

# Aplicação de Árvore de Decisão e Métodos de Precificação em Negociações entre Agentes em um Estacionamento Inteligente

Alexandre L. L. Mellado<sup>1</sup>, Gleifer Vaz Alves<sup>1</sup>, André Pinz Borges<sup>1</sup>

<sup>1</sup>Departamento Acadêmico de Informática  
Universidade Tecnológica Federal do Paraná (UTFPR)  
Ponta Grossa – PR – Brasil

mellado@alunos.utfpr.edu.br

{gleifer, apborges}@utfpr.edu.br

**Abstract.** *This paper proposes an extension of a multi-agent system developed using JaCaMo, in which drivers deliberate on a parking space price determined by a manager using a dynamic module. Here, six managers were implemented using different pricing methods. In this paper, we are looking forward to exploring the representation of the problem of negotiating process between agents using a decision trees to determine the bid approval and also define profiles of the managers involved. Three managers were deployed, respectively using a static tree, an iterative tree, and a combination of an iterative tree and a modified module. The remaining three managers apply prices statically, based on the type of vehicle, and using a modified module. By running the simulations with the managers in different scenarios, we noticed that using the solution based on the vehicle type rewards the parking with the most credits, followed by the decision tree methods. While the modified module and static pricing are the solutions that present the less amount of credits earned.*

**Resumo.** *Este artigo propõe uma extensão de um sistema multi-agente, desenvolvido em JaCaMo, em que motoristas deliberam sobre o preço de vaga determinado por um gerente utilizando um módulo de precificação dinâmico. Neste trabalho foram implementados seis gerentes, os quais utilizam diferentes métodos de precificação. A motivação deste trabalho é a representação do problema de negociação das vagas entre agentes utilizando árvores de decisão para determinar aprovação de ofertas e ainda definir perfis dos gerentes envolvidos. Três gerentes empregam respectivamente, uma árvore estática, uma iterativa e uma combinação de árvore iterativa e módulo modificado. Outros três gerentes aplicam preços de forma estática, referente ao tipo de veículo e usando o módulo modificado. Após as simulações dos gerentes em diferentes cenários é possível determinar que alterar o preço de acordo com o tipo do veículo gera mais créditos para o estacionamento, seguido pelos métodos de árvores de decisão. E as soluções baseadas apenas no módulo e no preço estático geram a menor quantidade de créditos.*

## 1. Introdução

A eficiência de estacionamentos tem muita influência sobre a qualidade de vida urbana. Neste ambiente, veículos estão estacionados 95% do tempo [Shoup 2021] e ocupam um

espaço considerável da Terra para estacionamento [Jakle et al. 2004]. A maioria das atividades de transporte são iniciadas ao entrar em um veículo estacionado e terminadas ao estacioná-lo novamente [Hasker and Inci 2014]. Logo, o gerenciamento de um estacionamento tem uma função importante no ambiente urbano e novas soluções podem contribuir na mobilidade e sustentabilidade de cidades.

O paradigma de *Smart City* abrange a integração de tecnologias com mecanismos urbanos para melhorar a sustentabilidade de cidades [Di Nocera et al. 2014]. Em questão de gerenciamento de vagas, um estacionamento inteligente (EI) compõe componentes com foco no uso eficiente dos recursos existentes. Um elemento importante para este gerenciamento é o método de precificação das vagas [Shoup 2021]. Em um EI, o controle e negociação do preço podem ser realizados por agentes implementados um sistema multi-agente (SMA) [Wooldridge 2009]. Essa negociação é a troca de mensagens entre agentes envolvidos até a formação de um consenso sobre a oferta proposta.

O Aprendizado de Máquina (AM) busca aprender automaticamente relacionamentos e padrões significativos a partir de exemplos e observações [Bishop 2007]. Avanços em AM permitiram o recente surgimento de sistemas inteligentes com maior capacidade cognitiva, aumentando produtividade, e adaptação às preferências individuais de usuários [Fischer et al. 2020]. Árvores de Decisão são uma abordagem que podem conter AM de forma supervisionada e usadas como método de classificação para tirar conclusões sobre um conjunto de observações [Sammut and Webb 2011]. Ao transformar ofertas de vagas em um problema de classificação, é possível utiliza-las nas negociações em um SMA.

Neste artigo é apresentado o uso de árvore de decisão e de um módulo de precificação em negociações entre agentes em uma simulação com diversos estacionamentos inteligentes. Estes mecanismos são utilizados pelos agentes gestores de cada estacionamento para aprovar ofertas recebidas de motoristas que aceitaram seus preços divulgados. As árvores de decisão foram criadas utilizando dados de simulações passados para determinar os atributos e pesos usados nas negociações. Foi usado o pacote *Weka* [Eibe et al. 2016] para gerar uma árvore base e para produzir as iterações seguintes. O módulo de precificação indicado é uma extensão de [Mellado et al. 2021]. Nesta nova versão, o módulo realiza uma previsão de demanda do dia seguinte utilizando os mesmos dados para gerar a árvore base.

