

Criação de Modelo de Detecção de Anomalias para Termômetro IoT Usado em Refrigeradores Hospitalares

Creation of Anomaly Detection Model for IoT Thermometer Used in Hospital Refrigerators

Diego Mendes¹

 orcid.org/0000-0001-6934-6614

Ingrid Nunes¹

 orcid.org/0000-0002-2015-9620

Selton Guedes¹

 orcid.org/0000-0003-1056-7871

Elyr Teixeira²

 orcid.org/0000-0003-1754-5886

¹ Escola Politécnica de Pernambuco, Universidade de Pernambuco, Recife, Brasil. E-mail: dms3@ecomp.poli.br

²Senfio – Soluções Tecnológicas, Recife, Brasil.

DOI: 10.25286/rep.v6i5.2159

Esta obra apresenta Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.

Como citar este artigo pela NBR 6023/2018: MENDES, D.; NUNES, I.; GUEDES, S.; TEIXEIRA, E. Criação de Modelo de Detecção de Anomalias para Termômetro IoT Usado em Refrigeradores Hospitalares. Revista de Engenharia e Pesquisa Aplicada, Recife, v.6, n. 5, p. 120-128, Novembro, 2021.

RESUMO

Ambientes hospitalares precisam de refrigeradores hospitalares para armazenar fármacos, vacinas, bolsas de sangue, dentre outros. Tais equipamentos são configurados de forma a manter determinada faixa de temperatura, visto que os produtos armazenados são sensíveis a mudanças de temperatura fora dessa faixa. Este projeto objetiva analisar as variações de temperatura acima do adequado. Nos experimentos realizados foram implementados diferentes técnicas de detecção de anomalias utilizando três métodos de agrupamento: *k-means*, DBSCAN e *Isolation Forest*. Levando em consideração a acurácia encontrada (76,7%), o método utilizado foi o DBSCAN. Com a análise realizada, foi possível perceber diversas relações entre os valores de temperatura, quantidade de alertas e os horários que eles aconteceram. Observou-se que a maior parte das anomalias encontradas aconteceram entre às 6:00 e às 8:00 horas da manhã, coincidindo com o horário de troca de turnos entre funcionários.

PALAVRAS-CHAVE: Termômetro IoT; Mineração de dados; Detecção de Anomalias; Refrigeradores Hospitalares.

ABSTRACT

Hospital environments need hospital refrigerators to store drugs, vaccines, blood bags, among others. Such equipment is configured in order to maintain a certain temperature range, since the stored products are sensitive to temperature changes beyond this range. This project aims to analyse the temperature variations beyond adequate. In the experiments performed, different anomaly detection techniques were implemented, using three clustering methods: k-means, DBSCAN and Isolation Forest. Taking into account the accuracy found (76.7%), the method used was DBSCAN. With the analysis performed, it was possible to see several relationships between the temperature values, the number of alerts and the times they happened. It was observed that most of the anomalies found happened between 6:00 and 8:00 am, coinciding with the shift change time between employees.

KEY-WORDS: IoT thermometer; Data mining; Anomaly Detection;

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Ambientes hospitalares, clínicas, laboratórios e hemocentros, precisam de geladeiras específicas (ou refrigeradores hospitalares) para o armazenamento de fármacos, vacinas, bolsas de sangue, dentre outros. Tais equipamentos de refrigeração, são configurados de forma a manter determinada faixa de temperatura, visto que os produtos armazenados são sensíveis a mudanças de temperatura além da faixa adequada para cada tipo de ativo [1].

1.2 DESCRIÇÃO DO PROBLEMA

A má gestão e mau uso dos refrigeradores hospitalares podem causar o comprometimento de medicamentos, vacinas, dentre outros produtos ali armazenados. Um exemplo prático dessa situação, ocorreu em 2017, em Brasília, onde várias doses de imunoglobulina humana e outros medicamentos foram desperdiçados por terem sido armazenados em temperatura incorreta [2]. Além desse caso, no Amapá, auditores encontraram embalagens de suco, frutas e garrafas d'água nos mesmos refrigeradores usados para guardar os remédios [2]. Usar os refrigeradores para guardar alimentos e bebidas, permite contaminações e colabora para que o refrigerador seja aberto com maior frequência, dificultando a manutenção da temperatura apropriada [1]. No caso de vacinas, o monitoramento de temperatura deve ser feito tanto no transporte quanto no armazenamento, pois pode gerar invalidade das mesmas. Em julho de 2021, o Distrito Federal recebeu 40,1 mil doses de vacinas congeladas, que ficaram indisponíveis para uso [3].

