, todas as estratégias foram simuladas em todos os cenários, e o respetivo valor de tempo de atraso médio calculado. Para cada cenário é selecionada a melhor estratégia resultante dos valores da simulação, que servirão para comparar a qualidade da previsão dos algoritmos PRIM e AC.

## 5 Resultados

### 5.1 Desempenho relativo das Estratégias

Apesar de terem sido definidas 5 estratégias, duas delas não apresentam o melhor desempenho para nenhum dos cenários. As estratégias número 3 e 5, que representam as vias reservadas que permitem os veículos não prioritários usar o final da via para seguirem em frente no cruzamento, o que indica que, mesmo com este acréscimo de capacidade para os veículos ligeiros, não há melhorias significativas no desempenho.

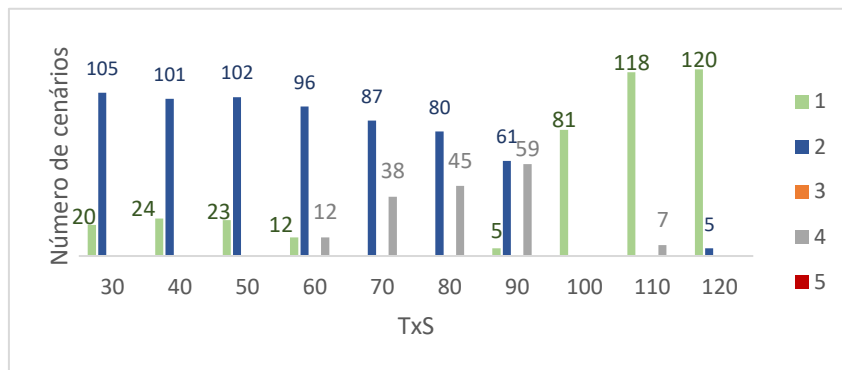


Fig.2. Número de cenários para cada estratégia.

Ao analisar a distribuição dos cenários pelas melhores estratégias, podem tirar-se algumas conclusões sobre quais são as estratégias recomendadas para cada região de cenários. Na figura 2 pode ver-se que, para Taxa de Saturação entre 30% e 50%, apenas as estratégias 1(Base) e 2 (Via Bus) apresentam melhor desempenho. Olhando para esta situação com mais detalhe, a figura 3 apresenta o número de cenários com as melhores estratégias 1 e 2 para valores de TxS entre 30% e 50%. Para estes casos, a estratégia Base apenas é melhor quando a percentagem de autocarros é reduzida, e que para valores acima de 6% de autocarros a estratégia Via Bus é a que deve ser aplicada.




Fig.3. Número de cenários para cada estratégia, para TxS entre 30% e 50%.

A partir da taxa de saturação de 100%, a estratégia 1 domina claramente as restantes estratégias, o que pode significar que para níveis de volume de tráfego elevados o acréscimo de capacidade oferecido aos veículos prioritários não compensa a diminuição do nível de serviço sofrido pelo tráfego generalizado. Nos cenários com volumes de tráfego intermédios, com taxa de saturação entre 60% e 90%, as estratégias que apresentam o melhor desempenho são as 2 (Via Bus) e 4 (Via VAO), o que indica que para intensidades de tráfego moderadas, a beneficiação dos tipos de veículos com capacidade de transporte de passageiros superior leva um melhor nível de serviço para toda a rede.

Comparando entre as estratégias 2 (Via Bus) e 4 (Via VAO), a figura 4 mostra que o que condiciona o desempenho de cada estratégia é essencialmente a percentagem de autocarros. Enquanto que para valores reduzidos a estratégia que deve ser implementada é a Via VAO, para situações em que há uma forte presença de autocarros, traduzida por percentagens acima de 12%, a estratégia recomendada é a Via Bus. Estes resultados parecem comprovar que há um benefício em permitir a VAO utilizar a reserva de capacidade nas vias reservadas quando o volume de autocarros é reduzido, mas, à medida que, este volume aumenta, o foco deve ser virado para a beneficiação exclusiva dos TP. Por outro lado, o número de VAO não parece condicionar o desempenho deste tipo de estratégias, o que pode ser explicado pelo facto deste tipo de veículos não estar obrigado a circular na via reservada, o que pode diluir o efeito da implementação desse tipo de estratégias para este tipo de veículos.




Fig.4. Número de cenários para cada estratégia, para TxS entre 60% e 90%.

## 5.2 Desempenho das Árvores de Classificação vs PRIM

Relativamente à capacidade dos algoritmos PRIM e AC de ajudarem no processo de geração de cenários, os resultados são apresentados na figura 5. Para a avaliação do desempenho destes processos foi analisada a capacidade de atribuir as melhores estratégias corretamente aos cenários, utilizando-se como atribuições corretas as que resultam da simulação sistemática de todos os cenários.

