

A UTILIZAÇÃO DA INFERÊNCIA BAYESIANA NA PREVISÃO DE ATRASOS EM ESQUEMAS *MILK-RUN* NA ERA DA INDÚSTRIA 4.0

Jaime Andres Cardona Arias

Antônio Galvão Naclério Novaes

Orlando Fontes Lima Junior

Laboratório de Aprendizagem em Logística e Transportes - LALT

Faculdade de Engenharia Civil, Arquitetura e Urbanismo

Universidade Estadual de Campinas – UNICAMP

José Eduardo Souza de Cursi

Laboratoire de Mécanique de Normandie

Institut National des Sciences Appliquées de Rouen – INSA

RESUMO

Com a chegada da Indústria 4.0 surgiram diversas tecnologias como a Internet das Coisas (IoT) e Computação em Nuvem (CC), o que aumentou o volume de dados disponíveis. Com sistemas IoT, os dados da manufatura ou da operação logística podem ser coletados e convertidos em informações valiosas mediante algoritmos para grandes volumes de dados. O objetivo deste artigo é desenvolver um modelo de previsão de atrasos na liberação de componentes, por parte de um fornecedor num esquema *milk-run*. O problema será estudado com a inferência Bayesiana. Foi aplicado o método de Monte Carlo via Cadeias de Markov (MCMC), especificamente o algoritmo de amostragem *Metropolis-Hastings* (MH). Para cada um dos parâmetros do modelo Bayesiano foi calculada a distribuição de probabilidade *a posteriori*. O modelo permite prever a magnitude dos atrasos futuros em função de quatro variáveis de incerteza do processo de fabricação do fornecedor.

ABSTRACT

Some technologies such as the Internet of Things (IoT) and Cloud Computing were born when the Industry 4.0 concept appeared. As a consequence, the data volume explodes. With IoT systems, manufacturing and logistics operating data can be collected and converted into valuable information using Big Data algorithms. The objective of this work is to develop a Bayesian model to have a reliable prevision of order release delays from a supplier in a milk-run operation. It is proposed a Bayesian inference method with a Markov Chain Monte Carlo approach. The Bayesian parameters will be estimated with the Metropolis-Hastings sampling algorithm. An *a posteriori* probability distribution for each Bayesian model parameter is calculated. The model allows to predict the magnitude of future delays as a function of four uncertainty variables of the supplier's manufacturing process.

1. INTRODUÇÃO

Em cadeias de suprimentos do tipo OEM (*Original Equipment Manufacturer*), diferentes fornecedores fabricam componentes para abastecer a linha de produção de uma manufatureira OEM, que monta produtos de maior valor agregado. Um exemplo de cadeias de suprimentos tipo OEM são as da indústria automotiva e de eletrônicos. Neste tipo de cadeia a OEM líder e todos os fornecedores trabalham de forma integrada para alcançar um objetivo comum (Safaei *et al.*, 2013) e adotam um esquema *milk-run* como estratégia de aquisição de componentes. O *milk-run* é um sistema programado de coleta de peças comumente adotado por indústrias montadoras. Este modelo nasceu do sistema tradicional de abastecimento da indústria leiteira em que se estabelecia uma rota para coletar o leite em cada fazenda. Quando o veículo fazia a coleta deixava ao mesmo tempo uma embalagem vazia para a seguinte coleta. De forma geral, em esquemas *milk-run* um caminhão sai de uma montadora para fazer coletas programadas num determinado período de tempo a vários fornecedores seguindo um roteiro previamente estabelecido e retorna à montadora quando finalizar as coletas. Os componentes fabricados por cada fornecedor são armazenados em contêineres de volume menor à capacidade do caminhão, dado que deve transportar os componentes produzidos por vários fornecedores.

Em esquemas *milk-run* os padrões tradicionais de recebimento, inspeção e armazenamento

são substituídos por acordos comerciais onde fornecedores se comprometem a entregar os componentes dentro de um prazo, em acordo com a manufatureira OEM (Novaes *et al.*, 2017). Caso os componentes sejam entregues pelo operador logístico nas instalações da OEM fora do prazo acordado, esta última penalizará monetariamente o fornecedor responsável. Os atrasos podem ser ocasionados por quebra de máquinas, falhas na fabricação de componentes, entre outros.

Tradicionalmente, após a ocorrência de um evento imprevisto nas operações de manufatura e logística, como a quebra de uma máquina, é necessário planejar novamente as atividades programadas, buscando manter as operações da cadeia ou melhorar seu desempenho. Ou seja, adota-se uma estratégia corretiva, dado que falhas na manufatura e na logística são corrigidas depois de serem registradas. Por outro lado, na visão da Indústria 4.0, a manufatura se torna preditiva e eventos imprevistos são detectados e prevenidos antes que aconteçam (Xu *et al.*, 2017).

No contexto da Indústria 4.0 é possível que as companhias possam lidar com as incertezas associadas ao seu processo produtivo e antecipar medidas corretivas para evitar falhas. Assim, o operador logístico, que coleta e transporta os componentes até a OEM, tem acesso a um repositório de dados do processo produtivo dos fornecedores e, a partir desse, prevê possíveis atrasos na liberação dos componentes e antecipa ações como a reprogramação dos ciclos *milk-run* de coleta.

