

Indução de demanda de transporte público através da identificação de padrões e cashback.

Gustavo Wagner Nunes Balieiro¹; [Ricardo Brito Alves](mailto:ricardo.alves@ecobonuz.com)²; Carlos Vinícius Bindewald²; Túlio Lima Lessa Carvalho²; Talisson Lins Rocha¹; João Leonardo Nunes Balieiro¹

¹Aequante Planejamento, Operação e Inovação na Mobilidade LTDA – Avenida Raja Gabaglia, 2680 – Estoril, Belo Horizonte – MG – (31) 3049-4170

gbalieiro@aequante.com; Talissonlins74@gmail.com; joaoleonardo@aequante.com

²Ecobonuz Marketing e Fidelidade S/A – Rua Gonçalves Dias, 874 – Sala 402 – Savassi, Belo Horizonte – MG – (31) 3289-2175

ricardo.alves@ecobonuz.com; tulio@ecobonuz.com; vinicius.bindewald@ecobonuz.com;

RESENHA

Induzir um melhor uso do transporte público ajuda a distribuir melhor a demanda. Isso posto a aplicação de algoritmos de inteligência artificial para compreender o comportamento dos usuários de transporte público ao longo do tempo e o uso de análises preditivas atrelados a benefícios por cashback incentivam os usuários a utilizarem o sistema de uma forma mais controlada.

PALAVRAS-CHAVES

Indução; Transporte Público; Inteligência Artificial; Cashback.

INTRODUÇÃO

A indução de demanda no transporte público através de incentivos é mais uma opção de estratégia a ser utilizada por governos e autoridades de transporte para encorajar mais pessoas a optarem pelo transporte público de uma forma sustentável. Isto pode ser alcançado através de uma variedade de benefícios e políticas que tornam o transporte público mais atrativo em comparação com outras opções de mobilidade.

Dentre as várias maneiras para estimular a demanda pelo transporte público, através de benefícios, citamos os programas de fidelidade e recompensas. Pelo uso de programas de recompensas para passageiros frequentes é possível oferecer descontos ou benefícios adicionais para aqueles que usam regularmente o transporte público. Deste modo, se tem, estratégias eficazes para induzir a demanda, incentivando os passageiros a utilizarem o transporte público com uma maior frequência. Esses programas são semelhantes aos programas de fidelidade oferecidos por empresas aéreas, hotéis e outras indústrias, e têm como objetivo recompensar os usuários fiéis, tornando o uso contínuo do transporte público mais atraente. A seguir serão detalhadas as estruturas desses programas:

- Pontos por viagens: os passageiros ganham pontos cada vez que utilizam o transporte público. A quantidade de pontos ganhos pode depender da distância da viagem, do tipo de bilhete utilizado ou da frequência de uso. Por exemplo, uma pessoa que utiliza o transporte público todos os dias poderá ganhar mais pontos do que alguém que o faz esporadicamente. Bem como, quem não utiliza o transporte público de forma frequente será incentivado a fazê-lo por meio de bonificações em pontos.
- Níveis de associação: os passageiros podem ser classificados em diferentes níveis de associação com base em quantos pontos eles acumularam ao longo do tempo. À medida que acumulam mais pontos, podem avançar para níveis superiores com recompensas mais atraentes. Isso incentiva a fidelização e o uso contínuo do transporte público.
- Recompensas monetárias: os pontos acumulados podem ser convertidos em créditos para futuras viagens ou benefícios financeiros, como pagamento de contas.