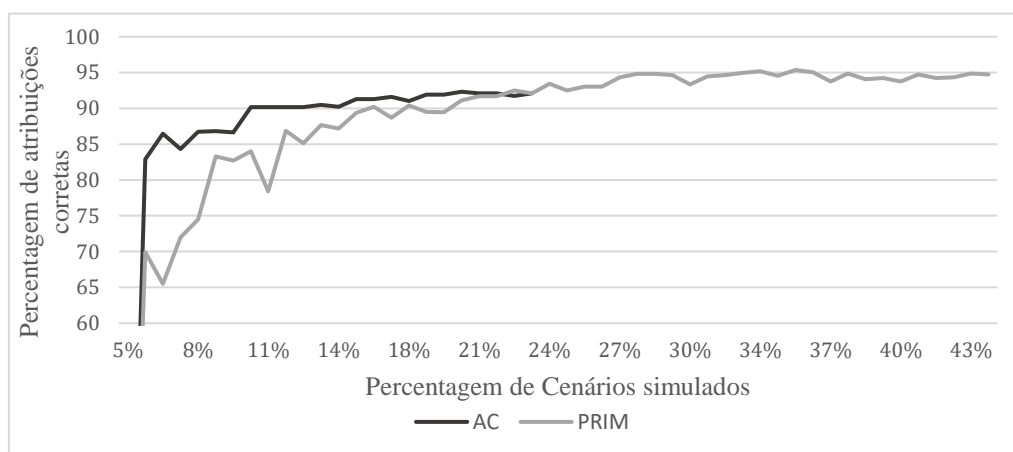


Fig.5. Percentagem de atribuições corretas por número de cenários simulados.

Para ambos os algoritmos as iterações iniciais parecem ser as mais críticas, em que há um crescimento inicial muito rápido da capacidade de previsão, começando depois a aproximar um patamar de estabilização, e com as AC a apresentarem um desempenho superior. A estabilização ocorre com a simulação de 200 cenários para o PRIM e 130 cenários para as AC, cerca de 16% e 10% do total dos cenários respetivamente, atingindo uma percentagem de atribuições corretas de cerca de 90%. Adicionalmente, ambos os métodos apresentam um tempo de computação semelhante, tendo as AC demorado 100,9 segundos, comparando com 82,6 segundos do PRIM, sem contar com o tempo das simulações. Contudo, a computação do primeiro encerrou-se com cerca de 270 cenários simulados, contra 550 cenários para o PRIM, o que indica que o segundo método necessita do dobro dos cenários simulados para atingir a mesma estabilidade que o primeiro.



## 6 Conclusões

Neste trabalho foi apresentada uma metodologia para a avaliação de estratégias de ordenamento de tráfego para a otimização da alocação de espaço aos modos de transporte na infraestrutura rodoviária. Essa metodologia é assente na microssimulação de tráfego para avaliação do desempenho de cada estratégia, complementado por um algoritmo de geração inteligente de cenários assente em dois métodos de referência na área de *machine-learning*: Árvores de Classificação e o *Patient Rule Induction Method*.

A metodologia proposta foi testada numa aplicação prática, que serviu de prova de conceito para a aplicabilidade e eficiência potencial. Foi desenhada uma pequena rede representativa de uma avenida urbana típica, a que foram implementadas 5 estratégias de ordenamento de tráfego baseadas em soluções do tipo via reservada para os transportes públicos e veículos de alta ocupação. Cada uma das estratégias foi testada num conjunto extensivo de cenários que totalizavam um total de 1250 combinações de situações.

No que diz respeito ao desempenho relativo potencial das estratégias, no problema tipo testado, chegou-se à conclusão que o uso das zonas *set-back* para os movimentos em frente nos cruzamentos não apresentou um impacto significativo no desempenho do sistema. Adicionalmente, foram identificadas 3 grandes regiões no espaço de cenários onde foi possível agrupar diferentes estratégias com base no seu potencial de aplicabilidade particular. Para níveis de tráfego baixos, as estratégias do tipo Via Bus apresentam um desempenho superior, exceto em situações em que o volume de veículo de TP é reduzido. Para uma rede sujeita a volumes de tráfego intermédios, as estratégias Vias Bus e Vias VAO são as que apresentam o melhor desempenho, sendo que a primeira se apresenta mais favorável à medida que a presença de veículos de TP aumenta. Para o último grupo, para situações em que se verifica algum nível de congestionamento, a disponibilização de todas as vias de trânsito ao tráfego generalizado apresenta melhor desempenho, uma vez que a implementação de vias reservada não providencia os benefícios suficientes para compensarem a perda de capacidade sofrida pelos veículos ligeiros.

Relativamente aos algoritmos para a geração de cenários, ambos apresentam potencial para ajudar a reduzir o número de simulações necessárias, tendo conseguido atingir uma capacidade de previsão correta de cerca de 90% das melhores estratégias para os cenários, simulando apenas 16% e 10% dos cenários para o PRIM e AC, respetivamente. Para o caso analisado, as AC apresentaram um desempenho ligeiramente superior ao PRIM em termos de atribuições corretas das melhores estratégias, necessitando também de um número inferior de cenários simulados para atingir o critério de convergência.