1.3 OBJETIVO

Este trabalho tem por objetivo fazer uma análise dos dados obtidos de refrigeradores hospitalares sobre como tem sido o condicionamento térmico de bolsas de sangue.

1.4 JUSTIFICATIVA

As vacinas e fármacos necessitam que os limites de temperatura sejam respeitados para manter a qualidade e eficácia [4]. Diante de

preços elevados ou dificuldades na aquisição dos mesmos, a conservação do maior número de unidades é essencial, para imunizar ou tratar o maior número de pessoas possível, assim como evitar gastos indesejados e desperdícios.

Pensando nesse desafio, este projeto trará vários benefícios ao ajudar a identificar problemas e falhas nos equipamentos que armazenam as vacinas e medicamentos, para que sejam consertados, mantendo os fármacos na temperatura ideal.

1.5 ESCOPO NEGATIVO

Como limitações, este projeto não trará soluções para a notificação de eventuais problemas em armazenamentos; não serão desenvolvidos novos modelos de equipamentos de armazenamento; não serão desenvolvidos modelos de termômetros; e este projeto não explicará as boas práticas de armazenamento e transporte de vacinas.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 REFRIGERADORES HOSPITALARES

Os medicamentos termolábeis são sensíveis à variação da temperatura, e geralmente requerem armazenamento sob refrigeração (entre 2,0°C e 8,0°C), que deve ser realizado em refrigeradores apropriados [1]. As vacinas são produtos biológicos sensíveis, que podem ser danificados por exposição a temperaturas de congelamento, ao calor e à luz. Uma vez que a eficácia da vacina é perdida, ela não pode ser recuperada [4].

Para manter a qualidade da vacina, é essencial haver o monitoramento da temperatura em toda a cadeia de abastecimento. O monitoramento eficaz e a manutenção de registros alcançam os seguintes objetivos [4]:

1. Verificação de que as temperaturas de armazenamento da vacina estão dentro de intervalos aceitáveis de +2,0°C a +8,0°C em câmaras frigoríficas e geladeiras de vacina; e -25,0°C a -15,0°C em salas de congelamento e freezers de vacina;

2. Detecção de temperaturas de armazenamento fora do intervalo de modo que alguma ação corretiva pode ser tomada;

3. Detecção de temperaturas de transporte fora do intervalo de modo que ação corretiva pode ser tomada.

Para auxiliar nas orientações com relação ao transporte, manuseio e armazenamento de medicamentos sensíveis à temperatura, o Ministério da Saúde emitiu uma resolução, a RDC Nº 304 de 17 de setembro de 2019, que dispõe sobre as boas práticas de distribuição, armazenagem e de transporte de medicamentos [5]. Mas como a RDC Nº 304 era apenas um manual de boas práticas, e não obrigatório, em 8 de outubro de 2020, a RDC Nº 430 foi lançada, e dentre outras alterações com relação à anterior, surge a obrigatoriedade de monitoramento de temperatura, sendo isento apenas em casos de transporte de até 8 horas de duração [6].

O refrigerador hospitalar deve ser utilizado exclusivamente para o armazenamento de medicamentos, não sendo permitida a manutenção de qualquer outro produto, inclusive na porta [2]. A colocação do material na porta o expõe a uma maior variação de temperatura, enquanto a presença de alimentos permite contaminações e colabora para que o refrigerador seja aberto com maior frequência, dificultando a constância da temperatura apropriada.

Atualmente, muitos modelos de termômetros utilizados são fabricados fora do país, então é necessário verificar se existe uma chave de alternância de leitura entre Fahrenheit e Celsius, para posicioná-la em graus Celsius. O termômetro deve ser fixado no lado externo da porta do refrigerador, sendo introduzido o cabo extensor pelo lado de fixação das dobradiças, localizando o sensor (ou bulbo) na parte central da segunda prateleira. O bulbo não deve ser colocado dentro de líquidos ou recipientes, visto que a recomendação de manter a faixa de temperatura de armazenamento entre 2,0°C e 8,0°C é baseada no ar circulante [1, 4].