O problema tratado no presente trabalho, da roteirização de veículos em esquemas OEM/*milk-run* em suas diferentes extensões, é estudado por outros autores com diferentes abordagens. Novaes *et al.* (2015) utilizaram um algoritmo genético para construir roteiros dinâmicos e designar as coletas, que provavelmente excederiam o tempo limite de entrega, a veículos auxiliares. Neste trabalho a única variável de atraso analisada foi o tempo de entrega dos componentes nas instalações da OEM. Já uma versão mais detalhada foi apresentada em Novaes *et al.* (2017), onde as variáveis definidas e analisadas são: a probabilidade de atraso de cada fornecedor na liberação dos componentes, o tempo médio de deslocamento do veículo e o atraso para cada fornecedor em cada ciclo *milk-run*. Por meio do algoritmo *Simulated Annealing* determinou-se a sequência de visitas do ciclo *milk-run* que minimizava o atraso.

Em Novaes *et al.* (2015) e Novaes *et al.* (2017) o operador logístico toma ciência do atraso na liberação dos componentes quando o veículo chega nas instalações do fornecedor. O problema é abordado com uma visão corretiva, na qual um veículo auxiliar unicamente é acionado após ocorrência do atraso. Paralelamente, dentro de uma visão preditiva como a contemplada pela Indústria 4.0, o operador logístico deveria tomar ciência do atraso antes da chegada do veículo às instalações do fornecedor e, assim, reprogramar o ciclo *milk-run*. Portanto, o uso de Inferência Bayesiana para prever possíveis atrasos na liberação de componentes em esquemas *milk-run*, apresenta-se como alternativa viável para a determinação de uma solução ótima ao problema.

Diante do exposto, o objetivo deste trabalho é a aplicação do método de Monte Carlo via Cadeias de Markov Carlo (MCMC), especificamente o algoritmo de *Metropolis-Hastings*, para construir um modelo de previsão de atrasos na liberação de componentes por parte dos fornecedores numa operação *milk-run*. Foram empregadas quatro variáveis consideradas como fonte de incerteza no processo de fabricação de um dos fornecedores que geram atrasos,

visando antecipar ações corretivas.

Este trabalho se estrutura da seguinte forma: na primeira seção é apresentada a revisão da literatura, seguida pela descrição do problema e a metodologia utilizada para prever atrasos. Posteriormente, são apresentados os resultados, o modelo de regressão Bayesiano e as conclusões sobre sua utilização.

2. PREVISÃO DE ATRASOS NA MANUFATURA DE COMPONENTES EM ESQUEMAS *MILK-RUN*

O esquema *milk-run* tem sido empregado em diversas indústrias, mas a indústria automotiva é a principal usuária deste sistema (Hosseini, 2014). Uma fabricante OEM contrata um operador logístico para uma operação *milk-run*, que coleta componentes ou partes nas instalações de diferentes fornecedores e, posteriormente, transporta-os até a linha de produção da fabricante OEM (Aragão *et al.*, 2019). O volume de componentes coletados em cada fornecedor é menor em relação à capacidade total do caminhão. Neste tipo de esquema, a frequência das viagens é maior, o que aumenta os custos do transporte, enquanto elimina os custos de armazenamento, por trabalhar com a filosofia JIT (*Just in Time*). A produção de componentes por parte das indústrias fornecedoras pode apresentar atrasos e, num esquema tradicional de coleta, o operador logístico tomará ciência do atraso quando o veículo de coleta chega às instalações do fornecedor. Essa situação pode ocasionar pedidos não entregues e afetar o acordo de entrega entre fornecedores e a OEM líder (Hu *et al.*, 2013). Por outro lado, na visão da Indústria 4.0 o operador logístico percebe a possibilidade de atraso antes que ele aconteça.

O *Big Data* possui diversas aplicações no contexto industrial, uma delas é a detecção e prevenção de falhas ou interrupções em sistemas produtivos. Segundo Bennacer *et al.* (2014), a maioria das abordagens desenvolvidas para a detecção de falhas são baseadas em análises estocásticas, teoria de grafos e técnicas de inteligência artificial. Na pesquisa desenvolvida por Jia *et al.* (2016), os autores desenvolvem uma Rede Neural Artificial com a finalidade de melhorar a precisão dos diagnósticos de falhas em um conjunto de máquinas. Para validar o método foi utilizada uma quantidade massiva de dados em diferentes condições de operação. Algumas pesquisas de detecção de falhas se concentram na construção de modelos de manutenção preventiva, mecanismos que atuam em tempo real (Wan *et al.*, 2017; Lee *et al.*, 2015). Sistemas de detecção de falhas permitem identificar com grande precisão a causa das interrupções num sistema, como no modelo desenvolvido por Bennacer *et al.* (2014) que utiliza Redes Bayesianas para detectar e prever falhas em redes VPN.

A principal característica da inferência Bayesiana na detecção e prevenção de falhas em sistemas produtivos é que, à medida que os dados são disponibilizados durante a operação do sistema, estas novas observações são consideradas na análise do problema em questão. O teorema de Bayes é uma ferramenta para recalculas as probabilidades de eventos não observados, em função da probabilidade *a priori* (informações já coletadas dos dados estudados) e a verossimilhança para obter a probabilidade *a posteriori* do parâmetro estudado (Fernandes, 2013). Uma abordagem de interesse para estimar a magnitude dos atrasos, na liberação dos pedidos de componentes nas instalações dos fornecedores, com grandes volumes de informações, é a utilização da inferência Bayesiana, em que o principal objeto é a distribuição *a posteriori*, isto é, as distribuições de probabilidade dos parâmetros do problema são corrigidas constantemente, a partir das novas observações durante a operação do sistema.