A simulação do SMA apresentado foi implementado utilizando o *framework* JaCaMo [Boissier et al. 2013] e é uma extensão do Projeto Smart Parking<sup>1</sup> (UTFPR) de gerenciamento de estacionamentos inteligentes. As execuções desta simulação visam comparar diferentes métodos de precificação ou negociação de vagas e identificar quais as melhores abordagens para dados cenários. Este trabalho almeja obter as seguintes contribuições: **i.** estender a implementação do SMA e módulo de precificação desenvolvido em [Mellado et al. 2021]; e **ii.** aplicar árvores de decisão nas operações de negociação de agentes inteligentes no estacionamento inteligente.

A estrutura do trabalho segue por uma apresentação de trabalhos relacionados na seção 2. A descrição do SMA e dos métodos de precificação na seção 3. Exposição dos resultados na seção 4. E, na na seção 5 a conclusão é apresentada.

---

<sup>1</sup><https://www.smartparking.ipb.pt>

## 2. Trabalhos Relacionados

No artigo [Wang and Govindarasu 2020] é apresentado um *design* baseado em multi-agentes para melhorar a resiliência cibernética da Proteção da Integridade do Sistema utilizando uma árvore de decisão para detectar anomalias. Essa detecção é realizada por cada agente separadamente, mas a decisão final depende de um consenso. O SMA foi desenvolvido com o *Java Agent Development Framework* (JADE) e uma máquina de estado finita na troca de dados entre os agentes. Os resultados mostram que o *design* proposto pode detectar estados anômalos na rede, ajustar suas ações corretivas e adquirir maior resiliência diante de ataques maliciosos comparado a proteções centralizadas tradicionais.

O trabalho [Pozo et al. 2021] propõe uma predição de Nível de Serviço de estacionamento orientada por dados usando uma classificação de subamostragem aleatória em que é removido, aleatoriamente, elementos da classe majoritária até um equilíbrio com a classe minoritária. Os classificadores foram treinados e validados usando 13 meses de dados coletados de um estacionamento inteligente na cidade de Madri, da Espanha. Foram utilizadas três situações de ocupação como classe, baixa, média e alta. Os resultados deste método apresentam valores médios de revocação acima de 0.94 e 0.87 para previsões até 10 e 60 minutos, respectivamente, mesmo em cenários congestionados.

É proposto em [Kakkar et al. 2022] um esquema de previsão de preços de estacionamento baseado em *Blockchain* e usando Sistema de armazenamento associativo, que mitiga os custos de armazenamento. Além disso, é empregado um modelo de leilão de segundo preço para otimizar o preço do estacionamento para os usuários que pagam mais e beneficiando também os proprietários. Foram simulados 100 usuários com 40 vagas e usando diferentes modelos de leilão. Os resultados no artigo mostram que o esquema proposto é mais seguro, econômico e benéfico para usuários e proprietários de vagas de estacionamento do que esquemas tradicionais.

Estes trabalhos são relacionados devido a utilização de árvore de decisão ou técnica de precificação em EIs em suas soluções. O primeiro trabalho contém agentes utilizando árvore de decisão para melhorar a resiliência de um sistema; o segundo determina o nível de serviço por meio de árvore de decisão sem agentes; e o terceiro prevê o preço de um estacionamento por meio de um esquema baseado em *Blockchain*. Com isso, destaca-se que neste artigo é apresentado uma abordagem diferenciada do uso de agentes negociando o preço de vagas utilizando árvore de decisão em um EI.

## 3. Desenvolvimento dos Métodos de Precificação Dinâmicos

Neste trabalho, foram incorporadas árvores de decisão no processo de negociação. Anteriormente, o uso da vaga foi determinado com uma decisão binária: motorista aceita o preço ou não [Mellado et al. 2021]. O uso de árvores de decisão introduz um nível de aprendizagem aos gerentes em suas negociações com motoristas. Nos cenários simulados, os gerentes desconsideram os métodos uns dos outros, porém, motoristas escolhem o melhor preço após negociar com todos gerentes.

Com a implementação de diferentes métodos, este trabalho visa a simulação do comportamento de seis gerentes e identificar qual método de precificação usado promove o maior total de renda adquirida ao decorrer de um mês em tempo de simulação. Os motoristas consideram os preços de todos estacionamentos, tentam negociar por valores

menores e escolhem o menor disponível para estacionar. Os valores aceitos por cada motoristas são iguais em todas simulações. O horário de chegada e tempo de uso de vaga dos motoristas são encontrados durante a execução usando uma distribuição de Poisson.