Para determinar se as características farmacológicas de um determinado medicamento foram mantidas, é necessário analisar um parâmetro conhecido como estabilidade. Para determinar este parâmetro, é necessário avaliar 5 propriedades do produto: química, física, microbiológica, terapêutica e toxicidade.

Diversos fatores (intrínsecos ou extrínsecos) podem causar alterações nestas propriedades. Entre os extrínsecos, está o controle de temperatura inadequado que pode levar a perda

total ou parcial das propriedades do medicamento. Portanto, manter a refrigeração adequada dos mesmos é de fundamental importância para ter-se uma preservação de qualidade, evitando quaisquer danos à sua saúde [7].

2.2 DETECÇÃO DE ANOMALIAS

Em conjuntos de dados, existem pontos de dados normais e podem existir pontos de dados que se destacam como sendo diferentes de todos os outros pontos de dados. Esses pontos de dados que diferem significativamente de outros pontos de dados são chamados de *outliers* ou anomalias [8].

É de extrema importância identificá-los e entender porque esses pontos de dados podem estar associados a situações fraudulentas. A detecção de anomalias é o processo responsável por identificar pontos de dados incomuns, descobrir padrões anteriormente desconhecidos e fornecer informações importantes para a empresa [9].

Existem diferentes métodos para detectar anomalias: supervisionados, semi supervisionados e não supervisionados.

Quando os conjuntos de dados têm um rótulo (por exemplo, normal e outlier), métodos supervisionados são aplicados. Quando os conjuntos de dados não possuem um rótulo, então, nesse caso, métodos não supervisionados devem ser aplicados [8].

2.3 TRABALHOS RELACIONADOS

- **Network Anomalies Detection Using Statistical Technique [10]**: A Chi-Square approach: este artigo tem como objetivo construir um Sistema de Detecção de Anomalias que pode detectar anomalias conhecidas e desconhecidas automaticamente. Este estudo mostra o plano, a implementação e a análise destas ameaças através da utilização de uma técnica estatística, de forma a prevenir estes ataques e construir um sistema de detecção de anomalias na Rede.
- **Unsupervised Anomaly Detection of Retail Stores Using Predictive Analysis Library on SAP HANA XS Advanced [11]**: Esse artigo discute sobre como algoritmos de mineração de

dados podem ser úteis para detectar anomalias, diferenciando o normal do anormal. Este estudo adotou o algoritmo de agrupamento k-Means para detecção de anomalias em uma amostra de 90 lojas em uma grande rede varejista de alimentos, revelando a existência de alguns outliers nos dados.

- **A Real-time Temperature Anomaly Detection Method for IoT Data [12]:** Um método de detecção de anomalias de temperatura baseado no limiar dinâmico adaptativo e no algoritmo Smoothed Z-Score é proposto, para detectar anomalias em dados de séries temporais de refrigeradores IoT, para melhorar a qualidade e a eficiência do gerenciamento de temperatura de armazenamento de medicamentos. Este método leva em consideração a estacionariedade e a periodicidade da série temporal de temperatura e, assim, desenvolve uma abordagem de detecção mais precisa.

3 MATERIAIS E MÉTODOS

3.1 STAKEHOLDERS ENVOLVIDOS

Para esse projeto, serão necessários dois grupos de *Stakeholders*:

- Usuários principais: responsáveis pelo monitoramento e uso dos refrigeradores hospitalares (como por exemplo, farmacêuticos e gerentes de operação);
- Usuários intermediários: responsáveis pelo acompanhamento do monitoramento.

3.2 DESCRIÇÃO DA BASE DE DADOS

A base de dados utilizada neste projeto foi cedida pela empresa SENFIO, que trabalha com termômetros IoT para monitoramento de temperatura de refrigeradores hospitalares em clínicas, laboratórios, hemocentros, etc. Esta base contém medições de temperatura num espaço de tempo, separadamente para cada refrigerador monitorado.

São armazenadas na base de dados as informações de temperatura, data e hora de registro da medição. Cada planilha contém a informação de um intervalo de tempo determinado,

de acordo com o modelo do termômetro utilizado. Podendo ter registros de temperatura a cada 5 minutos ou 30 minutos.