O cenário geral da inferência Bayesiana é formado por uma função $X = (X_1, \dots, X_m)$, que é um vetor de parâmetros observados, associado a um vetor de parâmetros desconhecidos θ , assumido como uma variável aleatória de distribuição *a priori* $\pi(\theta)$. Um modelo $f(X | \theta)$ é inicialmente definido. A distribuição *a posteriori* para a inferência estatística, relacionada aos parâmetros θ , de acordo com a formulação de Bayes, é dada por:

$$f(\theta|X) = \frac{f(X|\theta) \pi(\theta)}{\int f(X|u) \pi(u) \partial u} \quad (1)$$

A integral $\int f(X|u) \pi(u) \partial u$, que é a densidade marginal dos dados observados X , não depende de θ . Por outro lado, em problemas dimensionais relativamente complexos, a integral (1) pode ser difícil de solucionar (Minka, 2001). Mas uma forma de resolver este problema é através da aplicação do método Monte Carlo via Cadeias de Markov (MCMC), amplamente utilizado para resolver problemas técnicos inversos, como em Hassan *et al.* (2009) e Azizi *et al.* (2015). O método mais moderno de inferência Bayesiana é o MCMC, que serve para aproximar integrais complexas e custosas de avaliar de forma exata (Valero, 2013). Por meio dos métodos MCMC pode-se obter estimativas da magnitude do atraso, com aceitável nível de precisão. Supondo que $\tilde{x}_1, \dots, \tilde{x}_m$ são os valores amostrais do conjunto de variáveis aleatórias $X = (X_1, \dots, X_m)$ que caracterizam o caso em análise. A expectativa da função $f(X_1, \dots, X_m)$ pode ser aproximada através de (Kass *et al.*, 1998):

$$E[f(X)] = \sum_{\tilde{x}_1} \dots \sum_{\tilde{x}_m} f(\tilde{x}_1, \dots, \tilde{x}_m) * pr(X_1 = \tilde{x}_1, \dots, X_m = \tilde{x}_m), \quad (2)$$

Ou,

$$E[f(X)] \approx \frac{1}{N} \sum_{t=0}^{N-1} f(x_1^{(t)}, \dots, x_m^{(t)}), \quad (3)$$

Onde $x_1^{(t)}, \dots, x_m^{(t)}$ são os valores, no estágio t , do processo de inferência com uma amostra de tamanho N (Kass *et al.*, 1998). Empregando $X^{(t)} = \{X_1^{(t)}, \dots, X_m^{(t)}\}$ para representar o conjunto de variáveis no estágio t , a cadeia de Markov correspondente é definida assumindo-se uma distribuição inicial $X^{(0)}$ para $t=0$, e as probabilidades de transição para $X^{(t)}$ são calculadas a partir de $X^{(t-1)}$, aplicando as probabilidades de transição Markovianas. Essas probabilidades são escolhidas de modo que, a distribuição de $X^{(t)}$ deve convergir ergodicamente para um estado de equilíbrio estocástico, possibilitando que a cadeia de Markov resultante possa ser simulada por amostragem, a partir do estágio inicial e, na sequência, por meio das distribuições de transição condicionais sucessivamente. Para uma cadeia de Markov suficientemente extensa, a equação (3) pode ser usada para estimar as expectativas de $f(X)$ (Gilks *et al.*, 1996; Kass *et al.*, 1998, Novaes *et al.*, 2018).

Dentro do universo MCMC, existem diversos métodos de cálculo, entretanto o algoritmo de *Metropolis-Hastings* (MH) é o método MCMC mais popular. Assim, todos os algoritmos MCMC podem ser considerados como casos especiais do MH (Valero, 2013). O algoritmo de MH (Metropolis *et al.*, 1953; Hastings, 1970) produz amostras a partir de distribuições que poderiam ser de difícil amostragem: o algoritmo simula uma cadeia de Markov cuja distribuição estacionária é π , isto significa que, em longo prazo, as amostras da cadeia se aproximam das amostras de π . Dada uma distribuição de probabilidade $p(x)$, o algoritmo de *Metropolis-Hastings* que será utilizado nesta formado pelas seguintes etapas:

- i. Inicia-se arbitrariamente com um ponto qualquer de x ;
- ii. Gera-se um novo valor x' da distribuição $x' \sim q(x'|x)$;
- iii. Aceita-se o novo valor com probabilidade

$$\alpha(x, x') = \min \left\{ 1, \frac{p(x')q(x|x')}{p(x)q(x'|x)} \right\} \quad (4)$$

- iv. Repetir o passo i ;

Onde $q(x'|x)$ representa a distribuição de probabilidade proposta de x que está sendo estudada, e indica a probabilidade de que a cadeia no estado x gere um valor x' . Com os valores dessas probabilidades calcula-se a probabilidade de aceitação do novo valor. Desta forma o algoritmo simula uma cadeia de Markov até que a convergência seja alcançada. Uma das principais aplicações do algoritmo de MH na indústria têm sido a estimativa de tempos de ciclo de manufatura (Fan, 2006; Chen *et al.*, 2001).

3. MODELO DE PREVISÃO DE ATRASOS NA INTEGRAÇÃO MANUFATURA/LOGÍSTICA

Atualmente, os conceitos e práticas de JIT estão sendo amplamente estudados e utilizados na gestão de cadeias de suprimentos do tipo OEM, com o fim de reduzir custos logísticos e integrar estreitamente as operações de manufatura e logística (Ullrich, 2013). Neste tipo de operações, procura-se reduzir até zero o nível do inventário de componentes em cada um dos elos da cadeia e, desta forma, excluir os custos de armazenamento. Dentro da filosofia JIT, a linha de produção da montadora OEM é abastecida com uma alta frequência e de acordo com seu programa de produção. Dessa forma, garante-se que os componentes necessários para a montagem de novos lotes de produção estejam disponíveis na montadora no momento certo.