### 3.1. Métodos de Precificação

Os métodos de determinação do preço das vagas são diferenciados entre os gerentes como apresentado na figura 1. O gerente 1 usa o mesmo valor em todas negociações; o gerente 2 difere conforme o tipo do veículo (motocicleta, carro ou caminhão); o gerente 3 decide com base em um modelo gerado por uma árvore de decisão; o gerente 4 utiliza uma árvore de decisão iterativa ao decorrer da simulação, isto é, uma árvore de decisão que evolui com novas informações; o gerente 5 usa de um módulo de precificação; e o gerente 6 escolhe o preço por uma árvore iterativa que incorpora o mesmo módulo do gerente 5.



**Figura 1.** Métodos de Precificação de cada gerente

Para todos os métodos é determinado um preço base (PB). No método referente ao tipo de veículo, os preços são negociados considerando essa informação dos motoristas. Para motocicletas o preço da vaga é PB menos 0,5; para carros o valor igual ao PB; e para caminhões os motoristas devem pagar PB mais 0,5. O método de intervalo de preço funciona de forma semelhante. Diferentes tipos de veículos possuem mínimos aceites menores, mas o preço não é estático e pode ser negociado dentro de um intervalo deste mínimo. No método referente a ocupação, o valor da vaga é alterado de acordo com a percentagem de vaga ocupadas no estacionamento. Quando vazio, o preço das vagas inicia com redução de 8% e aumenta em 5% para cada 20% de ocupação.

A partir das informações adquiridas em simulações prévias, padrões sobre o sistema podem ser determinados. Com essas informações pode-se criar uma árvore de decisão e observar padrões para um módulo de precificação baseado em demanda. Maiores detalhes sobre o módulo de precificação são encontrados em [Mellado et al. 2021].

### 3.1.1. Árvore de Decisão

Os componentes de uma árvore de decisão são os atributos de teste, os valores usados nos testes e as classes de resposta. Para este trabalho foram escolhidos o preço e o tipo do veículo como atributos. Estes são os elementos utilizados nas ofertas entre agentes. Os valores de teste são determinados utilizando simulações passadas realizadas sem negociações dinâmicas neste mesmo sistema. Cada valor é encontrado usando o número de pedidos de cada preço para determinar a frequência e pesos. Para o tipo, foram usados três tipos de veículos nestas simulações passadas, os quais são então usados na árvore. As classes de respostas representam a aprovação de uma oferta e portanto são divididas entre sim e não. A figura 2 mostra a árvore de decisão encontrada a partir dos dados destas simulações passadas e a qual é utilizada nos métodos dos gerentes três, quatro e seis.

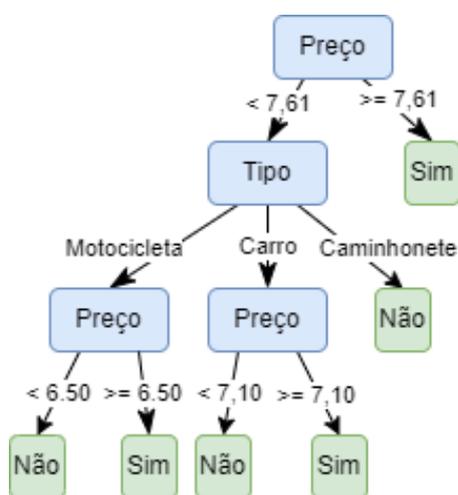


Figura 2. Árvore de Decisão Base

Enquanto o gerente três utiliza esta árvore base por toda a simulação, para os gerentes quatro e seis, a árvore de decisão da figura 2 é o ponto inicial e será atualizada usando novas informações ao decorrer de uma execução. Uma árvore de decisão funciona como uma sequência de perguntas que leva a uma resposta. As árvores neste trabalho realizam perguntas sobre as ofertas recebidas de motoristas. Uma oferta contém o preço desejado e o tipo do veículo. Por exemplo, usando a árvore de decisão base da figura 2 uma oferta de 7 créditos de um carro é recusada.

A criação das árvores de decisão usadas neste trabalho são realizadas por meio do pacote *Weka* [Eibe et al. 2016]. Através dos logs criados em simulações anteriores, estes são reformatados em um arquivo arff, usando um artefato do sistema em *JaCaMo* e classificado pelo algoritmo J48 (C4.5) usando linha de comando. Este classificador retorna uma resposta em *string* que contém a árvore de decisão resultante. Este texto é analisado e transformado em uma estrutura de dados em formato de árvore e guardado para ser utilizado no futuro no sistema.

### 3.1.2. Módulo de Precificação

O módulo de precificação utiliza as demandas passadas para prever as circunstâncias do mês atual. Este módulo funciona por comparar a demanda observada no mês anterior e, pelo o arquivo de configuração da tabela 1, determina o novo preço das vagas.