Além das medições habituais, a base de dados também armazena informações dos alertas gerados quando há uma variação expressiva de temperatura em um refrigerador, além dos limites pré-estabelecidos. Nessa situação, são salvas as informações da data e hora da ocorrência, além da temperatura marcada.

Os dados são armazenados em duas tabelas diferentes: a primeira é um relatório detalhado enviado a cada período de tempo definido pelo cliente, enquanto que a segunda é um relatório específico para alertas, onde são apresentados os dados dos alertas citados anteriormente e o tipo de alerta que foi enviado naquele instante (e-mail ou SMS).

Para as análises desenvolvidas neste artigo, foi necessário realizar um pré-processamento dos dados originais, convertendo as duas tabelas recebidas em apenas uma tabela adequadamente formatada. Nenhum dado foi alterado ou gerado aleatoriamente, foi feita apenas uma conversão das informações originais.

Com o pré-processamento (que será descrito com maiores detalhes na seção 3.4), os dados compreendem as medições de um refrigerador específico, durante o período de 12/01/2021 até 31/05/2021. A Quadro 1 mostra o dicionário de dados pré-processados.

Quadro 1- Dicionário de dados

ATRIBUTO	DOMÍNIO	DESCRIÇÃO
monitored_object	Texto	identificador do equipamento
day	Numérico	int
month	Texto	string
year	Numérico	int
weekday	Texto	string
hour	Numérico	int
minute	Numérico	int
value	Numérico	Temperatura (°C)
is_alert	Numérico	1 = true, 0 = false

Fonte: Os autores.

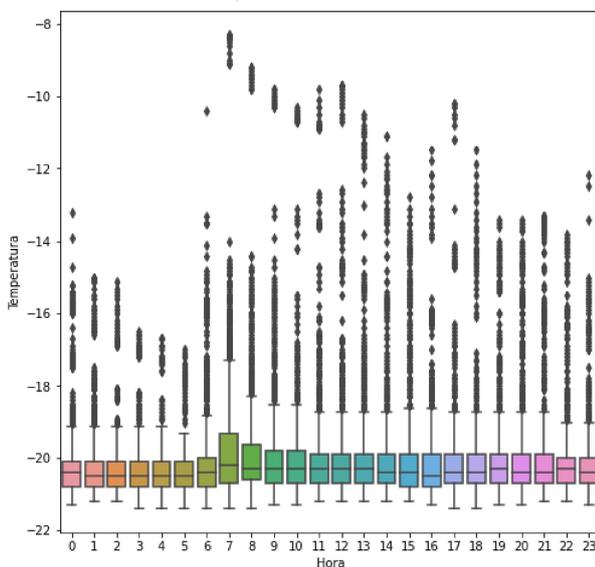
3.3 ANÁLISE DESCRITIVA DOS DADOS

A base de dados utilizada possui medições feitas num intervalo de cinco minutos, durante cerca de cinco meses. Total são mais de 38.000 medições, cada uma com respectiva data, hora, temperatura medida e se foi gerado um alerta no momento.

A partir da base de dados, foi escolhido o atributo nominal *hour* e o numérico *value* para analisar as medições de temperatura registradas. Com a primeira visão geral sobre toda a base, é possível notar que as temperaturas variam muito, mas grande parte está contida entre $-21,0^{\circ}$ e $-19,0^{\circ}$, então as casas decimais dos valores precisam ser mantidas sem alterações, a fim de não haver perda significativa dos dados.

A Figura 1 mostra um gráfico BoxPlot que relaciona as horas com as medições de temperatura. É possível observar os vários *outliers* presentes principalmente em temperaturas acima de $-19,0^{\circ}\text{C}$. Além disso, é válido ressaltar a estreita faixa entre os primeiros e terceiros quartis, indicando que a grande parte das medições de temperatura obtiveram valores próximos à mediana.