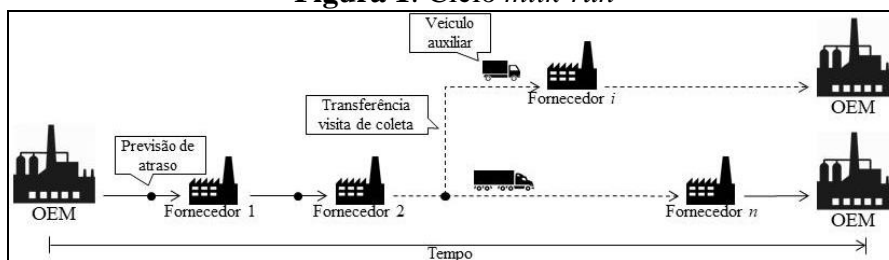
A linha de produção de uma montadora é complexa, ela é responsável por gerenciar e coordenar um conjunto de diversos fornecedores que a abastecem. À medida que mais fornecedores integram a cadeia de suprimentos, maior a incerteza e probabilidade de que os componentes não sejam entregues no momento certo nas instalações da OEM. Para Safaei *et al.* (2013) a somatória das incertezas individuais de cada um dos fornecedores da cadeia gera uma incerteza maior na linha de produção da manufatureira OEM. Estas últimas podem ser geradas por eventos aleatórios imprevisíveis, como atrasos na liberação de componentes nas instalações do fornecedor.

Atrasos na fabricação de componentes podem ser ocasionados por quebras de máquinas, mão-de-obra deficiente, variações no tempo de ajuste de máquinas, taxa de produção, etc. Operações como as de cadeias de suprimentos do tipo OEM demandam sistemas logísticos, os suficientemente sofisticados, para lidar com atrasos, além de garantir a integração entre a manufatura e a logística. Por isso, em cadeias de suprimentos do tipo OEM se adota a operação *milk-run* para coletar e transportar componentes até a montadora. Por exemplo, através de um esquema dinâmico de *milk-run* no qual sejam previstos os atrasos dos fornecedores, as consequências dos atrasos podem ser mitigadas. Se o operador logístico prevê um nível de atraso muito alto na fabricação de componentes, será necessário acionar uma medida corretiva, nesse caso, transferir a visita de coleta em questão a um veículo auxiliar, o qual parte das instalações da OEM e faz a coleta do lote de produção atrasado. Com esta estratégia, o veículo principal pode continuar com a sequência de visitas do seu ciclo *milk-run*.

A estratégia dinâmica do ciclo *milk-run* consiste em remover do roteiro aqueles fornecedores, que segundo o modelo de previsão do operador logístico, vão se atrasar na liberação dos componentes. Como se observa na Figura 1, a previsão se realiza antes do deslocamento até o fornecedor que será atendido. Dessa forma pode-se tomar uma medida antecipada, como transferir a visita de coleta do fornecedor em questão a um veículo auxiliar.

Por outra parte, fatores externos como condições climáticas extremas, greves no transporte público, congestionamentos, etc., aumentam o nível de incerteza no deslocamento dos veículos de coleta na operação *milk-run*. Portanto, é necessário que o esquema *milk-run* dinâmico adote uma estratégia de tempo real, em função das condições de tráfego na região de operação do sistema.

Figura 1: Ciclo *milk-run*



Para condições de tráfego regulares, o operador logístico programa as rotas dos ciclos *milk-run* com base em previsões de tráfego padrões para certos períodos do dia. Para isso, é necessário ter acesso a repositórios de dados públicos ou privados. Numa visão mais sofisticada, como a da Indústria 4.0, se utilizam grandes volumes de dados para prever congestionamentos através de Redes Bayesianas, Clusterização ou Aprendizado de Máquina Profundo e modificar dinamicamente os roteiros dos veículos de coleta do sistema. Por exemplo, no trabalho desenvolvido por Guner *et al.* (2017), foram utilizados dados de um repositório público com grandes volumes de dados sobre a variação da velocidade ao longo do dia para determinada zona urbana e, a partir deste, foi estimada a velocidade média e seu respectivo desvio padrão para trechos específicos da zona. Em países em desenvolvimento é difícil implementar este tipo de estratégia, principalmente porque tais dados não estão disponíveis hoje, a não ser em situações muito específicas, nesses casos, é possível adotar formas mais simples de prever os congestionamentos. Apesar de congestionamentos serem fonte de atrasos em operações *milk-run*, neste trabalho apenas serão considerados aqueles atrasos relacionados com a liberação dos componentes nas instalações dos fornecedores.

3.1. Descrição do problema

Num esquema *milk-run*, conformado por uma fabricante OEM, um conjunto de fornecedores e um operador logístico, um dos fornecedores implanta um sistema *Big Data* de informações sobre o processo de fabricação de seus componentes. Entre os objetivos do sistema implantado, está o fornecimento de informações relacionadas ao processo produtivo do turno de coleta *i*, bem como a magnitude do atraso (caso ocorra), ao operador logístico que faz a coleta e transporta os componentes à OEM líder. Desta forma, o operador logístico poderá realizar correções nas suas atividades antes que os atrasos efetivamente aconteçam. O fornecedor produz componentes no turno entre as 8 horas da manhã e 16 horas, um total de 8 horas. O operador logístico deve coletar os componentes em um momento *H* dentro do turno *i*, horário esse estipulado pela OEM. Neste problema específico, são considerados apenas os atrasos na liberação dos componentes originados na manufatura do fornecedor.