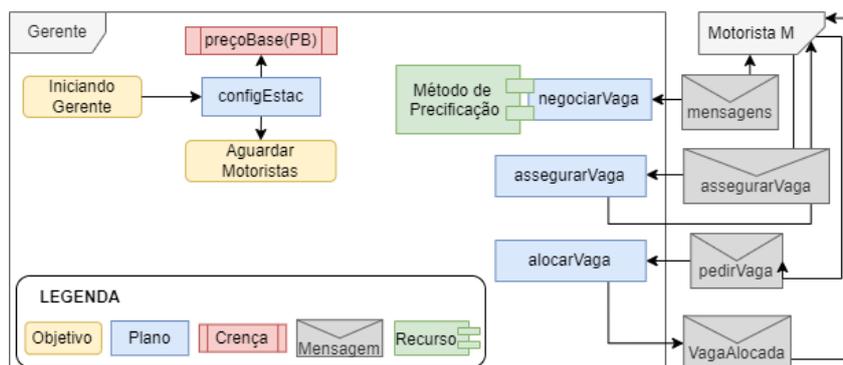
**Tabela 1.** Arquivo de Configuração

ID	String	Intervalos
1	Demanda	0-0.2-0.4-0.6-0.8-1
Categoria	Condição	Valor
Demanda	MuitoBaixa	-0.1
Demanda	Baixa	-0.05
Demanda	Média	0.0
Demanda	Alta	0.05
Demanda	MuitoAlta	0.1

Por exemplo, para o dia 5, caso a ocupação média neste dia no mês anterior seja de 72%, a configuração considera este valor de demanda como alta e o preço da vaga aumenta em 5%. Neste sistema, o valor base de todos os estacionamentos é de 8 créditos. Um aumento de 5% resulta em um valor de 8.4 créditos.

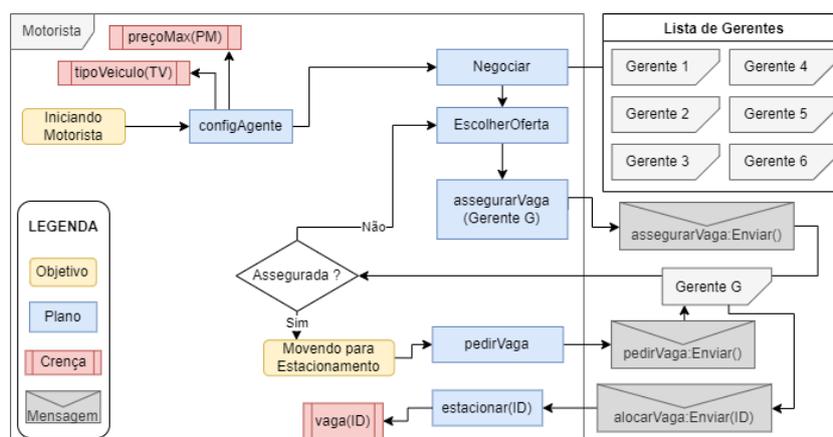
### 3.2. Sistema Multi-agente

A simulação foi realizada utilizando um SMA composto de dois tipos de agentes: gerentes que controlam o gerenciamento de um estacionamento; e motoristas que utilizam as vagas nestes estacionamentos. A figura 3 mostra o processo de interação com os motoristas. Cada gerente iniciado possui um método de precificação diferente usada durante a negociação por vagas. Este método é determinado em sua criação e o gerente não é capaz de modificar seu funcionamento além das maneiras propostas em cada um. Após a negociação com um motorista, este pode requerer a reserva da vaga negociada para quando chegar ao estacionamento receber o espaço alocado.



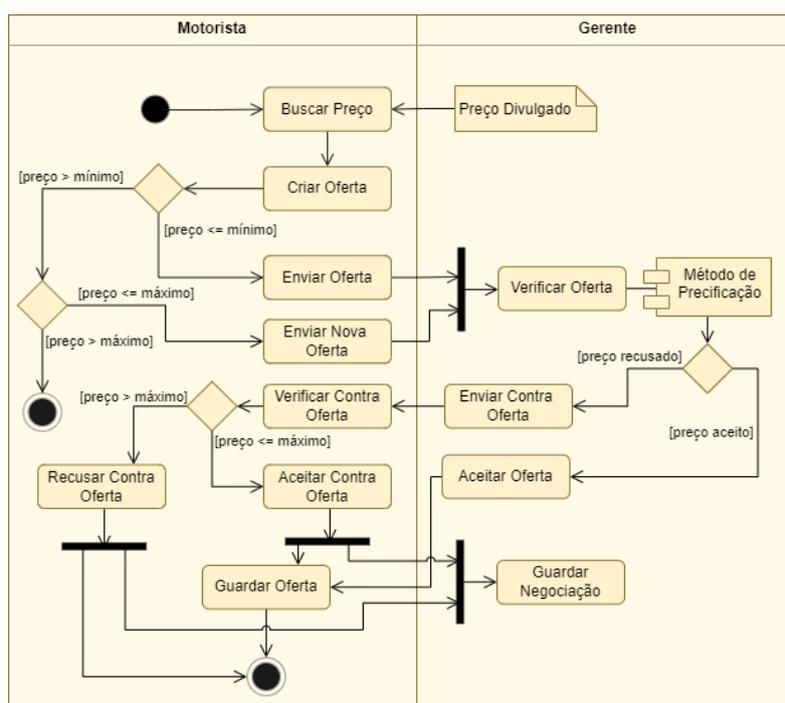
**Figura 3.** Diagrama do Gerente

A figura 4 mostra o lado dos agentes nestas negociações. Cada motorista negocia com todos gerentes. Após finalizar todas as trocas de ofertas, o motorista escolhe aquela com o menor preço. Ocorre logo a reserva desta vaga. Caso a vaga não esteja mais disponível, o motorista escolhe a próxima melhor oferta. Ao confirmar a vaga assegurada, o motorista encaminha-se para o estacionamento, pede a vaga e estaciona.