Figura 1- BoxPlot



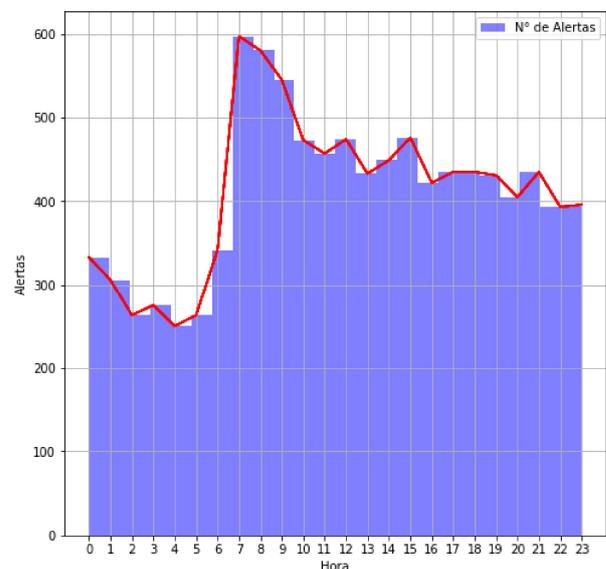
Fonte: Os autores.

A Figura 2 representa um histograma contabilizando todos os alertas registrados em cada hora. A base de dados registra temperaturas uma vez a cada cinco minutos, então em cada hora

é possível haver até 12 registros de alertas. É possível notar que de madrugada é registrado bem menos alertas, mas o número sobe rapidamente a partir das 6 horas da manhã.

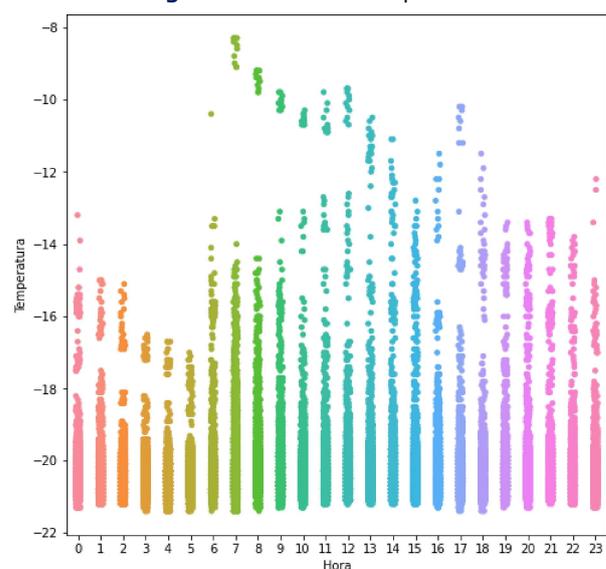
Na Figura 3 pode ser observado o gráfico de dispersão, onde é notável que grande parte das medições possui valores próximos a $-20,0^{\circ}\text{C}$. Além disso, a quantidade de *outliers* é grande, mas fazendo a contagem na base de dados, a grande maioria deles estão em temperaturas inferiores a $-19,0^{\circ}$.

Figura 2- Histograma



Fonte: Os autores.

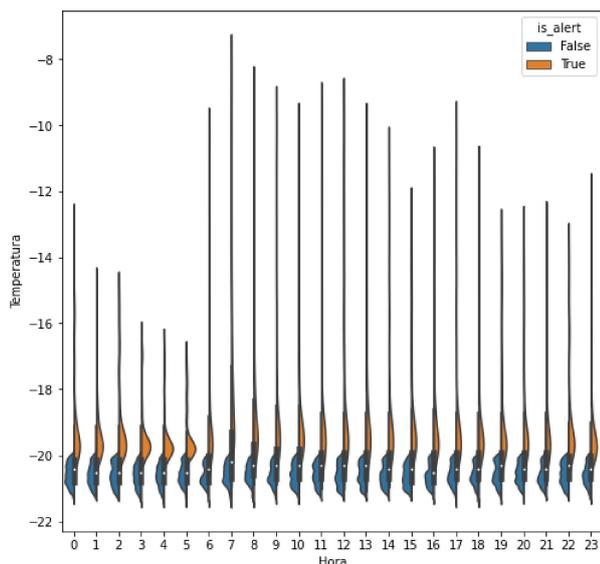
Figura 3- Gráfico de Dispersão



Fonte: Os autores.

A Figura 4 apresenta o gráfico de violino, que mostra basicamente as mesmas informações que o BoxPlot, mas faz a divisão entre as medições comuns, e as que geraram um alerta de temperatura. Com isso, é possível notar que grande parte dos alertas foram de temperaturas próximas do limite, por volta de $-20,0^{\circ}\text{C}$.

Figura 4- Gráfico de Violino



Fonte: Os autores.