Para prever atrasos na liberação de componentes numa indústria fornecedora é essencial avaliar e analisar as principais causas de incerteza. Para Koh *et al.* (2006) os principais fatores de incerteza em um ambiente de manufatura são as mudanças na demanda, variações no tempo de produção e quebra de máquinas. O problema estudado neste artigo envolve quatro variáveis de incerteza, relacionadas aos atrasos nas liberações. A primeira variável é o instante de coleta dos componentes (*ic*), que indica o instante *t* em que os mesmos foram coletados nas instalações do fornecedor. A segunda é a ocorrência de quebra de máquina (*qm*), variável binária, quando for 1 houve quebra de máquina, caso contrário, não houve. A terceira é o instante *t* de quebra da máquina (*iq*): caso aconteça, esta variável indica o momento em que a máquina do processo de fabricação de componentes do fornecedor quebrou. Caso *qm* for zero, o valor de *iq* também será nulo. A quarta variável é a taxa de utilização do sistema produtivo do fornecedor (*tu*). Para Branke e Matfeld (2005), uma taxa de utilização do sistema produtivo em torno de 0.7 representa uma situação confortável, enquanto 0.8 e 0.9 representam uma carga intermediária e elevada, respectivamente.

As informações do processo produtivo e a magnitude dos atrasos do fornecedor são armazenadas num repositório e compartilhadas com o operador logístico, para que este último faça as previsões. Neste artigo foi analisado um conjunto de dados de 960 turnos (dias úteis sucessivos) referentes a um fornecedor. Cada linha do banco de dados compreende o turno *i* e os respectivos valores das variáveis *ic*, *qm*, *iq* e *tu*, além da magnitude do atraso em horas. Caso não haja atraso no turno *i*, a magnitude será zero. Na Tabela 1 é apresentada uma descrição estatística geral do banco de dados do fornecedor em questão.

Tabela 1: Descrição estatística das variáveis

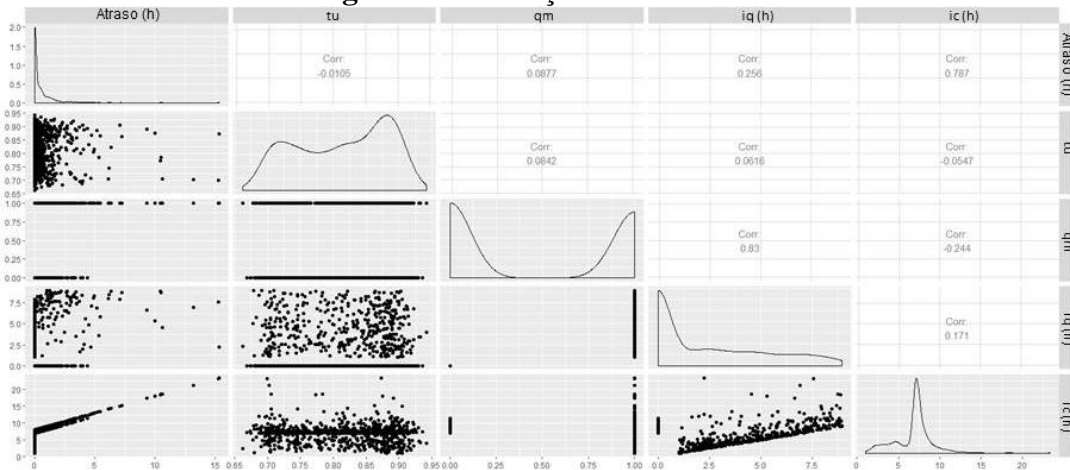
	<i>Instante de coleta ic (h)</i>	<i>Quebra de máquina qm</i>	<i>Instante de quebra iq (h)</i>	<i>Taxa de utilização tu</i>	<i>Atraso (h)</i>
Mínimo	1.04	0	0.00	0.66	0.00
Máximo	23.33	1	8.96	0.94	15.33
Média	6.92	-	2.15	0.81	0.62
Desv. Pad.	2.51	-	2.77	0.07	1.43

Das 960 observações, em 443 turnos o valor do atraso foi 0.00 horas. Para prever a magnitude do atraso em cada turno foi utilizado o método MCMC, algoritmo de *Metropolis-Hastings*.

3.2. Previsão de atrasos na liberação de componentes

A limpeza dos dados é uma das primeiras etapas em um estudo que envolve grandes volumes de informação. A primeira etapa consiste em preparar os dados observados para análise estatística, uma vez que o banco de dados pode ter linhas faltantes, duplicidades, erros de formato, ou de estrutura. Após preparar os dados, uma análise exploratória dos mesmos é realizada, visando obter um conhecimento inicial, antes da análise Bayesiana. Entre as diferentes análises iniciais executadas, na Figura 2 são mostradas as correlações entre todas as variáveis do problema.

Figura 2: Correlação das variáveis



A partir da análise de correlação, se pode afirmar que o instante de coleta (*ic*) e o instante de quebra de máquina (*iq*) têm uma correlação positiva com o atraso de 0.787 e 0.256, respectivamente. Isto indica que os atrasos podem ter uma forte relação com o instante em que os componentes são coletados nas instalações do fornecedor. Já a taxa de utilização (*tu*) e a quebra de máquina (*qm*) tem uma baixa relação com o atraso.