- Brindes e benefícios extras: além de descontos, os programas de fidelidade podem oferecer brindes e benefícios adicionais.
- Parcerias com empresas locais: o programa de fidelidade pode estabelecer parcerias com empresas locais, como restaurantes, lojas, academias, cinemas, entre outros. Os pontos acumulados também podem ser usados para obter cupons de descontos ou ofertas especiais nessas empresas, incentivando ainda mais o uso do transporte público.
- Programas sazonais e promoções: realização de promoções sazonais ou eventos especiais, nos quais os passageiros podem ganhar pontos extras ou recompensas adicionais e essa é uma maneira eficaz de atrair novos usuários e manter os atuais engajados. É uma espécie de gamificação em momentos especiais.
- Aplicativo ou cartão de fidelidade: a participação no programa é facilitada por meio de uma plataforma web, além de um aplicativo móvel, onde os passageiros podem verificar seu saldo de pontos, resgatar recompensas e acompanhar seu progresso.
- Comunicação eficaz: manter os passageiros informados sobre seu progresso, ofertas especiais e eventos do programa de fidelidade é essencial. Isso é feito por meio de notificações por push, emails ou mensagens de texto.
- Avaliação contínua: os programas de fidelidade são avaliados regularmente através de pesquisas NPS (Net Promoter Score) para garantir que estejam atingindo seus objetivos de indução de demanda. Os ajustes podem ser feitos com base no feedback dos passageiros e nas métricas de desempenho.

Usar inteligência artificial (IA) para induzir a demanda no transporte público através de programas de fidelidade e recompensas é uma estratégia eficiente, que se mostra benéfica para as autoridades de transporte público, para os operadores de transporte e, principalmente, para os usuários.

A IA é aplicada para coletar e analisar dados relacionados ao transporte público, como horários de pico, rotas mais movimentadas e hábitos dos passageiros. Isso ajuda a identificar oportunidades para incentivar o uso do transporte público. Os algoritmos de IA possibilitam personalizar os programas de fidelidade, que recompensam os passageiros frequentes, com base no histórico de viagens de cada passageiro, oferecendo incentivos específicos para aumentar a fidelidade. Também são ofertadas recompensas personalizadas com base no comportamento do passageiro. As campanhas de marketing são segmentadas para grupos específicos de passageiros, com base em seu comportamento de viagem e preferências, isso inclui promoções especiais e ofertas personalizadas.

Cabe mencionar, que todos esses dados coletados dos passageiros são clusterizados e agregados de forma que se agrupem usuários de mesmo perfil, tirando desses dados o fator individualizado, sendo esses dados então considerados anonimizados conforme Lei Geral de Proteção de Dados Pessoais (LGPD).

DIAGNÓSTICO, PROPOSIÇÕES E RESULTADOS

O processo de indução de demanda via cashback ocorre a partir da identificação de “tendências” no comportamento dos usuários, com posterior previsão do comportamento dos usuários para o mês seguinte. Para isto são utilizados algoritmos de uma área da Inteligência Artificial (IA) denominada Machine Learning (aprendizado de máquina), que se concentra no desenvolvimento de algoritmos e modelos que permitem aos sistemas de computador aprender e melhorar a partir de dados e experiências anteriores sem serem explicitamente programados. Em vez de serem programados para executar tarefas específicas, os sistemas de Machine Learning usam dados para aprender padrões e tomar decisões ou fazer previsões com base nesses padrões. Neste sentido, são utilizadas as seguintes ferramentas:

Clustering algorithms: os algoritmos de clustering (ou algoritmos de agrupamento) são técnicas de Machine Learning e análise de dados utilizadas para dividir um conjunto de dados em grupos ou clusters com base em características ou similaridades compartilhadas. A principal ideia desses algoritmos é agrupar objetos ou pontos de dados que sejam mais semelhantes entre si do que com aqueles em outros grupos. Isso ajuda a encontrar estruturas ou padrões ocultos, assim facilita a análise e interpretação de grandes conjuntos de dados.

Prophet: o algoritmo Prophet é uma biblioteca de código aberto desenvolvida pelo Facebook Research. O Prophet é amplamente utilizado em análises de dados onde se busca prever valores futuros em séries temporais, como no caso do comportamento do usuário no uso do transporte público. Este algoritmo lida bem com dados que exibem sazonalidade, como padrões diários, mensais, semanais ou anuais e com tendências. O Prophet decompõe uma série temporal em três componentes principais: tendência, sazonalidade e feriados. Isso ajuda a modelar de forma mais precisa as variações nos dados ao longo do tempo.

