

Predição de Séries Temporais de Demanda em Modelos de Compartilhamento de Veículos para Modelos Uni e Multi Variáveis

Victor Aquiles Alencar¹, Lucas Pessamilio¹, Felipe Rooke¹,
Heder Soares Bernardino¹, Alex Borges Vieira¹

¹Departamento de Ciência da Computação - Universidade Federal de Juiz de Fora

{victoraquiles, lucasribeiro, heder}@ice.ufjf.br

{felipe.rooke, alex.borges}@ufjf.edu.br

Abstract. *Car sharing is an alternative to urban mobility that has been widely adopted. However, this approach is prone to several problems, such as fleet imbalance, due to the daily demands variance in large urban centers. In this work, we apply two time series techniques, the LSTM and the Prophet, to infer the demand for three real car sharing services. In addition to historical data, we also use climatic attributes in the LSTM applications. As a result, it was observed that the addition of meteorological data improved the model's performance: an average MAE (Mean Absolute Error) of approximately 6.01% is obtained with the demand data, while an average MAE equals to 5.9% is observed when adding the climatic data. One can also notice that the LSTM's performance is better than that obtained by Prophet (average MAE equal to 10.4%) for the databases adopted here and considering only the demand for services.*

Resumo. *O compartilhamento de veículos é alternativa para a mobilidade urbana que vem sendo largamente adotada. Porém, essa abordagem está sujeita a problemas, como desbalanceamento da frota ao longo do dia, por conta de demandas variadas em grandes centros urbanos. Neste trabalho aplicamos duas técnicas de séries temporais, o LSTM e o Prophet, para inferir a demanda de três serviços reais de compartilhamento de veículos. Além dos dados históricos, atributos climáticos também foram considerados numa das aplicações do LSTM. Como resultado, foi observado que a adição de dados meteorológicos melhorou o desempenho do modelo: um MAE (Erro Absoluto Médio) médio de aproximadamente 6,01% é obtido com os dados de demanda, enquanto um MAE de 5,9% é observado quando adiciona-se os dados climáticos. Também é possível notar que o desempenho do LSTM é melhor do que o obtido pelo Prophet (MAE médio igual a 10,4%) para as bases de dados adotadas aqui e considerando apenas a demanda dos serviços.*

1. Introdução

O entendimento da mobilidade urbana e suas aplicações tem sido foco de diversos estudos [Alencar et al. 2019, Cocca et al. 2020, Shaheen 2016]. Tal atenção se deve a mobilidade urbana estar ligada a diversas tarefas que vão desde cotidianas a laborais, que cada vez mais necessitam de recursos inteligentes para melhor atender a sua crescente demanda. O fenômeno da economia do compartilhamento influenciou a criação de diversas

soluções para a mobilidade urbana, uma vez que ela propõe facilitar o compartilhamento de bens, principalmente através de plataformas online [Hamari et al. 2016].

Uma das soluções para aprimoramento da mobilidade urbana é o modelo de compartilhamento de veículos, que tem recebido atenção crescente da comunidade acadêmica [Cocca et al. 2020, Alencar et al. 2019, Boldrini et al. 2016, Nourinejad 2014]. O modelo de negócios do compartilhamento de veículos, se baseia em oferecer veículos em uma região de atendimento, onde os usuários podem reservar e utilizá-los a qualquer momento, sem se preocupar com problemas inerentes a manter um veículo próprio. Em 2015, ao total, os serviços detinham mais de 1,5 milhões de usuários e mais de 22 mil veículos em circulação nas Américas [Shaheen 2016].

O compartilhamento de veículos pode ser dividido em três principais modelos de negócios, sendo dois modelos baseados em estações e um sem estações [Nourinejad 2014]. Dessa forma, há os serviços de duas vias (*two-way*), onde um veículo pode ser reservado em estações espalhadas por uma região e utilizado livremente, e ao fim da reserva ele deve ser retornado a estação de origem. Também baseados em estações, temos os serviços de uma via (*one-way*) onde os veículos ficam disponíveis em estações para reserva e uso livre, ao término da utilização, ele pode ser retornado a qualquer estação do serviço. Por fim, como um modelo não baseado em estações temos os serviços de carga livre (*free-floating*), onde os veículos ficam disponíveis em qualquer local da região de abrangência do serviço e podem ser retornados em qualquer local da sua região [Boldrini et al. 2016].

Pesquisas já foram realizadas para descrição do comportamento de uso e demanda desses tipos de serviços [Alencar et al. 2019, Boldrini et al. 2016, Cocca et al. 2020]. Nesses trabalhos, foi exibido que a utilização dos serviços de compartilhamento de veículos, segue padrões de utilização tanto de demanda quanto de tempo de utilização. Assim, é possível realizar previsões de demanda de veículos para cada serviço, com objetivo de auxiliar na tomada de decisões, como por exemplo o número de veículos que serão alocados no dia, ou rotinas de manutenção.