Após uma análise dos dados através dos gráficos apresentados a seguir, a primeira conclusão a se observar é que à noite as temperaturas são mais baixas em relação ao resto do dia. Além disso, caso seja desejado mais atenção para conter o número de alertas, a melhor opção é observar as primeiras horas da manhã (entre 6h e 9h).

3.4 PRÉ-PROCESSAMENTO DOS DADOS

Para permitir o melhor uso dos dados, foi desenvolvido um algoritmo com a finalidade de extrair os dados das duas bases recebidas originalmente, e organizá-los de forma que facilitasse o uso.

As entradas do algoritmo foram duas planilhas, onde uma dispõe dos dados referentes aos alertas e a outra os dados referentes a relatórios onde os equipamentos estavam funcionando perfeitamente, porém ambas não seguiam um padrão. A saída foi uma nova planilha onde todos os dados estavam

juntos e padronizados. Os passos realizados no pré-processamento foram os seguintes:

1. Conversão das duas bases do formato original (.xls) para um formato de arquivo que fosse mais fácil de analisar e trabalhar nas ferramentas utilizadas (.csv);
2. **Integração dos dados**, retirando dados redundantes que são resultado da conversão do formato de arquivos;
3. Mesclagem das duas tabelas, formando uma nova base de dados, com a adição de um atributo *is_alert*, que indica quando a linha (que é uma medição de temperatura num dado momento) gerou um alerta.
4. **Limpeza dos dados**, excluindo linhas com atributos ausentes, duplicados ou inconsistentes;
5. Como as duas bases originais não possuem as mesmas datas de início e fim, foi necessário remover dados de uma das tabelas. Caso esta etapa não fosse feita, a base teria vários dias sem alertas, o que não foi o caso na realidade;
6. **Transformação dos dados**, utilizando a data de cada linha para gerar quatro novos atributos: *day*, *month*, *year* e *weekday*. Além disso, o horário foi utilizado para gerar dois atributos: *hour* e *minute*.
7. Exportação da nova base, no formato .csv.

Com os passos acima realizados, o resultado foi uma base de dados única e formatada corretamente, com medições realizadas entre 12 de janeiro de 2021 até 31 de maio de 2021. Além disso, a data e hora são separados por atributos para uma melhor visualização das tendências, e o atributo *is_alert* elimina a necessidade de utilizar uma segunda base de dados para a constatação de quais medições geraram um alerta.

3.5 METODOLOGIA EXPERIMENTAL

Nos experimentos realizados foram implementados diferentes técnicas de detecção de anomalias, utilizando três métodos de agrupamento: *k-means*, DBSCAN e *Isolation Forest*. Para cada teste, foi realizada uma etapa de pré-processamento adicional para extrair os atributos que seriam utilizados em cada algoritmo. Para isso, foi utilizado o *LabelEncoder* da biblioteca *sklearn* do *Python* para converter valores categóricos em numéricos. Por último foi feita a normalização dos dados.

Para testar os algoritmos de detecção de anomalias, 30% da base foi utilizada para testes, e para apresentar os resultados, foram utilizadas as funções: *accuracy_score*, *confusion_matrix* e *classification_report* da biblioteca *sklearn* do *Python*. Com isso, foi possível analisar e comparar o desempenho de cada técnica.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Os resultados dos testes estão apresentados na Tabela 2. A detecção de anomalias utilizando o DBSCAN obteve o melhor desempenho (76,7% de acurácia), porém a diferença na performance não é grande, o que pode indicar que uma análise mais detalhada dos parâmetros dos testes pode influenciar na busca por melhores soluções.

Tabela 2 - Comparação entre técnicas

Método	Acurácia
K-means	74,6%
DBSCAN	76,7%
Isolation Forest	68,0%

Fonte: Os autores.

Levando em consideração a acurácia encontrada, o método utilizado para o agrupamento do algoritmo de detecção de anomalias foi o DBSCAN.