O objetivo do modelo construído é descrever a variação de *y* em termos das variáveis explicativas x_1, \dots, x_k , onde *y* é o atraso previsto para a fabricação do componente. Para o modelo Bayesiano proposto $y_i = (Atraso_i)$ e $x_i = (tu_i, qm_i, iq_i, ic_i)$. Nesse sentido, na Equação (5) todas as variáveis são aleatórias. O valor médio do *Atraso*, em resposta ao *i*-ésimo valor individual de tu_i, qm_i, iq_i e ic_i , pode ser descrito por:

$$E(Atraso_i | \beta, X) = \beta_0 + \beta_1 * ic_i + \beta_2 * tu_i + \beta_3 * qm_i + \beta_4 * iq_i \quad (5)$$

Onde, β_0, \dots, β_4 são conhecidos como os parâmetros de regressão. A distribuição de probabilidade *a priori* para cada parâmetro do modelo foi definida como uma função de probabilidade normal, com média zero e desvio padrão de 10 horas, como observado em algumas pesquisas que utilizam o método MCMC como em Azizi *et al.* (2015) e autores como Gelman (2006), que recomendam seu uso para problemas que lidam com distribuições de probabilidade *a priori* pouco informativas. Portanto, as probabilidades *a priori* para os parâmetros $\beta_0, \beta_1, \beta_2, \beta_3$ e β_4 são descritas por distribuições de probabilidade normal $N(0,10)$, em horas.

A distribuição de probabilidade *a priori* representa a informação de certo parâmetro *x* desconhecido, que combinado à distribuição de probabilidade de novas observações, resulta na distribuição *a posteriori*, esta ultima utilizada para inferir e tomar decisões futuras que envolvem *x* (Gelman, 2002). Nesse sentido, a partir da função de probabilidade *a priori* são computadas as distribuições *a posteriori* para cada um dos parâmetros do modelo. Assume-se que os erros do modelo $\epsilon_i = Atraso_i - E(Atraso_i | \beta, X)$ são independentes e estão normalmente distribuídos com média zero e variância igual a 100 h². Em notação matricial o modelo para todas as observações pode ser descrito como:

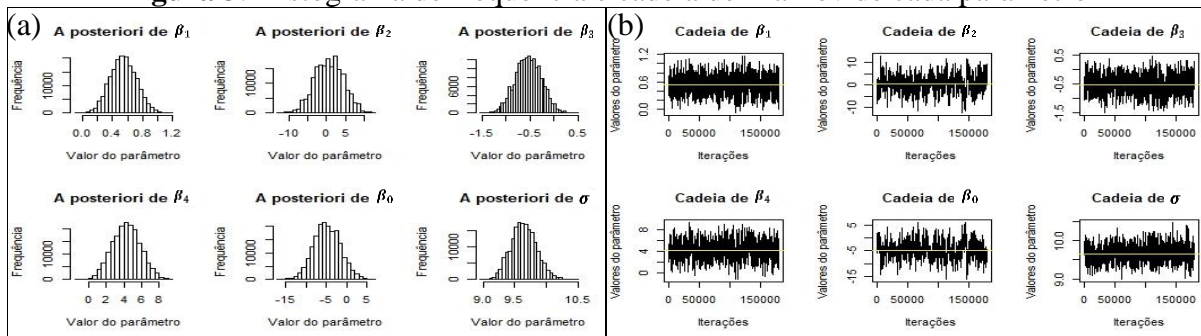
$$Atraso_i | \beta, \sigma^2, X \sim N_n(X \beta, \sigma^2 I) \quad (6)$$

O modelo Bayesiano foi construído depois de 200.000 replicações, utilizando a linguagem de programação R. Para isso foram utilizadas principalmente as bibliotecas, *coda*, *mcmcse* e *mcmc*. O alto número de iterações pode ser explicado pela quantidade de variáveis explicativas do modelo (quatro). Isso pode requerer um maior esforço computacional para alcançar a convergência. Os primeiros valores simulados da cadeia (*burn-in period*) devem ser excluídos da análise porque o processo ainda não alcança o estado estacionário.

4. RESULTADOS


Considerando as distribuições de probabilidade *a priori* que foram definidas previamente, foi construída uma cadeia de 200.000 iterações para cada parâmetro do modelo Bayesiano. Foram descartadas as primeiras 20.000 iterações. Na Figura 3(a), os histogramas representam as densidades aproximadas da distribuição de probabilidade *a posteriori* de cada um dos parâmetros do modelo Bayesiano, os quais são descritos por distribuições de probabilidade normal. Os traços do MCMC das amostras *a posteriori* para cada um dos parâmetros se apresentam na Figura 3(b). A linha amarela representa a média *a posteriori* para cada parâmetro construído a partir da amostra em cada iteração.

Figura 3: Histograma de frequência e cadeia de Markov de cada parâmetro



A partir dos traços obtidos na Figura 3(b), é possível afirmar que as cadeias conseguiram convergir. Para demonstrar este fato, foi necessário realizar uma análise gráfica da convergência para cada um dos parâmetros do modelo. Na Figura 4, é apresentada a convergência do parâmetro β_4 . A linha amarela representa o valor *a posteriori* da média, que é o valor para o qual converge a cadeia do parâmetro em questão. Além disso, é evidenciado novamente que o número de interações necessárias foi igual a 200.000.

Figura 4: Convergência de β_4



As médias estimadas das distribuições *a posteriori* dos parâmetros β_i foram calculadas com um intervalo de credibilidade Bayesiano *a posteriori* de 95%. Os resultados obtidos se resumem na Tabela 2.

Tabela 2: Estimadores Bayesianos. Resumo dos valores *a posteriori* dos parâmetros

Parâmetros	Média	Desvio Padrão	95% (Intervalo de credibilidade)
β_0	-2.5468	3.3857	(-9.0979:3.9757)
β_1	0.7047	0.1730	(0.3657:1.0397)
β_2	-3.1461	3.8322	(-10.6563:4.2108)
β_3	-0.6267	0.2727	(-1.1699:-0.1089)
β_4	4.6643	1.5349	(1.8195:7.8396)
σ	9.4815	0.2105	(9.0682:9.8921)

Na Tabela 2 observam-se as estimativas das médias *a posteriori* e o desvio padrão de cada um dos parâmetros que conformam o modelo Bayesiano. Na sequência o modelo Bayesiano é apresentado.