Neste trabalho, foram realizadas previsões de séries temporais dos principais modelos de compartilhamento de veículos, avaliando o seu desempenho para dados de uma única variável (univariável) e para múltiplas variáveis (multivariável). Mais precisamente, utilizamos dados de três serviços situados na cidade de Vancouver, Canadá, conjunto a dados históricos meteorológicos da cidade, para uma comparação de desempenho de diferentes técnicas de previsão de demanda para os seus modelos, e como se comportam com dados externos aos serviços. Sobre as técnicas, exploramos o Prophet, que vêm demonstrado resultados competitivos dentre métodos já consolidados [Taylor and Letham 2018, Papacharalampous et al. 2018] e o LSTM (*Long Short-Term Memory*) que é um método de alta escalabilidade e desempenho [Cocca et al. 2020, Laptev et al. 2017].

Os trabalhos existentes focam em realizar a previsão de demanda para um tipo de serviço sobre modelos do estado da arte [Cocca et al. 2020, Laptev et al. 2017]. Nós avaliamos dois modelos, sendo um de base estatística e outro de redes neurais sobre dados de três serviços e dados externos aos mesmos, o que complementa o entendimento sobre como modelos preditivos podem auxiliar para tomada de decisões para serviços de compartilhamento de veículos. Nossos resultados indicam que o modelo baseado em redes

neurais obteve melhores resultados em comparação ao estatístico, onde foram visualizados menores erros, principalmente para o cenário com dados externos. Em suma, nossas contribuições são voltadas a aplicação de modelos preditivos sobre as divisões de modelos de compartilhamento de veículos para predição de demanda e tomada de decisão.

O restante deste artigo está organizado como: Seção 2 apresenta os trabalhos relacionados; Seção 3 descreve a coleta e a base de dados utilizada para cada serviço; Seção 4 descreve a metodologia utilizada para cada modelo, conjunto a uma breve descrição dos mesmos; Seção 5 apresenta os resultados obtidos para cada modelo e uma comparação entre eles, por fim, Seção 6 conclui o artigo.

2. Trabalhos Relacionados

Trabalhos anteriores exploraram as características de demanda e padrões de uso dos principais modelos de compartilhamento de veículos [Alencar et al. 2019]. Nesse trabalho, foram analisadas características temporais, espaço-temporais e de comportamento dos usuários. Nele, pode ser visto que o comportamento da demanda de veículos diverge entre dias de semana e fins de semana para todos os serviços, assim previsões sobre fins de semana a partir de dias de semana podem gerar resultados não satisfatórios. Além disso, foi mostrado o tempo de duração das ocupações, que variam para cada serviço. Isso indica que certos serviços irão ter demandas diferentes com base em como e por quanto tempo os veículos são utilizados.

O Prophet já vem sendo utilizado na literatura obtendo um bom desempenho comparado aos métodos mais utilizados de predição de séries temporais de uma variável [Taylor and Letham 2018]. Para predição de séries temporais de temperatura e precipitação, o Prophet obteve resultados competitivos dentre os modelos clássicos utilizados na área, especialmente quando aplicado decomposição sazonal de séries temporais [Papacharalampous et al. 2018]. Outro trabalho utiliza o Prophet para prever o valor do Bitcoin ao longo do tempo, onde obteve uma performance melhor que o modelo ARIMA [Samal et al. 2019]. Esta pesquisa foca em aplicar o modelo Prophet para avaliar seu desempenho sobre séries temporais de demanda de compartilhamento de veículos.

O LSTM já foi utilizado para prever demanda de veículos. Um exemplo é a implementação feita pela empresa Uber, que escolheu o modelo pela sua escalabilidade e poder de predição. Eles modificaram a implementação básica do LSTM para melhorar a sua acurácia de predição sobre sua base de dados. A implementação modificada obteve valores de acurácia melhores que o atual modelo em produção da empresa para predição da demanda em dias festivos e feriados (eventos extremos) tanto quanto para séries temporais genéricas [Laptev et al. 2017].

Trabalhos anteriores exploraram a análise de séries temporais sobre dados de compartilhamento de veículos [Cocca et al. 2020]. Nessa pesquisa, o foco foi prever a demanda de veículos para um serviço de carga livre, utilizando algoritmos do estado da arte de aprendizado de máquina. Para isso, foram estabelecidos dois cenários: o primeiro que realiza a predição da demanda utilizando as condições climáticas e uso histórico do serviço, e o segundo prevê a demanda usando somente dados sociodemográficos. Como resultado, o Random Forest obteve um erro relativo abaixo de 10% para o primeiro cenário e de 40% para o segundo. Em nosso trabalho, utilizamos a mesma abordagem de utilizar algoritmos de aprendizado de máquina sobre dados históricos, contudo realizamos a

predição a demanda de 3 serviços de compartilhamento de veículos de diferentes categorias, além de utilizar dados meteorológicos conjunto aos dados de demanda e comparamos os seus resultados.

Outro trabalho também explora um serviço de carga livre para prever a demanda, com foco em previsão de curto espaço de tempo, como as próximas horas de operação [Müller and Bogenberger 2015]. Para alcançar esse objetivo, foram comparados diversos intervalos de tempo para descobrir o intervalo de tempo ideal de dados para treinar o modelo e obter boas predições. Como resultado, o intervalo de tempo de três meses de dados obtiveram a melhor performance para prever a demanda da próxima semana.