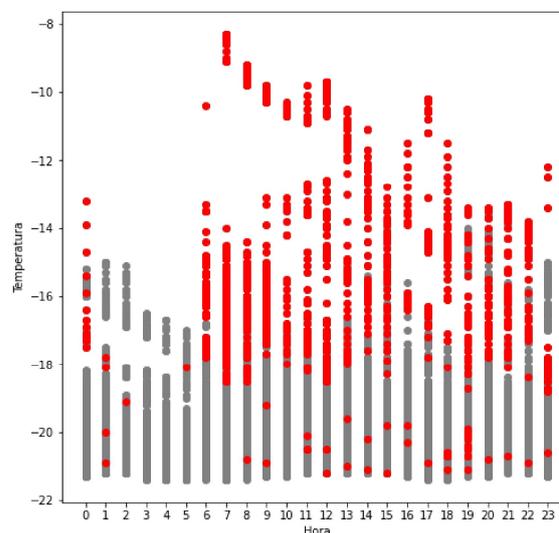
O algoritmo encontrou um total de 946 anomalias na base que possui cerca de 38 mil medições de temperatura. Com diferentes parâmetros é possível aumentar o número de anomalias, para reconhecer mais medições que geraram alertas, mas como a própria base de dados possui essa informação facilmente acessível, foi decidido que as anomalias seriam medições com temperaturas mais críticas (como grandes variações).

A Figura 5 faz uma comparação entre as medições existentes na base de dados, com as anomalias que foram detectadas. É possível perceber que o algoritmo detectou principalmente medições com temperaturas mais altas que o comum, indicando que é útil para encontrar a maioria das anomalias na base de dados.

O algoritmo de detecção de anomalias gera uma base de dados somente com as medições que foram reconhecidas como anomalias. Com isso, é possível realizar várias análises em busca de

informações úteis sobre medições que geraram alertas de temperatura, como mostra a Figura 6.

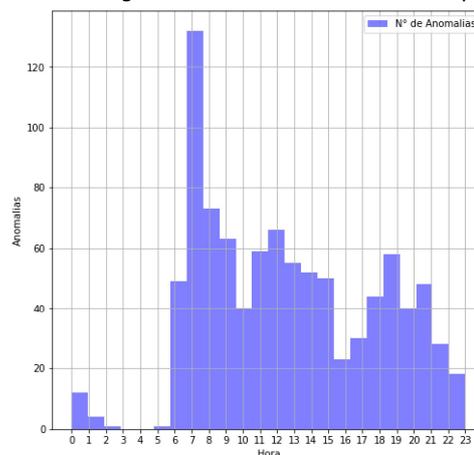
Figura 5 - Comparação entre a base de dados e as anomalias detectadas



Fonte: Os autores.

A Figura 6 mostra o número de anomalias encontradas, divididas por hora. A primeira conclusão que se pode obter é que às 7h da manhã, existe algum evento que altera bruscamente a temperatura do refrigerador. Como nas horas subsequentes o número de alertas diminui expressivamente, este evento não deve ser duradouro. Também é possível notar que os horários de madrugada possuem um número de anomalias relativamente baixo.

Figura 6 - Histograma do número de anomalias por hora



Fonte: Os autores.

Durante o dia, de acordo com a Figura 6, o número de anomalias possui picos perto das 12h e

19h. Levando essas análises em consideração, é possível concluir que a presença de pessoas no local pode influenciar no número de alertas (e consequentemente, anomalias) na base de dados, pois 7h e 19h são horários comuns para o início e fim do expediente de trabalho, além de que 12h é o início do horário de almoço de boa parte das pessoas.

5 CONCLUSÕES E TRABALHOS FUTUROS

Quando se trata da preservação de vacinas e fármacos, é necessário a atenção à temperatura do refrigerador para que o produto seja bem preservado e não sofra alterações em sua composição que possam danificá-lo. Pensando nisso, a detecção de anomalias com o algoritmo DBSCAN analisar situações onde a temperatura do refrigerador está acima do adequado, para que os resultados da análise possam ser utilizados no futuro como base para trabalhos de previsão de alertas, por exemplo.

Com a análise realizada, foi possível perceber diversas relações entre os valores de temperatura, quantidade de alertas e os horários que eles aconteceram. Observou-se que a maior parte das anomalias encontradas aconteceram entre às 6:00 e às 8:00 horas da manhã, coincidindo com o horário de troca de turnos entre funcionários.

Os resultados encontrados neste trabalho abrem portas para previsões de alertas, onde é possível prever em uma semana, por exemplo, um número de alertas. Com isso pode haver uma otimização do tempo para prevenir ou minimizar os danos causados.