SARIMA: Seasonal AutoRegressive Integrated Moving Average, ou simplesmente SARIMA é uma extensão do modelo ARIMA (AutoRegressive Integrated Moving Average) indicado para modelar e prever séries temporais, levando em consideração a sazonalidade dos dados. O modelo SARIMA é especialmente útil quando os dados exibem padrões sazonais claros e não podem ser adequadamente modelados apenas com um modelo ARIMA básico.

O SARIMA começa com os componentes de um modelo ARIMA básico, que são:

- AR (AutoRegressive): Refere-se à parte auto regressiva do modelo, que modela as dependências entre os valores passados da série temporal. O parâmetro "p" representa a ordem da parte auto regressiva.
- I (Integrated): Indica o número de vezes que a série temporal é diferenciada para torná-la estacionária. O parâmetro "d" representa o número de diferenciações necessárias.
- MA (Moving Average): Refere-se à parte de média móvel do modelo, que modela as dependências entre os erros passados da série temporal. O parâmetro "q" representa a ordem da parte de média móvel.

Além dos componentes ARIMA, o SARIMA inclui termos sazonais para modelar padrões sazonais na série temporal:

- P: Representa a ordem da parte auto regressiva sazonal.
- D: Representa o número de diferenciações sazonais.
- Q: Representa a ordem da parte de média móvel sazonal.

O modelo SARIMA é adequado para séries temporais que exibem tendências, sazonalidades e estacionariedade sazonal. Ao ajustar os parâmetros (p, d, q, P, D, Q) do SARIMA de acordo com os dados, é possível fazer previsões mais precisas e capturar melhor os padrões sazonais presentes na série temporal.

O processo de análise e resultados pode ser dividido em etapas, essas descritas abaixo:

Escolha do cenário: Inicialmente, escolheu-se um cenário de análise reduzido, os usuários de um operador de transporte em uma capital de grande importância no Brasil. Esta é uma estratégia prudente que ajuda a mitigar riscos, aprimorar modelos preditivos e obter insights valiosos antes de considerar uma implementação em grande escala. Isso permite uma abordagem mais focada e eficaz para o desenvolvimento de soluções de IA neste segmento de transporte público. Este cenário reduzido admite testar e validar conceitos e abordagens antes de escalá-los. Uma vez identificadas as falhas podem ser aplicados os ajustes e aprimoramentos necessários aos modelos e algoritmos, é possível serem utilizá-los em uma escala maior, ou seja, passa-se a expandir para outros operadores de transportes públicos.

É importante ressaltar que os resultados apresentados refletem o estudo aplicado neste cenário de análise reduzido.

Etapa de segmentação: Empregou-se algoritmos denominados clustering algorithms, para agrupar usuários com comportamentos estatisticamente semelhantes. Estas estatísticas permitem avaliar o quanto cada usuário utiliza o transporte em termos de percentual de dias úteis no mês, quantidade de vezes que cada usuário utiliza o transporte por dia, além de variações destas medidas. Através da formação dos clusters ou grupos de usuários com comportamentos estatisticamente semelhantes, é possível fazer uma previsão com uma boa acuracidade do comportamento esperado por agrupamento para o próximo mês, ou seja, é possível prever o uso e a receita esperada que cada grupo vai trazer. A Figura 01 nos mostra um resultado de segmentação do usuário em clusters pelo padrão de uso no transporte público.