Este trabalho detém como principal diferença a presença dos três principais modelos de compartilhamento de veículos, que são utilizados para realizar a predição de suas séries temporais de demanda. Com isso foram utilizados dois modelos de caráter distintos, sendo um estatístico e outro baseado em redes neurais para comparação de desempenho e descrição do seu comportamento sobre os dados.

3. Metodologia de coleta de dados

3.1. Coleta de dados

A coleta de dados se baseou em obter o registro de viagens de serviços de compartilhamento de veículos, assim, foram coletados dados de viagens de três serviços de compartilhamento de veículos, situados em Vancouver, Canadá. Os serviços são o Evo, Modo e Car2Go, que utilizam, respectivamente, os seguintes modelos de negócios: Uma via, duas vias e carga livre. Esses dados contém todas as viagens do serviço ordenadas pelo horário da coleta, que foram transformadas no número de viagens por hora, através de uma contagem de viagens.

Para os três serviços, foram coletadas informações do estado de cada veículo de suas respectivas frotas através de Interfaces de Programação de Aplicativos (API) públicas ou por informações disponíveis em páginas públicas dos serviços. A página de informações do Evo¹ disponibiliza a localização das suas estações bases, veículos ociosos e a porcentagem de combustível disponível. A API do Modo² retorna os veículos de cada estação, bem como os seus períodos de reserva, disponibilidade e ocupação. Por fim, a API do Car2Go³ detém de um comportamento semelhante ao do Evo. Mais informações sobre a coleta podem ser obtidas em [Alencar et al. 2019].

Para as análises multivariáveis foi utilizada uma API de dados históricos de meteorologia chamada *World Weather Online*⁴, para obter as informações meteorológicas de cada dia analisado, visando obter dados que podem influenciar na performance do modelo. Dentre eles foram coletados dados de temperatura, velocidade do vento, quantidade em milímetros de precipitação, visibilidade em metros e outros diversos indicadores binários meteorológicos do dia.

¹<https://www.evo.ca/api/Cars.aspx>, último acesso em: 15/07/2018

²<http://modo.coop/api/>, último acesso em: 15/07/2018

³<https://www.car2go.com/api/tou.htm>, último acesso em: 31/01/2018

⁴<https://www.worldweatheronline.com>, último acesso em: 18/05/2020

3.2. Resumo do conjunto de dados

Primeiramente, os dados do Evo e Modo foram coletados durante o mesmo período de tempo, que abrange do dia 01 de março de 2018 ao dia 15 de julho de 2018, ou seja, um período de aproximadamente 5 meses. Os dados do Car2Go foram coletados em outro período que inicia no dia 13 de dezembro de 2016 e termina no dia 31 de janeiro de 2018, totalizando um ano e 49 dias. A tabela 1 resume os dados obtidos de cada serviço para o período total de coleta. Nela pode ser visto que o serviço com mais dados é o Car2Go, dado o maior período de coleta. Também é possível notar que mesmo com um período igual de coleta, o Evo detém de um número significativamente superior de viagens comparado ao Modo, por conta de características de utilização dos serviços.

Serviço	Viagens	Veículos
Evo	644 887	1 237
Modo	98 915	682
Car2Go	1 095 577	1 077

Tabela 1. Resumo quantitativo das bases de dados.

Todas as bases de dados utilizadas contêm dados faltantes durante diferentes datas e períodos de tempo, por conta de interferências durante a coleta. A fim de evitar interferências ocasionadas por dados faltantes durante o treinamento dos modelos, foi selecionado um período de tempo em que houvesse menos dados faltantes para todos os serviços. Assim, foi utilizado o período do dia 23 de junho ao dia 17 de julho do ano de 2018 para os dados do EVO e do Modo e do ano de 2017 para o Car2Go.

Todos os nossos métodos e análises podem ser encontrados no nosso repositório⁵. Além disso, todos os nossos dados públicos estão disponíveis em nosso repositório⁶.

4. Modelos de Predição

Nesta seção será apresentada a metodologia adotada por cada modelo utilizado, bem como uma breve explicação sobre eles. Para ambos modelos, os dados foram discretizados para valores de hora em hora e normalizados, utilizando somente a demanda para o Prophet e LSTM univariável e a demanda, dia da semana e dados climáticos para o LSTM multivariável. Além disso, todos os modelos realizam a predição de demanda futura de um período de 12 horas, que pode ser representado como o horizonte de utilização diária do serviço para auxílio na tomada de decisões.

Por fim, para fins de comparação de desempenho, todos os resultados foram avaliados utilizando as métricas MSE (*Erro Quadrático Médio*) e MAE (*Erro Absoluto Médio*). Primeiramente, o MSE pode ser definido como

$$MSE(\mathbf{Y}, \hat{\mathbf{Y}}) = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$

onde n indica a quantidade de amostras, Y_i o i -ésimo valor real e \hat{Y}_i o i -ésimo valor predito. Em outras palavras, o MSE indica o quão próximo estamos de encontrar uma

⁵<https://github.com/netlabufjf/timeseries-forecast>, último acesso em: 18/05/2020

⁶<https://netlab.ice.ufjf.br/index.php/carsharingdata/>, último acesso em: 18/05/2020

curva que melhor representa os dados. A métrica MAE é ser definida como

$$MAE(\mathbf{Y}, \hat{\mathbf{Y}}) = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|$$

onde suas variáveis seguem o mesmo padrão do MSE. Assim, pode ser dito que o MAE indica o quanto em média obtemos de erro absoluto entre a previsão e o valor real.