**Figura 4.** Diagrama do Motorista

A figura 5 mostra o processo de troca de ofertas entre um motorista e gerente. As negociações são sempre iniciadas por motoristas. Estes começam buscando, verificando e criando uma oferta com o preço divulgado pelo gerente. Este é o preço de negociação inicial de cada gerente e pode mudar ao decorrer da simulação.



**Figura 5.** Diagrama do protocolo de negociação entre o motorista e o gerente

A partir deste preço, o motorista inicia o processo de criação de uma oferta. Esta contém o tipo de veículo e um preço aceito pelo motorista. Todo motorista possui um valor mínimo, máximo e desejado para negociar. O valor mínimo indica após quanto o motorista aceita sem nenhuma negociação. O valor máximo é quanto o motorista aceita pagar. O valor desejado encontra-se entre o mínimo e o máximo e indica o preço em que o motorista aceita uma oferta e dispensa a negociação com outros gerentes. Caso o preço divulgado seja menor que mínimo aceito pelo motorista, o valor não é alterado, caso seja

maior que seu máximo aceito, ele ignora o estacionamento, e caso esteja entre o dois, é enviado uma oferta com valor na metade de seu mínimo e máximo.

Ao receber uma oferta, o gerente utiliza o seu método de precificação para determinar se aceita ou não. Quando o gerente aceita, é enviado uma mensagem de confirmação e o motorista guarda a oferta negociada. Quando recusada, o gerente gera, usando seu método, e envia uma contra-oferta ao motorista. O preço é comparado ao máximo do motorista. Caso maior, a contra-oferta é recusada e o motorista termina a negociação. Caso menor ou igual, ela é aceita e o motorista guarda esta oferta para decisão futura.

#### 4. Resultados

Foram executados experimentos a partir de 15 simulações, 5 vezes para cada um dos 3 cenários e os resultados mostram a média entre eles. Os cenários simulados possuem diferença somente na quantidade de vagas disponíveis. A tabela 2 apresenta a especificação de cada um. Os 600 motoristas são divididos em 200 veículos para cada tipo (motocicleta, carro e caminhão). Foram determinados três níveis de demanda: alta, quando o número de motoristas é maior que o de vagas disponíveis; exata, quando o número de motoristas e vagas é o mesmo; baixa, quando o total de vagas é superior ao número de motoristas na simulação.

**Tabela 2.** Especificação dos cenários simulados

Cenário	Total de Motoristas	Total de Vagas
Demanda Alta	600	300
Demanda Exata	600	600
Demanda Baixa	600	900

A tabela 3 mostra os resultados dos métodos de precificação em cada cenário de demanda simulada. A taxa de sucesso de venda ( $tsv$ ) representa o número de vendas sucedidas ( $vs$ ) em comparação com o total de negociações ( $tn$ ) realizadas, ou seja:  $tsv = tn/vs$ . Dentre os métodos utilizados, alterar o preço segundo o tipo do veículo possuiu a maior  $tsv$  e logo obtém a maior quantidade de créditos e de taxa de ocupação. Isto ocorreu devido uma característica no protocolo de negociação. Neste processo, uma peculiaridade aparece em que o preço da vaga poderia ser menor em outros métodos, mas a negociação termina após duas ofertas. Logo o preço baixo para motocicletas gera ganhos constantes ao ser escolhido um maior número de vezes.

Analisando os métodos das árvores de decisão. Em geral, a árvore estática teve resultado levemente melhor que a iterativa, que por sua vez ficou um pouco acima daquela usando demanda. Esses dados indicam que a forma de aprendizado implementado, em conjunto com o protocolo de negociação, obteve rendimentos menores que um método mais simples. Por último, encontra-se o método que considera a demanda e aquele em que o preço é estático durante a execução. Ambos métodos obtiveram os piores resultados. Enquanto o método que considera a demanda adquire em torno de 1/3 dos totais prévios, o preço estático consegue vender uma vaga em apenas 1% de suas negociações.

Diferentes métodos possuem resultados maiores em diferentes demandas. O preço estático adquire desproporcionalmente mais créditos durante os cenários de alta demanda.