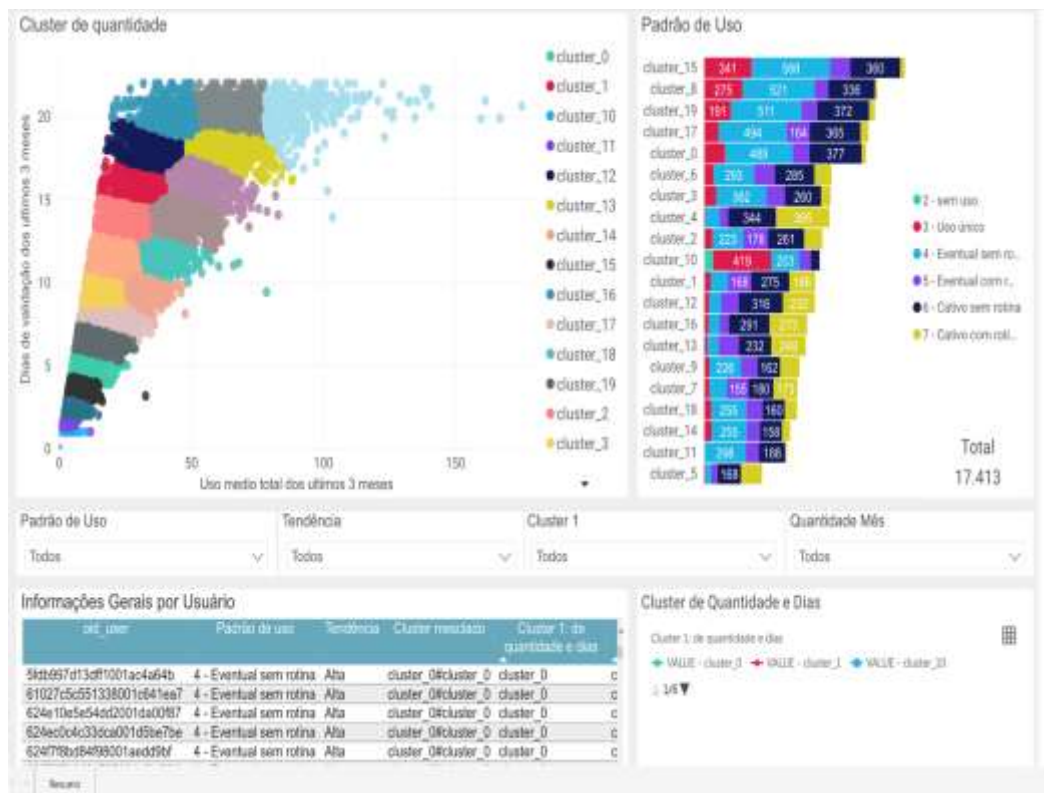


Figura 01 - Segmentação do usuário

Etapa de definição de tendências: as previsões são feitas obtendo uma boa precisão nos resultados. São utilizados os algoritmos Prophet e Sarima através de uma técnica chamada Ensembling. Esta técnica envolve a combinação de múltiplos modelos para obter uma previsão agregada, que é geralmente mais precisa do que as previsões individuais dos modelos. Isso é feito aproveitando as forças de cada modelo e mitigando suas fraquezas. A previsão feita pelo Prophet/SARIMA Model Ensembling traz a informação do quanto, em percentual de dias úteis, os usuários de cada agrupamento deverão utilizar o transporte no mês seguinte, bem como quantas vezes por dia cada usuário deverá utilizar. Por meio destas previsões é possível estimar o montante de receita esperado que os usuários trarão para o operador do transporte.

Etapa de definição dos desafios: uma vez obtida a previsão de uso e receita diária por grupo de usuários é possível criar os “desafios ou missões” que irão estimular os usuários a utilizarem o transporte acima das estimativas. Para isso, são premiados os passageiros com pontos, por cumprir os desafios ou missões, que na verdade são ações de indução. Estes pontos acumulados se transformam em cashback, que é calculado a partir do aumento de

receita esperado com os desafios. Desta forma o operador garante um ROI (Return on Investment) positivo, ou seja, mesmo com o custo do cashback, ainda obtém lucro na ação.

As previsões classificam os grupos de usuários em 3 categorias (tendências), sendo estas:

- **Alta:** o usuário aumenta a quantidade de dias que utiliza o transporte com o passar dos meses;
- **Estabilidade:** a quantidade de dias de utilização tem tido pouca alteração no decorrer dos meses;
- **Queda:** o usuário diminui a quantidade de dias que utiliza o transporte com o passar dos meses.