4.1. Metodologia Prophet

O Prophet é um modelo estatístico desenvolvido pelo Facebook, onde a proposta é ser um método escalável de fácil utilização com foco em séries temporais que detém de fortes padrões de sazonalidade e que sofrem efeitos gerados por feriados ou eventos extremos [Taylor and Letham 2018]. O seu modelo de previsão é composto por outros três modelos: (1) Tendência, que se preocupa com as mudanças não periódicas nos valores; (2) Sazonalidade, que traduz as mudanças periódicas dos valores, como padrões diários ou semanais; (3) Feriados, que representa as mudanças que podem ocorrer com a incidência de dias festivos ou mudanças de padrões repentinas. Assim, ele pode ser considerado um modelo apropriado para predição do comportamento de mobilidade humana.

O modelo Prophet é utilizado para prever um horizonte de tempo dado os dados históricos, o nosso objetivo é fornecer predições de demanda para um dia normal de utilização. Os dados históricos são compostos por toda a série temporal disponível, assim o último valor fornecido será o último valor obtido pela coleta de dados. Com isso, determinamos que o modelo irá prever um horizonte de 12 horas no futuro a partir do último valor fornecido. Por fim, indicamos para o modelo que os dados seguem uma sazonalidade semanal e anual, uma vez que os padrões de demanda seguem um padrão para dias de semana e fins de semana [Alencar et al. 2019]

Os dados foram tratados novamente para remover *outliers*. Para isso, foram selecionados valores a partir de 4 desvios padrões acima da média para serem removidos. Assim, só foi necessária a remoção de valores somente da base de dados do Modo, onde foram removidos 0,5% dos dados. Fora os *outliers*, dentro do intervalo selecionado há a ocorrência de um feriado nacional no país, o Canada Day, que ocorreu no dia 1 de julho de 2017 e no dia 2 de julho no ano de 2018. Assim, as suas datas foram incluídas durante a montagem do modelo, uma vez que o modelo considera eventos festivos como um dos seus parâmetros.

4.2. Metodologia LSTM

O LSTM (*Long Short-Term Memory*) é um tipo de rede neural que têm obtido destaque para previsão de séries temporais [Cocca et al. 2020, Laptev et al. 2017]. Ela é baseada em uma Rede Neural Recorrente, que segue a ideia de manter uma memória de curto prazo para influenciar a previsão do próximo intervalo de tempo. Assim, durante o treino é determinado o intervalo de tempo que será utilizado como memória e o horizonte que será previsto. Os dados a serem utilizados no modelo são organizados seguindo o formato [lote, instantes de tempo, colunas], o tamanho do lote nos indica o número de exemplos a serem trabalhados, o número de passos de tempo representa quantos instantes de tempo estarão contidos em cada lote para a memória de curto prazo e, por fim, o número de colunas representa quantas colunas de dados são atribuídas para cada instante de tempo.

Primeiramente, os dados filtrados foram separados em dados de treino e validação. A quantidade de dados separados foram de 70% para treinamento e 30% para validação. Como a base de dados foi filtrada de um período de tempo pequeno, o tamanho dos lotes de cada serviço é variado com base na porcentagem de dados referente ao tamanho de sua base de dados, além de serem únicos, tanto para os dados de treinamento quanto para os de avaliação. Assim, para o EVO foi utilizado um lote de tamanho 43, para o Modo de tamanho 83 e o Car2Go com tamanho 96, todos eles com 24 horas de dados e suas 51 colunas de informações.

Todos os modelos seguiram as mesmas especificações durante o treinamento, sendo utilizadas 50 épocas, com 200 passos de treino e 50 passos de validação. Para a rede neural, foram usadas duas camadas LSTM e uma camada densa de 12 neurônios, porém o número de neurônios das camadas LSTM é diferente entre os modelos, já que para o modelo univariável foram utilizados 50 neurônios e para o multivariável foram utilizados 80 neurônios. Como o modelo depende da determinação de um período de tempo de memória de curto prazo e um horizonte de previsão, foi determinado que o modelo irá utilizar 24 horas passadas para realizar a previsão das 12 horas futuras. O otimizador utilizado foi o RMSprop com um valor de clipvalue de 1,0.

5. Predição temporal da demanda

Nesta seção, serão apresentadas as previsões e valores obtidos com as métricas dos três serviços para o modelo Prophet (Seção 5.1). Em seguida, serão expostas as previsões uni e multivariáveis do modelo LSTM para os serviços (Seção 5.2). Por fim, serão debatidos os resultados obtidos conjunto a uma comparação entre os resultados dos modelos (Seção 5.3).

5.1. Prophet

Nesta subseção iremos apresentar os resultados obtidos pelo modelo Prophet. A apresentação dos resultados seguiram o mesmo padrão, onde serão exibidos os valores reais por meio de pontos e os valores preditos por meio de uma curva principal. A previsão das 12 horas futuras é representada por uma curva pontilhada ao fim da curva dos valores preditos. Além disso, todo intervalo de incerteza das previsões está sendo exibido conjunto às retas.