4.1. Modelo bayesiano

O modelo bayesiano de previsão de atrasos é formulado na Equação 7:

$$Atraso_i' = -2.5468 + 0.7047 * ic_i - 3.1461 * tu_i + 0.6267 * qm_i + 4.6643 * iq_i + \varepsilon_i \quad (7)$$

O modelo construído pretende servir ao operador logístico que se encarrega de coletar os componentes e transportá-los até a linha de montagem da OEM. Com o modelo de previsão, é possível que o operador logístico determine se o fornecedor sofrerá um atraso. Quando um atraso for previsto, o operador logístico pode antecipar uma ação corretiva, como retirar esse fornecedor do seu roteiro e designar a coleta a um veículo auxiliar, com o objetivo de cumprir os compromissos de entrega estabelecidos entre os integrantes do esquema *milk-run*. Para validar o modelo comparou-se a magnitude dos atrasos previstos com os reais observados dentro de um período. Para isso o tamanho da mostra foi de aproximadamente o 10% dos atrasos observados, ou seja, 100 observações (do turno 861 ao turno 960) comparadas com 100 atrasos modelados com a Equação 7. Na Figura 5 são mostradas a distribuição de probabilidade acumulada dos atrasos observados e com os modelados.

Figura 5: Distribuição de probabilidade acumulada dos atrasos observados e modelados.



A média do atraso observado é 0.46 h com um desvio padrão de 0.87 h, enquanto a média do atraso modelado é 0.68 horas com desvio padrão de 1.01 h. O comportamento da curva de distribuição de probabilidade acumulada dos atrasos observados e dos modelados tendem a uma distribuição exponencial negativa. Isto pode ser sinal de que o modelo Bayesiano construído está mimetizando, até certo grau, o comportamento do atraso real observado.

5. CONCLUSÕES

Neste artigo foi utilizada uma abordagem Bayesiana, o método de Monte Carlo baseado em cadeias de Markov para formular um modelo de previsão de atrasos na liberação de componentes numa indústria fornecedora. Estes valores de atrasos ajudarão o operador logístico a rever sua programação de coleta de componentes com razoável antecipação, melhorando assim o cumprimento dos acordos de entrega com a empresa OEM líder. Através do algoritmo de *Metropolis-Hastings* foram simuladas as cadeias de Markov de cada um dos parâmetros do modelo, para determinar a sua respectiva distribuição de probabilidade *a posteriori* e definir o modelo Bayesiano. O modelo resultante foi validado através da comparação entre os atrasos observados e os modelados. A curva da função de probabilidade acumulada para os dados observados e modelados foi descrita por uma exponencial negativa. É de conhecimento dos autores que o modelo Bayesiano utilizado não é o mais sofisticado para realizar a inferência dos atrasos, e que outros modelos poderiam melhorar a função explicativa. Assim, o desenvolvimento futuro desta pesquisa contempla a elaboração e aplicação de um modelo híbrido com o de Mills (2013), dado que no problema algumas das variáveis se caracterizam por ter muitos valores nulos, junto com valores reais positivos, como o caso dos atrasos ou dos instantes de quebra de máquina (*iq*). Nesse sentido, com a aplicação de métodos MCMC mais elaborados, será possível obter melhor precisão no modelo Bayesiano.

A principal motivação para utilizar inferência Bayesiana, especificamente o método MCMC, baseia-se no fundamento de que esquemas *milk-run* são dinâmicos, e à medida que os componentes são coletados podem surgir eventos inesperados como atrasos na fabricação e liberação dos componentes, e os métodos MCMC além de considerar dados históricos na suas previsões, também considera dados que são disponibilizados durante a operação do sistema. Desta forma o modelo pode atualizar as previsões quando novos dados alimentam o sistema.

Por outro lado, o banco de dados utilizado para a construção do modelo foi criado mediante simulações, pois nesta etapa da pesquisa não foi possível adquirir dados de uma situação real em que fosse utilizada uma operação de *milk-run*. Ademais, em países em desenvolvimento, como o Brasil, situações mais sofisticadas de aplicações de esquemas *milk-run* são escassas. Nesse sentido, para as próximas etapas da pesquisa, pretende-se utilizar dados possivelmente extraídos de uma situação real.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

REFERÊNCIAS BIBLIOGRÁFICAS

- Aragão, D.; A. Novaes e M. Luna (2019) An agent-based approach to evaluate collaborative strategies in milk-run OEM operations. *Computers & Industrial Engineering*, v. 129, p. 545 – 555.
- Azizi A.; A. Ali.; L. Ping e M. Mohammadzadeh (2015) Production uncertainties modelling by Bayesian inference using Gibbs sampling. *South African Journal of Industrial Engineering*, v. 26, p. 27 – 40.
- Bennacer, L.; Amirat, Y.; Chibani, A.; A. Mellouk, e L. Ciavaglia (2015) Selfdiagnosis technique for virtual private networks combining Bayesian networks and case-based reasoning. *IEEE Trans. Autom. Sci. Eng.*, v. 12, n. 1, p. 354 – 366.
- Branke, J. e D. Mattfeld (2005) Anticipation and flexibility in dynamic scheduling. *IJPR*, v. 43, p. 3103 – 3129.
- Chen, C.; E. George e V. Tardif (2001) A Bayesian model of cycle time prediction. *IIE Transactions*, v. 33, n. 10, p. 921 – 930.
- Fan, C. (2006) Estimating manufacturing cycle time by Markov Chain Monte Carlo. *IIE Annual*, Orlando.
- Fernandes, L. (2013) Inferência bayesiana em modelos discretos com fração de cura. *Dissertação (Dissertação)*