Cabe ressaltar, que os usuários são informados sobre a existência de desafios disponíveis no mês em questão. Isso é feito por meio de notificações via push, emails ou mensagens de texto. É necessário que o usuário aceite os desafios disponíveis, porque somente assim, caso cumpra os desafios propostos, ele será pontuado.

Análise dos resultados: o gráfico da Figura 02 demonstra, em termos financeiros, a Receita esperada (previsão) x Receita realizada para o grupo de usuários que não foram impactados pelos “desafios”. Assim sendo, tais usuários utilizaram o transporte de forma costumeira, sem que houvesse nenhum estímulo para a utilização do transporte em uma frequência maior. No gráfico, estes usuários estão agrupados segundo suas tendências de utilização do transporte (Alta, Estável e Queda, respectivamente).




Figura 02 - Receita esperada x Receita realizada

A análise do gráfico da Figura 02 evidencia que, para os usuários em:

- **Alta:** a Receita realizada foi 16% inferior à esperada (R\$ 461.482,00 x R\$ 551.443,00).
- **Estabilidade:** a Receita realizada foi 2% superior à esperada (R\$ 342.127,00 x R\$ 335.786,00).
- **Queda:** a Receita realizada foi 22% superior à esperada (R\$ 373.847,00 x R\$ 305.259,00).

Considerando-se algum percentual de erro nas previsões, principalmente nos grupos de Alta e Queda, ao ser propostos os desafios aos usuários, se trabalha com valores mais conservadores, de modo que se possa garantir que, mesmo com o pagamento de cashback aos usuários, é viável alcançar um ROI positivo.

Aplicando o processo de indução observamos a Figura 03 que demonstra, para o mesmo grupo de usuários da Figura 02, qual seria a receita prevista com a proposição de desafios

(Receita desafio), além da receita esperada e receita real. Assim sendo, esta receita seria o montante previsto caso os usuários aceitassem o desafio e atingissem a meta proposta.




Figura 03 – Receita desafio x Receita esperada x Receita realizada

Em todos os casos, a “Receita desafio” gerada com a aceitação (e cumprimento) dos desafios por parte dos usuários, seria maior do que a Receita realizada. Avaliando os resultados, é possível concluir que em caso de se premiar usuários com cashbacks mais atrativos, ainda sim é viável manter um ROI positivo.

No gráfico da Figura 04 está descrito o grupo de usuários para o qual foram propostos desafios e que aceitaram participar. Neste caso, não necessariamente os usuários foram premiados com cashback, uma vez que não atingiram a meta proposta.

Ao serem comparados os resultados da Figura 04 com a Figura 03, pode-se notar que, percentualmente foi obtido um aumento de receita para os usuários que estavam em Queda e Alta. Percebe-se então que o fato de os usuários participarem de desafios já demonstra uma certa indução nos resultados.

- **Alta:** a Receita realizada (R\$ 32.459,00) foi 2% inferior à esperada (R\$ 33.178,00). Anteriormente era 16%;
- **Estabilidade:** a Receita realizada (R\$ 26.720,00) foi 2% superior à esperada (R\$ 26.186,00);
- **Queda:** a Receita realizada (R\$ 20.268,00) foi 41% superior à esperada (R\$ 14.392,00). Anteriormente era 22%.