Contudo, apesar do enquadramento do problema ter o foco em ser representativo de diversos ambientes urbanos, ainda há a oportunidade de expandir a análise para outro tipo de soluções, inclusive em redes de tráfego reais, com por exemplo incluindo modos suaves. Por outro lado, o uso de apenas um indicador de desempenho pode ser expandido para uma análise multicritério, para que tenha seja possível uma comparação mais robusta entre estratégias.

## 7 AGRADECIMENTOS

Este trabalho foi desenvolvido no âmbito de uma bolsa de doutoramento financiada pela Fundação para a Ciência e Tecnologia, FCT, IP com a referência PD/BD/113736/2015.

## 8 REFERÊNCIAS

1. G. Currie, M. Sarvi, & W. Young, A new approach to evaluating on-road public transport priority projects: Balancing the demand for limited road-space, *Transportation*, 34(4), 413–428 , 2007.
2. B. Santos, A. Antunes, & E. Miller, Multiobjective Approach to Long-Term Interurban Multilevel Road Network Planning, *Journal of Transportation Engineering*, 135(9), 640–649 , 2009.
3. H. Yang, & M. G. H. Bell, Models and algorithms for road network design: a review and some new developments, *Transport Reviews*, 18(3), 257–278 , 1998.
4. E. Miandoabchi, R. Z. Farahani, W. Dullaert, & W. Y. Szeto, Hybrid Evolutionary Metaheuristics for Concurrent Multi-Objective Design of Urban Road and Public Transit Networks, *Networks and Spatial Economics*, 12(3), 441–480 , 2012.

5. T. Litman, *Generated Traffic and Induced Travel Implications for Transport Planning* , 2018.
6. M. Mesbah, M. Sarvi, I. Ouveysi, & G. Currie, Optimization of transit priority in the transportation network using a decomposition methodology, *Transportation Research Part C: Emerging Technologies*, 19(2), 363–373 , 2011.
7. Y. Chen, G. Chen, & K. Wu, Evaluation of Performance of Bus Lanes on Urban Expressway Using Paramics Micro-simulation Model, *Procedia Engineering*, 137, 523–530 , 2016.
8. D. Jepson, & L. Ferreira, Assessing travel time impacts of measures to enhance bus operations. Part I: past evidence and study methodology, *Road & Transport Research Journal*, 8(4), 41–54 , 1999.
9. D. Jepson, & L. Ferreira, Assessing Travel Time Impacts of Measures to Enhance Bus Operations Part 2: Study Methodology and Main Findings, *Road & Transport Research Journal*, 9(1), 3–18 , 2000.
10. City of Portland Office of Transportation, *Transit Preferential Streets Program* , 1997.
11. A. Alam, E. Diab, A. M. El-Geneidy, & M. Hatzopoulou, A simulation of transit bus emissions along an urban corridor: Evaluating changes under various service improvement strategies, *Transportation Research Part D: Transport and Environment*, 31, 189–198 , 2014.
12. M. Cassidy, & C. Daganzo, Deploying Lanes for High Occupancy Vehicles in Urban Areas, (February) , 2007.
13. Y. Bin, K. Lu, S. Yao, Y. Baozhen, & G. Ziyou, A bi-level programming for bus lane network design, *Transportation Research Part C: Emerging Technologies*, 55, 310–327 , 2015.
14. Department for Transport Local Government and the Regions, *Keeping Buses moving. A guide to traffic to assist buses in urban areas.* , 2001.
15. T. Brown, & R. Paling, *Getting more from our roads : an evaluation of special vehicle lanes on urban arterials October 2014* , 2014.
16. J. Viegas, & B. Lu, Widening the scope for bus priority with intermittent bus lanes, *Transportation Planning and Technology*, 24(2), 87–110 , 2001.
17. C. O’Flaherty, M. Bell, G. Leake, A. MAy, & C. Nash, *Transport Planning and Traffic Engineering*, (C. O’Flaherty, Ed.)*Chemistry & amp;* , 2004. Elsevier.
18. AECOM, *Transit Lane Warrants Study* , 2012.
19. T. Litman, *When Are Bus Lanes Warranted ?* , 2016.
20. TSS, *Aimsun 7 Dynamic Simulators User ’ s Manual September* , 2013.
21. L. Breiman, J. H. Friedman, R. A. Olshen, & C. J. Stone, *Classification And Regression Trees*, 1984.
22. B. P. Bryant, & R. J. Lempert, Thinking inside the box: A participatory, computer-assisted approach to scenario discovery, *Technological Forecasting and Social Change*, 77(1), 34–49 , 2010.
23. J. H. Friedman, & N. I. Fisher, Bump Hunting in High-Dimensional Data, *Statistics and Computing*, 9(2), 123–143 , 1999.
24. R. J. Lempert, B. P. Bryant, & S. C. Banks, Comparing Algorithms for Scenario Discovery, *RAND Infrastructure, Safety and Environment*, 1–35 , 2008.
25. Mathworks, *Matlab - Classification Learner Toolbox* , 2018.
26. G. Jekabsons, Bump Hunting using Patient Rule Induction Method for Matlab/Octave , 2015.
27. A. H. Pires da Costa, *Manual do Planeamento de Acessibilidades e Transportes: Transportes Públicos* , 2008.