Figura 1. Previsão de 12 horas pelo modelo Prophet para o Evo.

Na figura 1, apresentamos os resultados obtidos pelo modelo Prophet sobre os dados do Evo. É possível perceber que os dados faltantes alteraram o comportamento inicial do modelo, contudo, quando chegamos em uma região com poucos dados faltantes, o modelo se adapta muito bem aos dados. A previsão das futuras 12 horas seguiu o padrão dos demais dias, com um máximo local pelo período da manhã, seguida por uma diminuição da demanda durante a tarde para no futuro resultar em um máximo global. Tal modelo traduz bem o comportamento de demanda do serviço, uma vez que por ser um serviço de uma via, as viagens são curtas. Não há muitos veículos ocupados ao mesmo tempo ao longo do dia, exceto em horários de pico de movimentação.




Figura 2. Previsão de 12 horas pelo modelo Prophet para o Modo.

A figura 2 apresenta os resultados obtidos pelo modelo Prophet sobre os dados do Modo. Primeiramente, pode ser visto que essa base de dados apresenta menos dados faltantes quando comparado com os do Evo (Figura 1), além de deter picos de demanda maiores. Assim, pode ser visto o padrão diário que o modelo adotou com um máximo global para o período da manhã seguido por uma diminuição abrupta, que resulta em um máximo local ao meio dia para seguir diminuindo ao longo do dia. Assim, para a previsão das próximas 12 horas, o modelo retornou o pico da manhã que em seguida decaiu ao entrar no período da tarde. Por ser um serviço de duas vias, o comportamento de uso segue a ideia de ocupar os veículos pela manhã para a utilização ao longo do dia, o que justifica o pico durante a manhã e um outro pico menor ao meio dia.

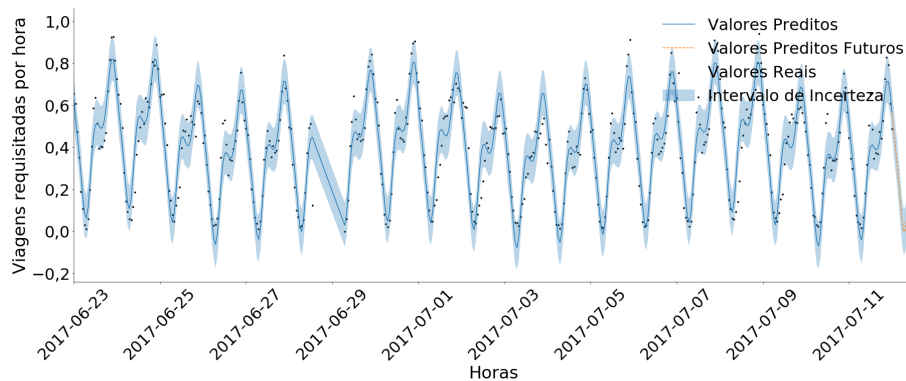


Figura 3. Previsão de 12 horas pelo modelo Prophet para o Car2Go.

A figura 3 apresenta os resultados obtidos pelo modelo Prophet sobre os dados do

Car2Go. Em comparação aos demais serviços, o Car2Go está com menos dados faltantes no período. Primeiramente, é possível visualizar que o comportamento do modelo é semelhante ao do Evo em relação a incidência de máximos locais (Figura 1). Contudo, a crescente utilização ao longo do dia alcança um pico local próximo ao meio dia para em seguida aumentar a sua demanda ao longo do dia. Com isso, a previsão das 12 horas só traduziu o crescimento constante de demanda que o serviço detém pela manhã. Pelo fato de ser um serviço carga livre, ele possui um comportamento semelhante ao do Evo no sentido de ser utilizado para viagens curtas, mas por magnitude de demanda o Car2Go é mais utilizado na cidade.

Serviço	MSE	MAE
Evo	0,043260	0,167807
Modo	0,008499	0,067900
Car2Go	0,009766	0,077209

Tabela 2. Valores das métricas obtidas pelo Prophet.

Analisando os valores das métricas pode ser avaliado quantitativamente o desempenho em cada serviço. A tabela 2 resume os valores do MSE e MAE para os três serviços a partir de uma validação cruzada de toda a série temporal, onde um horizonte de 12 horas foi utilizado para validação, por meio de uma funcionalidade provida pelo modelo [Taylor and Letham 2018]. Logo de início, é possível perceber que os modelos desempenharam bem para o MSE, com valores na terceira casa decimal, que representa um baixo valor de erro, exceto pelo Evo, por conta dos dados faltantes no início de sua série temporal que podem prejudicar o treinamento do modelo, mas que ainda obteve um desempenho satisfatório. Para os valores do MAE, é possível notar que o erro relativo aos valores do Modo e Car2Go estão baixos, o que nos indica a confiabilidade sobre os mesmos. Contudo, os valores obtidos pelo Evo são maiores que os demais, novamente por conta dos dados faltantes.