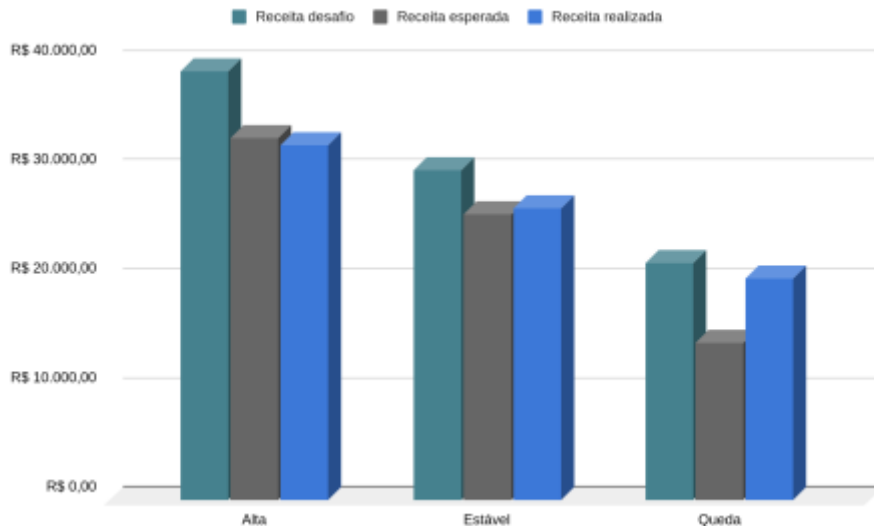


Figura 04 - Receita desafio x Receita esperada x Receita realizada

Foi observado que, mesmo sem ter vencedores para efetuar pagamento de cashback, foi possível obter um aumento de receita para os usuários em Queda e Alta.

Na Figura 05, observa-se o grupo de usuários que efetivamente receberam cashback com os desafios, ou seja, usuários que aceitaram os desafios propostos e cumpriram a meta estipulada.




Figura 05 - Receita desafio x Receita esperada x Receita realizada

A análise da Figura 05, permite dizer que, em todas as tendências, o montante das receitas geradas pelos usuários que foram premiados com cashback foram significativamente maiores do que o estimado. Ou seja, as estimativas previstas, eram suficientes para se pagar cashback aos usuários e ainda obter um ROI positivo. Contudo, a receita gerada por estes usuários se apresentou acima das estimativas, proporcionando um ROI significativamente maior, como pode ser visto na Figura 06, que demonstra uma comparação entre o ROI esperado e o ROI real.

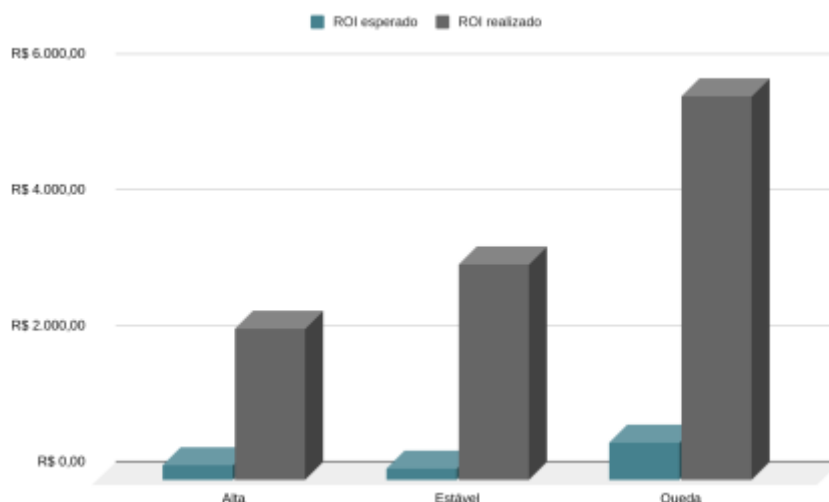


Figura 06 – ROI esperado x ROI realizado

Atualmente, na proposição dos desafios, os prêmios oferecidos aos usuários estão em 6 faixas de premiação: 30, 50, 100, 500, 1000 e 1500 moedas de cashback no aplicativo. Essas premiações são calculadas do quanto o usuário precisará aumentar a utilização do transporte, além do que está previsto para ele como uma tendência de comportamento.

O gráfico da Figura 07, demonstra o percentual de usuários que aceitaram participar dos desafios em cada uma das faixas de premiação. Foi avaliado que, quanto maior a faixa de premiação, há uma maior tendência de os usuários aceitarem participar dos desafios.




Figura 07 – Percentual de aceites nos desafios por faixa de premiação

As atuais faixas de premiação estão ainda em um patamar abaixo do possível, ou seja, há a possibilidade de se aumentar a premiação e ainda obter um ROI positivo para o operador de transporte. O aumento dos valores de premiação possivelmente fará com que mais usuários aceitem participar dos desafios, o que possibilitaria também, como descrito nas análises, uma maior receita para o operador.