- em Estatística*) – UnB. Brasília, p. 64.
- Gelman, A. (2002) Prior distribution. In: El-Shaarawi, A.; Piegorisch, W. (Ed). *Encyclopedia of Environmetrics*. Chichester: John Wiley & Sons, p. 1634 – 1637.
- Gelman, A. (2006) Prior distributions for variance parameters in hierarchical models. *Bayesian Analysis*, v. 1, p. 515 – 534.
- Gilks, W.R.; S. Richardson e D. Spiegelhalter (1996) *Markov Chain Monte Carlo in Practice*. London, UK: Chapman & Hall.
- Guner, A.; A. Murat e R. Chinnam (2017) Dynamic routing for milk-run tours with time windows in stochastic time-dependent networks. *Transportation Research Part E*, v. 97, p. 251 – 267.
- Hassan, A.; M. Bekhit e J. Chapman (2009) Using Markov Chain Monte Carlo to quantify parameter uncertainty and its effect on predictions of a groundwater flow model. *Environmental Modelling & Software*, v. 24, p. 749 – 763.
- Hastings, W. (1970) Monte Carlo sampling methods using Markov chains and their applications. *Biometrika*, v. 57, n. 1, p. 97 – 109.
- Hosseini, S.D. (2014) Cross-docking and milk run logistics in a consolidation network: A hybrid of harmony search and simulated annealing approach. *Journal of Manufacturing Systems*, v. 33, n. 4, p. 567 – 577.
- Hu, Y.; J. Lie e L. Holloway (2013) Resilient control for serial manufacturing networks with advance notice of disruptions, *IEEE Transactions on Systems, Man, and Cybernetics*, v. 42, n.1, p. 98 – 114.
- Jia, F.; Lei, Y.; Lin, J.; X. Zhou e N. Lu (2016) Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *MSSP*, v. 3, p. 303 – 315.
- Kass, R.E.; Carlin, B.; A. Gelman e R. Neal (1998) Markov Chain Monte Carlo in practice: A roundtable discussion. *The American Statistician*, v. 52, p. 93 – 100.
- Koh, S.; A. Gunasekaran e S. Saad (2005) A business model for uncertainty management. *Benchmarking: An International Journal*, v. 12, p. 383 – 400.
- Lee, J.; Ardakani, H.; S. Yang e B. Bagheri (2015) Industrial Big Data Analytics and Cyber-physical Systems for Future Maintenance & Service Innovation. *Procedia CIRP*, v. 38, p. 3 – 4.
- Metropolis, N.; Rosenbluth, A.; M. Rosenbluth e A. Teller. (1953) Equation of State Calculations by Fast Computing Machines. *The Journal of Chemical Physics*, v. 21, n. 6, p. 1087 – 1092.
- Mills, E. (2013) Adjusting for covariates in zero-inflated gamma and zero-inflated log-normal models for semicontinuous data. *Tese (Tese em Estatística)* – Universidade de Iwoa, p. 280.
- Minka, T.P. (2001) A family of algorithms for approximate Bayesian inference. *Tese (Tese em estatística)* - Massachusetts Institute of Technology, Cambridge, Mass, USA.
- Novaes, A.; Lima Jr, F.; M. Luna e E. Bez (2017) Mitigating supply chain tardiness risks in OEM milk-run operations. *Dynamics in Logistics – Proceedings: 5th International Conference*, LDIC, Bremen, p. 141 – 150.
- Novaes, A.; Bez, E.; P. Burin e D. Aragão (2015) Dynamic milk-run OEM operations in over-congested traffic conditions. *Computers & Industrial Engineering*, v. 88, p. 326 – 340.
- Novaes, A.; F. Lima Jr e G. Montoya (2018) Forecasting Manufacturing Tardiness in OEM Milk-Run Operations Within the Industry 4.0 Framework. *Dynamic in Logistics – Proceedings of the 6th International Conference*, LDIC 2018, Bremen, p. 305 – 309.
- Safaei, M.; Issa, S.; Seifert, M.; K. Thoben e W. Lang (2013) A method to estimate the accumulated delivery time uncertainty in supply networks. *Dynamics in Logistics – Proceedings: Third International Conference*, LDIC, Bremen, p. 337 – 347.
- Ullrich, C. (2013) Integrated machine scheduling and vehicle routing with time windows. *European Journal of Operational Research*, v. 227, p. 152 – 165.
- Valero, S. (2013) Métodos MCMC para la inferencia Bayesiana. *TFC (Graduação em telecomunicações)* – Universidad Carlos III de Madrid, p. 74.
- Wan, J.; Tang, S.; Li, D.; Wang, S.; Liu, C.; H. Abbas e A. Vasila (2017) A manufacturing big data solution for active preventive maintenance. *IEEE Trans. Ind. Informat.*, v. 13, n. 4, p. 2039 – 2047.
- Xu, Y.; Sun, Y.; Wan, J.; X. Liu e Z. Song (2017) Industrial big data for fault diagnosis: Taxonomy, review, and applications. *IEEE Access*, v. 5, p. 17368 – 17380.

Jaime Andres Cardona Arias (jaiandcardona@utp.edu.co)

Antônio Galvão Naclério Novaes (antonio.novaes1992@gmail.com)

Orlando Fontes Lima Junior (oflimaj@fec.unicamp.br)

José Eduardo Souza de Cursi

Laboratório de Aprendizagem em Logística e Transportes - LALT, DGT, FEC, Universidade Estadual de Campinas - UNICAMP

R. Albert Einstein, 951, 3º Piso, Sala 02, Cidade Universitária, Barão Geraldo, Campinas, SP, Brasil.