5.2. LSTM

Nesta seção são apresentados os resultados obtidos pelo modelo LSTM univariável e multivariável. É importante salientar que todos os gráficos irão seguir o mesmo padrão de apresentação, onde serão exibidas duas curvas, uma de valores reais e outra dos valores preditos. Tais valores são referentes ao lote de avaliação dos dados. Assim, o eixo y indica a demanda de viagens do serviço e o eixo x os instantes de tempo armazenados no lote.

A Figura 4 apresenta os resultados obtidos pelos modelos LSTM univariável e multivariável para os dados do Evo. Tanto na Figura 4-a quanto na 4-b a previsão está seguindo corretamente o formato da curva real, contudo o modelo univariável apresenta, em alguns pontos, erros de magnitude e erros de previsão da curva no início da curva, como exemplo a crescente de demanda que se inicia na hora 0 e se estende até a hora 8, onde o modelo não previu corretamente o pico local de demanda. O modelo multivariável apresenta resultados melhores para o formato da curva e diminui erros de magnitude obtidos anteriormente, principalmente para o primeiro pico e vale de demanda.

A Figura 5 apresenta os resultados obtidos pelos modelos LSTM univariável e multivariável para os dados do Modo. Novamente, pode ser visto que ambos os modelos

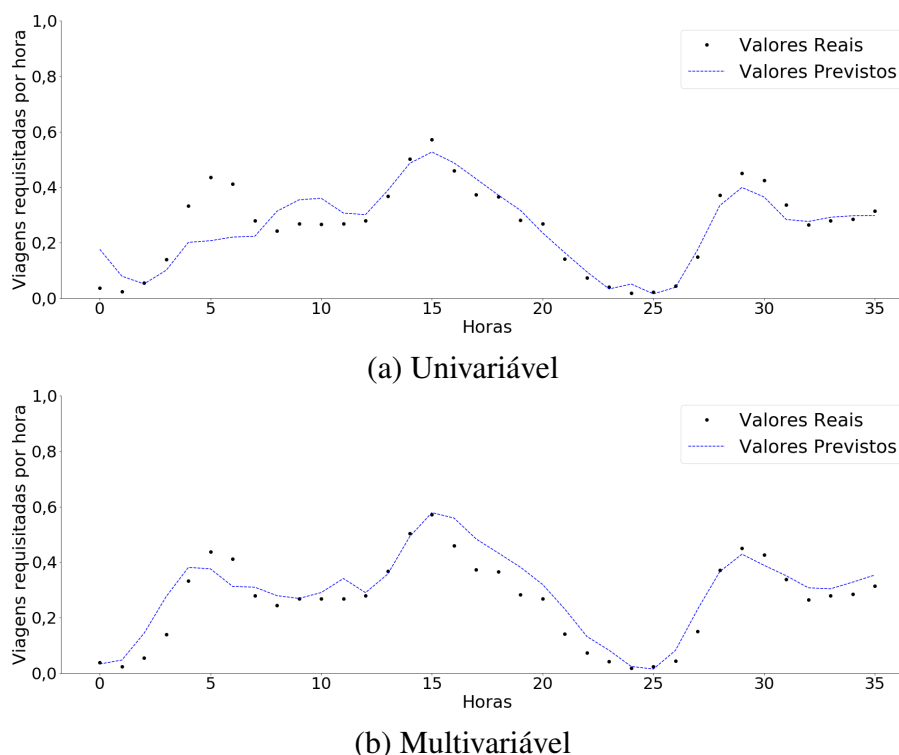


Figura 4. Previsão de 12 horas pelo modelo LSTM para o Evo.

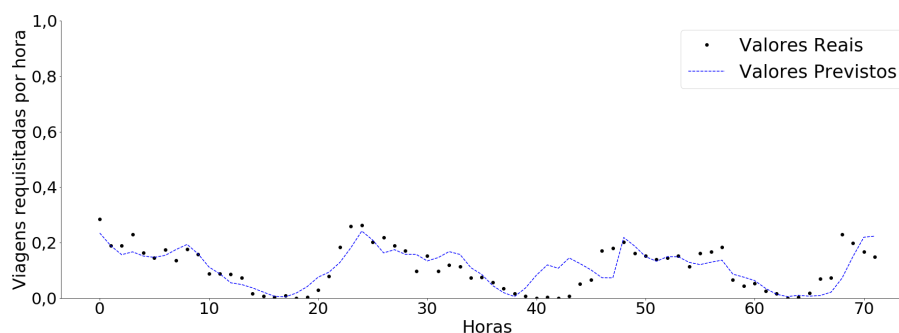
das Figuras 5-a e 5-b, em sua maioria, acertam o formato das curvas. Contudo, o modelo univariável não previu corretamente o terceiro pico de valores, uma vez que ele segue um comportamento diferente dos demais, o que resulta no crescimento dos valores de erro. O modelo multivariável apresenta resultados semelhantes ao modelo anterior, mas ele consegue prever o terceiro pico de demanda com maior precisão, além de diminuir o erro de magnitude em geral.

A Figura 6 apresenta os resultados obtidos pelos modelos LSTM univariável e multivariável para os dados do Car2Go. Para as Figuras 6-a e 6-b é possível visualizar que ambos os modelos obtiveram resultados semelhantes, sendo que estão seguindo o formato da curva real com boa performance e com poucas diferença de magnitude entre o valor predito e o real. Assim, visualmente ambos modelos estão prevendo as demandas reais com boa performance, somente sendo equivocados para picos extremos de demanda.