CONCLUSÕES

Programas de fidelidade e recompensas no transporte público são estratégias eficazes para induzir a demanda, incentivando os passageiros a utilizarem o transporte público com frequência. Eles ajudam a melhorar a experiência geral do passageiro, tornando o transporte público uma opção mais atraente em comparação com o uso de veículos particulares.

Impulsionar a utilização de programas de fidelidade e recompensas no transporte público pelo uso da inteligência artificial (IA), demonstra ser uma estratégia altamente eficaz para incentivar e aumentar a demanda por esse serviço essencial. A capacidade da IA de analisar dados e segmentar grupos de passageiros, identificando tendências e preferências, permite que as autoridades de transporte público otimizem suas ofertas, adaptando-as às necessidades específicas dos usuários.

Essas iniciativas não apenas melhoram a experiência do passageiro, mas também contribuem para a redução do tráfego rodoviário e das emissões de poluentes, promovendo, assim, cidades mais sustentáveis. Além disso, ao promover a fidelidade dos passageiros, esses programas geram receita adicional que pode ser reinvestida na melhoria da infraestrutura e na expansão dos serviços de transporte público.

Portanto, à medida que se avança no uso da IA e da mobilidade urbana inteligente, programas de fidelidade e recompensas baseados em dados são ferramentas cruciais para induzir uma demanda cada vez maior pelo transporte público, tornando as cidades mais eficientes, ecológicas e acessíveis a todos.

REFERÊNCIAS BIBLIOGRÁFICAS

1. SUTTON, Richard S.; BARTO, Andrew G. **Reinforcement Learning: An Introduction (Adaptive Computation and Machine Learning)**. 2ª edição. Bradford Books, 2018.
2. MURPHY, Kevin P. **Machine Learning: A Probabilistic Perspective**. The MIT Press, 2012.
3. HENSHAW, David A.; BUTTON, Kenneth J. (Eds.). **Handbook of Transport Modelling**. Pergamon, Amsterdam, 2000.
4. OUM, Tae; YU, Chunyan; YAN, Jia (Eds.). **Data Science for Transport**. Springer, 2023.
5. GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. MIT Press, 2016.
6. LI, Baoju; WANG, En; YANG, Funing; YANG, Yongjian; LIU, Wenbin; TIAN, Zijie; LIU, Junyu; ZHENG, Wanbo. **Sample-based Prophet for Online Ride-sharing with Fairness**. 18th International Conference on Mobility, Sensing and Networking (MSN), 14-16 de dezembro de 2022.
7. ZHANG, Yang; ZHU, Hongyi; WANG, Yujing; LI, Tianchen. **Demand Forecasting: From Machine Learning to Ensemble Learning**. IEEE Conference on Telecommunications, Optics and Computer Science (TOCS), 11-12 de dezembro de 2022.
8. BRIAND, Anne-Sarah; CÔME, Etienne; MAHRSI, Mohamed K. El; OUKHELLOU, Latifa. **A mixture model clustering approach for temporal passenger pattern characterization in public transport**. International Journal of Data Science and Analytics, 2016.
9. ABDALAZEEM, M.; OKE, J. **Extracting Spatiotemporal Bus Passenger Trip Typologies from Noisy Mobile Ticketing Boarding Data**. Data Science in Transportation, vol. 5, nº 20, 2023.
10. GHANDEHARIOUN, Z.; ZENDEHDEL NOBARI, P.; WU, W. **Exploring Deep Learning Approaches for Short-Term Passenger Demand Prediction**. Data Science in Transportation, vol. 5, nº 19, 2023.
11. COSTA, M.A.; MARRA, A.D.; CORMAN, F. **Public Transport Commuting Analytics: A Longitudinal Study Based on GPS Tracking and Unsupervised Learning**. Data Science in Transportation, vol. 5, nº 15, 2023.