**Tabela 3.** Comparação entre Métodos de Precificação

Método de Precificação	Demanda Simulada	Créditos Adquiridos	Ocupação Média (%)	Taxa de sucesso de Venda
Preço Estático	Alta	25.712	4,44	0,015
	Exata	<b>5.019</b>	0,45	<b>0,003</b>
	Baixa	5.528	<b>0,32</b>	<b>0,003</b>
Referente ao Tipo do Veículo	Alta	387.885	<b>74,10</b>	0,253
	Exata	<b>436.141</b>	41,39	<b>0,284</b>
	Baixa	432.243	27,48	0,281
Árvore Estática	Alta	377.937	68,27	0,234
	Exata	360.491	32,73	0,218
	Baixa	353.536	21,34	0,217
Árvore Iterativa	Alta	373.049	66,41	0,227
	Exata	353.786	32,34	0,215
	Baixa	383.454	23,26	0,231
Baseado em Demanda	Alta	109.972	28,86	0,067
	Exata	139.882	20,68	0,084
	Baixa	140.033	13,99	0,084
Árvore Iterativa usando Demanda	Alta	338.371	60,23	0,205
	Exata	335.902	30,25	0,199
	Baixa	314.282	19,15	0,188

Devido ao menor número de vagas disponíveis, um grupo de motoristas que aceitam pagar o seu preço inegociável, estacionam nestas vagas devido à disponibilidade de outros estacionamentos. O estacionamento com preço referente ao veículo é melhor em qualquer demanda, mas possui resultados superiores em demanda exata. Seu créditos são menores em demanda alta devido ao menor número de vagas e logo menor total de créditos disponíveis no sistema. Devido a semelhança de precificação e logo maior competição direta, os resultados dos métodos de árvores são próximos uns dos outros mesmo em mudança de demanda. Os resultados do método baseado em demanda indicam que o mês passado não refletiu completamente as situações futuras. Em demanda alta, situação em que se esperava melhor resultado do modelo, conteve menor total de créditos recebidos.

#### 4.1. Evoluções das Árvores de Decisão

A figura 6 mostra as principais iterações envolvidas no aprendizado das árvores de decisão utilizadas no sistema. As iterações indicadas na imagem destacam o último momento em que a árvore mostrada possui seu formato. Como a escolha de quando aprender é subjetiva, foi determinado arbitrariamente que uma nova iteração é gerada a cada 5 dias de simulação usando os novos dados adquiridos por negociações. Para as árvores inferiores, uma nova iteração também ocorre quando o preço é alterado pelo módulo de precificação.

A progressão das árvores na figura mostra como os novos dados influenciaram na construção de novas versões. Para o método sem módulo, as mudanças começam pequenas, apenas alterando um valor de teste, seguido de maiores alterações na estrutura da árvore, passando a considerar o tipo do veículo como verificação principal na decisão sobre a oferta do motorista. No caso do método contendo uso do módulo, a importância do tipo do veículo ocorrer mais cedo e a mesma árvore do método anterior é alcançada. Contudo, após 15 iterações o preço passa a ser o único componente considerado.