Além disso, trabalhar com uma base de dados com dados de anos diferentes, seria interessante para analisar o comportamento do algoritmo ao receber essas informações, pois podem existir diversas relações que não foram possíveis de extrair com a base de dados atual. Além de ajudar em uma previsão melhor, pode ser possível identificar sazonalidades que podem trazer resultados ainda melhores.

REFERÊNCIAS

- [1] RAPKIEWICZ, Jackson C.; GROBE, Rafaela. **Cuidados no Armazenamento de Medicamentos sob Refrigeração**. Disponível em: https://www.crf-pr.org.br/uploads/revista/24141/cim_crf_pr_2_2014_web.pdf. Acesso em: 7 jul. 2021.
- [2] BBC News Brasil. **SUS joga fora R\$ 16 milhões em medicamentos de alto custo**. Disponível em: <https://www.bbc.com/portuguese/brasil-41007650>. Acesso em: 30 ago. 2021.
- [3] G1 Distrito Federal. **Vacina contra Covid-19: DF recebe 40,1 mil doses da Janssen congeladas e 'indisponíveis para uso', diz Secretaria de Saúde**. Disponível em: <https://g1.globo.com/df/distrito-federal/noticia/2021/07/03/covid-19-df-recebe-401-mil-doses-da-janssen-congeladas-e-indisponiveis-para-uso.ghtml>. Acesso em: 30 ago. 2021.
- [4] World Health Organization. **HOW TO MONITOR TEMPERATURES IN THE VACCINE SUPPLY CHAIN**. Disponível em: https://apps.who.int/iris/bitstream/handle/10665/183583/WHO_IVB_15.04_eng.pdf. Acesso em: 26 ago. 2021.
- [5] Ministério da Saúde. **RDC Nº 304, DE 17 DE SETEMBRO DE 2019 - Dispõe sobre as Boas Práticas de Distribuição, Armazenagem e de Transporte de Medicamentos**. Disponível em: <https://www.in.gov.br/en/web/dou/-/resolucao-rdc-n-304-de-17-de-setembro-de-2019-216803526>. Acesso em: 26 ago. 2021.
- [6] Ministério da Saúde. **RDC Nº 430, DE 8 DE OUTUBRO DE 2020 - Dispõe sobre as Boas Práticas de Distribuição, Armazenagem e de Transporte de Medicamentos**. Disponível em: <https://www.in.gov.br/en/web/dou/-/resolucao-de-diretoria-colegiada-rdc-n-430-de-8-de-outubro-de-2020-282070593>. Acesso em: 15 Set. 2021.
- [7] FRIGOCENTER. **A Importância da Refrigeração para a Indústria Farmacêutica**. Disponível em: <https://frigocenter.com.br/blog/2019/01/29/importancia-da-refrigeracao-para-industria-farmaceutica>. Acesso em: 7 jul. 2021.

- [8] Chen J., Sathe S., Aggarwal C., Turaga D. **Outlier Detection with Autoencoder Ensembles.** Disponível em: <https://doi.org/10.1137/1.9781611974973.1>. Acesso em: 26 ago. 2021.
- [9] Fan C, Xiao F, Zhao Y, Wang J. **Analytical investigation of autoencoder-based methods for unsupervised anomaly detection in building energy data.** Disponível em: <https://doi.org/10.1016/j.apenergy.2017.12.005>. Acesso em: 26 ago. 2021.
- [10] Rastogi, Rahul; Khan, Zubair; Khan, M H. **Network Anomalies Detection Using Statistical Technique : A Chi- Square approach.** Disponível em: <https://www.proquest.com/docview/1035138243>. Acesso em: 7 jul. 2021.
- [11] OLIVEIRA, João Pedro; SOUSA, Rui Dinis. **Unsupervised Anomaly Detection of Retail Stores Using Predictive Analysis Library on SAP HANA XS Advanced.** Disponível em: <https://www.sciencedirect.com/science/article/pii/S1877050921002866>. Acesso em: 7 jul. 2021.
- [12] Liu, W., Jiang, H., Che, D., Chen, L. e Jiang, Q. **A Real-time Temperature Anomaly Detection Method for IoT Data.** Disponível em: <https://www.scitepress.org/Papers/2020/94100/94100.pdf>. Acesso em: 26 ago. 2021.