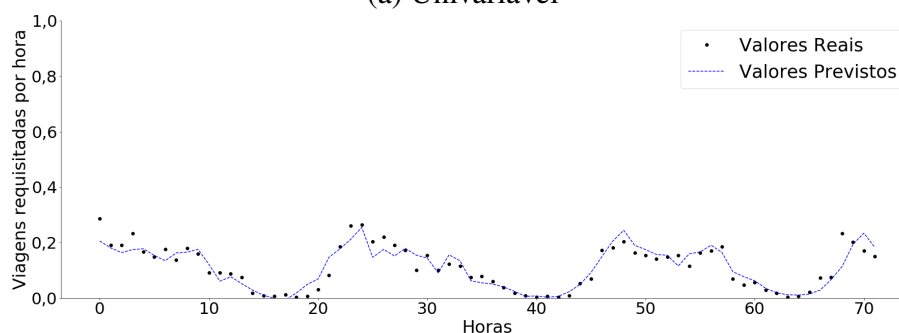
Serviço	MSE	MAE
Evo	0,019610	0,073403
Modo	0,005014	0,047543
Car2Go	0,006493	0,059610

Tabela 3. Valores das métricas obtidas pelo LSTM univariável.

A tabela 3 apresenta os valores das métricas obtidas pelo modelo LSTM univariável para cada serviço sobre os dados do lote de avaliação. Para o MSE é possível visualizar que os valores de todos os serviços estão indicando um bom desempenho do modelo para se adequar à curva real, mesmo com o Evo obtendo um valor que varia na segunda casa decimal. Para o MAE os valores estão variando na segunda casa decimal.



(a) Univariável



(b) Multivariável

Figura 5. Previsão de 12 horas pelo modelo LSTM para o Modo.

É interessante notar que os resultados do MAE mostram que em geral os modelos detêm erros que variam a partir de uma magnitude próxima.

Serviço	MSE	MAE
Evo	0,017541	0,078238
Modo	0,004699	0,041868
Car2Go	0,006556	0,057189

Tabela 4. Valores das métricas obtidas pelo LSTM multivariável.

A tabela 4 apresenta os valores das métricas obtidas pelo modelo LSTM multivariável para cada serviço sobre os dados do lote de avaliação. Para os valores de MSE, é possível notar que os valores estão muito próximos dos valores do modelo univariável apresentados na tabela 3, com a diferença que o Evo e o Modo melhoram de desempenho, ao contrário do Car2Go que por uma pequena diferença obteve piores resultados. Os valores do MAE também estão muito próximos dos valores do modelo univariável, uma vez que estão se diferenciando somente na terceira casa decimal. Mesmo com a pequena diferença entre os valores, o Modo e o Car2Go obtiveram uma melhoria de desempenho para o MAE, exceto o modelo do Evo que resultou em um decaimento de desempenho, mesmo que de pequena magnitude.

5.3. Análise dos resultados

Realizando uma comparação entre os modelos LSTM pode ser visto que, em geral, os multivariáveis obtiveram melhorias de desempenho, tanto visualmente quanto quantitativamente quando analisados os valores das métricas. Para os modelos do Car2Go, em

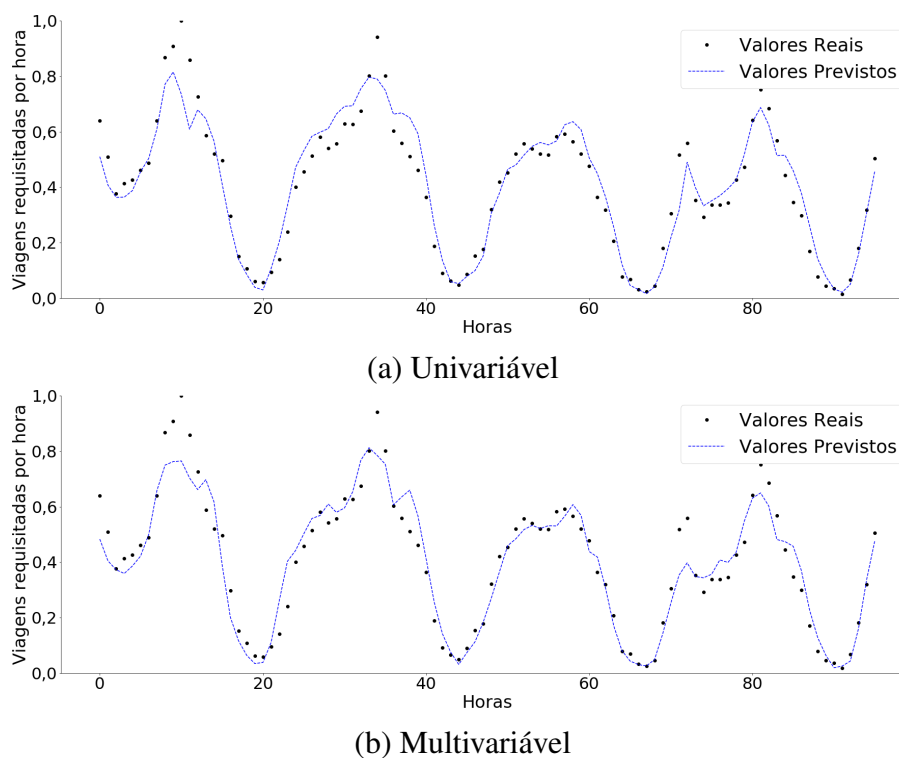


Figura 6. Previsão de 12 horas pelo modelo LSTM para o Car2Go.

especial, pode ser visto que as diferenças de desempenho foram mínimas. Mesmo assim, em geral pode ser dito que a adição dos dados meteorológicos auxiliaram na melhora do desempenho de previsão de demanda dos serviços.