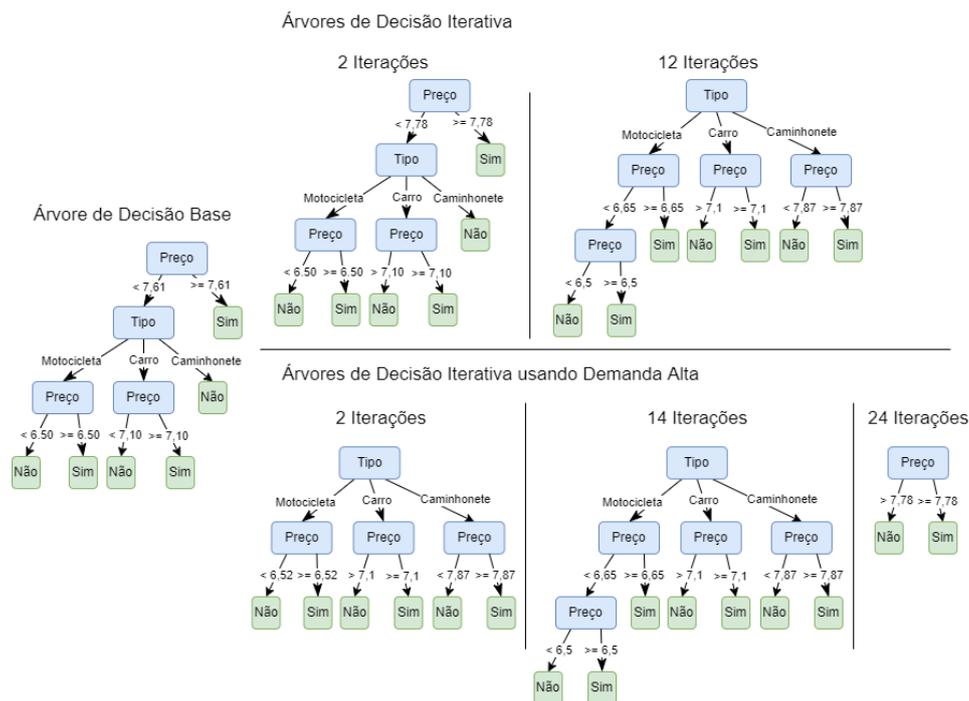
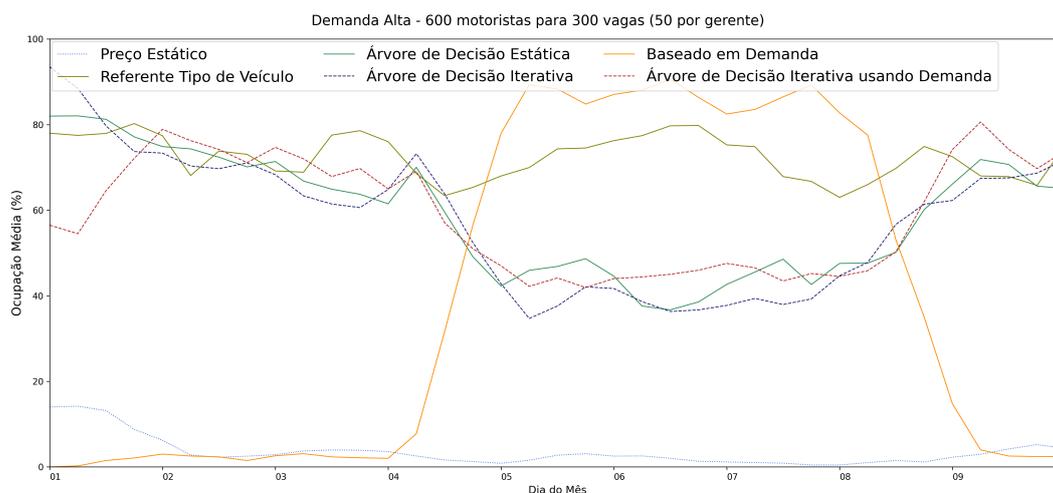


Figura 6. Aprendizado das Árvore de Decisão ao decorrer da simulação

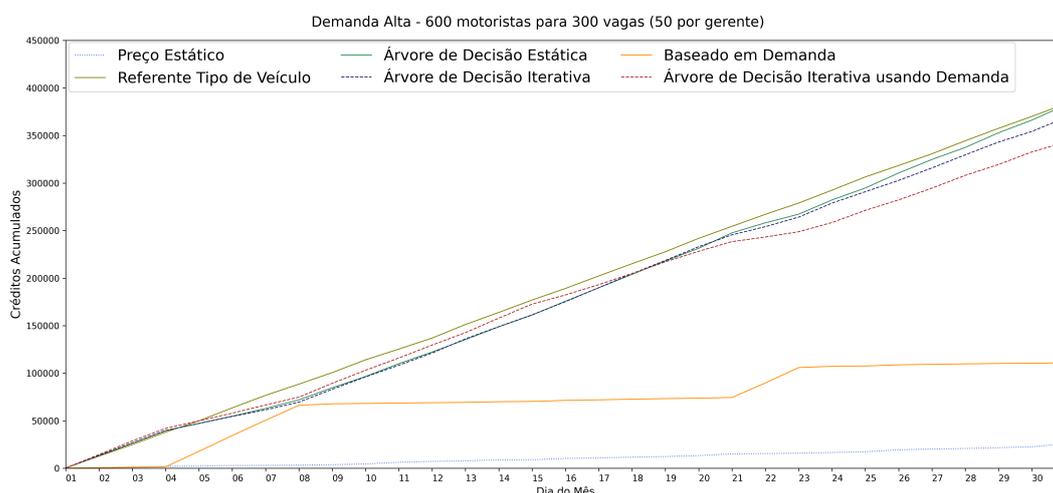
#### 4.2. Ocupações e Acúmulo de Créditos

As figuras 7 e 8 apresentam gráficos especificamente das simulações de cenários com demanda alta, isto é, quando o total de motoristas é maior que o total de vagas. O gráfico na figura 7 apresenta um trecho de ocupações apenas até o dia 10. Este período foi escolhido para mostrar a progressão dos gerentes sem um grande volume de dados. Nesta condição as características mais diferenciadas são do preço estático, baseado em demanda e referente ao tipo de veículo. A ocupação em preço estático é a menor em geral, apenas no início, quase alcançando taxa de 20%. As taxas usando o tipo de veículo são estáveis em toda a simulação, mesmo com a maior competição entre os dias 4 e 9. Para o gerente baseando-se em demanda, apenas nos dias em que a demanda foi prevista como baixa, ocorrem taxas relevantes de ocupação. Entre o 4º e 9º dia, a redução do preço neste estacionamento causa queda na ocupação de outros com valor mais alto.

O gráfico na figura 8 mostra a progressão do acúmulo de créditos ao decorrer do mês de cada método de precificação. O preço estático, por causa de seu valor alto, contém o menor ganho de créditos quando comparado aos demais métodos. Neste cenário, os melhores resultados ocorrem ao considerar o tipo de veículo e árvore estática. Todos os três métodos que envolvem as árvores possuem progressões semelhantes. Os três adquirem menos créditos nos períodos em que o próximo método possui um preço menor. Este último método utiliza o módulo de precificação baseando-se apenas em demanda. Neste, os preços são altos demais durante grande parte da simulação, mas nos períodos referentes aos dias 4 e 9; e 21 a 29, os preços são reduzidos e o método tem maior preferência dos motoristas.



**Figura 7.** Taxas de Ocupação no cenário de demanda alta até o dia 10



**Figura 8.** Acúmulo de créditos ao decorrer do mês no cenário de demanda alta

## 5. Conclusão

O gerenciamento de espaços usados como vagas é importante para o ambiente urbano, ao considerar que veículos passam a maioria de seu tempo estacionados. Diferentes estratégias podem influenciar os cenários de mobilidade urbana. Este artigo apresentou uma abordagem com o uso de árvores de decisão e um módulo de precificação durante as negociações entre gerentes e motoristas em um SMA. Foram comparados diferentes métodos de precificações da vaga a partir de simulações em diferentes cenários de demanda. Entre os cenários executados, aquele que obteve melhores resultados foi com o método que utiliza somente o tipo do veículo para escolher o preço. Observando o sistema após as simulações, encontra-se que este resultado é superior devido a uma peculiaridade no protocolo de negociação em que motoristas negociam até encontrar um preço que aceitam. Desta forma, enquanto os preços usando árvores podem ser menores, motoristas finalizam a negociação em valores maiores que deste estacionamento. Dentre as implementações de árvores de decisão, aquela inalterada durante a simulação foi a me-

lhor nos cenários de demanda exata e alta, enquanto a árvore iterativa obteve melhores resultados nos cenários de baixa demanda.

Como trabalho futuro, espera-se ampliar o escopo dos métodos implementados, assim utilizar outros classificadores. Isto é, utilizar mais atributos para a árvore de decisão e outras características para o módulo dinâmico. Além disso, pretende-se implementar novos métodos de precificação com algoritmos de aprendizagem por reforço. O protocolo de negociação igualmente pode ser adaptado, de forma a incluir a competição direta entre gerentes ao permitir que eles tenham acesso ao preço uns dos outros.

## Referências

- Bishop, C. M. (2007). Pattern recognition and machine learning (information science and statistics).
- Boissier, O., Bordini, R. H., Hübner, J. F., Ricci, A., and Santi, A. (2013). Multi-agent oriented programming with jacamo. *Science of Computer Programming*, 78(6):747–761.
- Di Nocera, D., Di Napoli, C., and Rossi, S. (2014). A social-aware smart parking application. In *WOA*.
- Eibe, F., Hall, M. A., and Witten, I. H. (2016). The weka workbench. online appendix for data mining: practical machine learning tools and techniques. In *Morgan Kaufmann*. Morgan Kaufmann Publishers.
- Fischer, M., Heim, D., Hofmann, A., Janiesch, C., Klima, C., and Winkelmann, A. (2020). A taxonomy and archetypes of smart services for smart living. *Electronic Markets*, 30(1):131–149.
- Hasker, K. and Inci, E. (2014). Free parking for all in shopping malls. *International Economic Review*, 55(4):1281–1304.
- Jakle, J. A., Jakle, J. A., Sculle, K. A., and Sculle, K. A. (2004). *Lots of parking: Land use in a car culture*. University of Virginia Press.
- Kakkar, R., Alzubi, J., Dua, A., Agrawal, S., Tanwar, S., Agrawal, R., Sharma, G., Bokoro, P. N., and Sharma, R. (2022). Padaav: Blockchain-based parking price prediction scheme for sustainable traffic management. *IEEE Access*, 10:50125–50136.
- Mellado, A. L. L., Alves, G. V., Leitão, P., and Borges, A. P. (2021). Um módulo de precificação dinâmica em sistema multiagente de um estacionamento inteligente. *Revista Eletrônica de Iniciação Científica em Computação*, 19(1).
- Pozo, R. F., González, A. B. R., Wilby, M. R., Díaz, J. J. V., and Matesanz, M. V. (2021). Prediction of on-street parking level of service based on random undersampling decision trees. *IEEE Transactions on Intelligent Transportation Systems*.
- Sammut, C. and Webb, G. I. (2011). *Encyclopedia of machine learning*. Springer Science & Business Media.
- Shoup, D. C. (2021). *The high cost of free parking*. Routledge.
- Wang, P. and Govindarasu, M. (2020). Multi-agent based attack-resilient system integrity protection for smart grid. *IEEE Transactions on Smart Grid*, 11(4):3447–3456.
- Wooldridge, M. (2009). *An introduction to multiagent systems*. John Wiley & Sons.