Realizando uma comparação entre os modelos Prophet e LSTM, pode ser visto que há uma grande diferença de performance, uma vez que, mesmo para o modelo univariável o Prophet obteve resultados inferiores. Para o MSE os valores estão variando aproximadamente 0,003 pontos para o Modo e o Car2Go e 0,03 para o Evo. Para o MAE os valores variam em aproximadamente 0,02 pontos para o Modo e o Car2Go e 0,1 para o Evo. Além disso, pode ser dito que os modelos LSTM estão se comportando melhor para bases com dados faltantes, pois mesmo com o Evo detendo de muitos dos dados totais faltantes os modelos LSTM obtiveram resultados muito melhores que os do Prophet. Assim, podemos concluir que de fato o desempenho dos modelos Prophet são inferiores aos modelos LSTM univariável, conseqüentemente aos modelos LSTM multivariável.

6. Conclusão

Neste artigo, nós propomos modelos preditivos de séries temporais de demanda de três serviços de compartilhamento de veículos. Os dados utilizados foram obtidos de serviços situados na mesma região de Vancouver, Canadá, que foram filtrados para obter a demanda em um período com menos incidência de dados faltantes para ambos serviços. Foram propostos três modelos, sendo dois univariáveis e um multivariável. Com isso, exibimos e analisamos os resultados obtidos pelos modelos e os comparamos entre eles.

A análise dos modelos apresentou que todos os modelos obtiveram boa performance mesmo em um cenário com dados faltantes. O modelo Prophet exibiu como re-

sultados médios o valor de 0,0205 para o MSE e 0,111 para o MAE, que indicam que o modelo está se adequando bem a curva de dados, mas obtendo um erro absoluto médio que pode variar a demanda em aproximadamente 11%, o que o torna apropriado para a previsão do comportamento dos serviços. Contudo, os modelos LSTM desempenharam melhores resultados quando comparados com os valores obtidos pelo Prophet, onde o univariável obteve uma melhoria de 49,42% para o MSE e 45,62% para o MAE, e o multivariável resultou em uma melhoria de 53,20% para o MSE e 46,60% para o MAE, assim também pode ser visto que os dados multivariáveis influenciaram na melhoria do modelo LSTM. Por fim, é esperado que esta pesquisa possa influenciar no aprimoramento de estratégias de previsão e monitoramento de utilização de serviços de compartilhamento de veículos e afins.

Referências

- Alencar, V. A., Rooke, F., Cocca, M., Vassio, L., Almeida, J., and Vieira, A. B. (2019). Characterizing client usage patterns and service demand for car-sharing systems. *Information Systems*, page 101448.
- Boldrini, C., Bruno, R., and Conti, M. (2016). Characterising demand and usage patterns in a large station-based car sharing system. In *Computer Communications Workshops (INFOCOM WKSHPS), 2016 IEEE Conference on*, pages 572–577. IEEE.
- Cocca, M., Teixeira, D., Vassio, L., Mellia, M., Almeida, J. M., and Couto da Silva, A. P. (2020). On car-sharing usage prediction with open socio-demographic data. *Electronics*, 9(1):72.
- Hamari, J., Sjöklint, M., and Ukkonen, A. (2016). The sharing economy: Why people participate in collaborative consumption. *Journal of the association for information science and technology*, 67(9):2047–2059.
- Laptev, N., Yosinski, J., Li, L. E., and Smyl, S. (2017). Time-series extreme event forecasting with neural networks at uber. In *International Conference on Machine Learning*, volume 34, pages 1–5.
- Müller, J. and Bogenberger, K. (2015). Time series analysis of booking data of a free-floating carsharing system in berlin. *Transportation Research Procedia*, 10:345–354.
- Nourinejad, M. (2014). Dynamic optimization models for ridesharing and carsharing. Master's thesis, University of Toronto.
- Papacharalampous, G., Tyralis, H., and Koutsoyiannis, D. (2018). Predictability of monthly temperature and precipitation using automatic time series forecasting methods. *Acta Geophysica*, 66(4):807–831.
- Samal, K., Babu, K. S., Das, S. K., and Acharaya, A. (2019). Time series based air pollution forecasting using sarima and prophet model. In *Proceedings of the 2019 International Conference on Information Technology and Computer Communications*, pages 80–85. ACM.
- Shaheen, S. A. (2016). Mobility and the sharing economy. *Transport Policy*, 51(Supplement C):141 – 142.
- Taylor, S. J. and Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1):37–45.