



Universidade Federal do Rio de Janeiro

Escola Politécnica

MBA em Big Data, Business Intelligence e Business Analytics
(MB3B)

**AUTOMATIZAÇÃO DO PROCESSO DE BLOQUEIO DE ENTREGAS
EM COMPRAS ONLINE FRAUDULENTAS**

Autor:

Guilherme Defanti Peres

Orientador:

Manoel Villas Boas Junior, M. Sc.

Examinador:

Flávio Luis Mello, D. Sc.

Examinador:

José Airton Chaves Cavalcante Junior, D. Sc.

Examinador:

Vinicius Drumond Gonzaga, M. Sc.

**Rio de Janeiro
Dezembro de 2021**

Declaração de Autoria e de Direitos

Eu, **Guilherme Defanti Peres**, inscrito no CPF/ME sob o nº 144.365.047-19, autor da monografia ***AUTOMATIZAÇÃO DO PROCESSO DE BLOQUEIO DE ENTREGAS EM COMPRAS ONLINE FRAUDULENTAS***, subscrevo para os devidos fins, as seguintes informações:

1. O autor declara que o trabalho apresentado na defesa da monografia do curso de Pós-Graduação, Especialização MBA em Big Data, Business Intelligence e Business Analytics da Escola Politécnica da UFRJ é de sua autoria, sendo original em forma e conteúdo.
2. Excetuam-se do item 1 eventuais transcrições de texto, figuras, tabelas, conceitos e ideias, que identifiquem claramente a fonte original, explicitando as autorizações obtidas dos respectivos proprietários, quando necessárias.
3. O autor permite que a UFRJ, por um prazo indeterminado, efetue em qualquer mídia de divulgação, a publicação do trabalho acadêmico em sua totalidade, ou em parte. Essa autorização não envolve ônus de qualquer natureza à UFRJ, ou aos seus representantes.
4. O autor declara, ainda, ter a capacidade jurídica para a prática do presente ato, assim como ter conhecimento do teor da presente Declaração, estando ciente das sanções e punições legais, no que tange a cópia parcial, ou total, de obra intelectual, o que se configura como violação do direito autoral previsto no Código Penal Brasileiro no art.184 e art.299, bem como na Lei 9.610.
5. O autor é o único responsável pelo conteúdo apresentado nos trabalhos acadêmicos publicados, não cabendo à UFRJ, aos seus representantes, ou ao(s) orientador(es), qualquer responsabilização/ indenização nesse sentido.
6. Por ser verdade, firmo a presente declaração.

Rio de Janeiro, 04 de dezembro de 2021.

Guilherme Defanti Peres

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO

Av. Athos da Silveira, 149 - Centro de Tecnologia, Bloco H, sala - 212,
Cidade Universitária Rio de Janeiro – RJ - CEP 21949-900.

Este exemplar é de propriedade Escola Politécnica da Universidade Federal do Rio de Janeiro, que poderá incluí-lo em base de dados, armazenar em computador, microfilmear ou adotar qualquer forma de arquivamento.

Permitida a menção, reprodução parcial ou integral e a transmissão entre bibliotecas deste trabalho, sem modificação de seu texto, em qualquer meio que esteja ou venha a ser fixado, para pesquisa acadêmica, comentários e citações, desde que sem finalidade comercial e que seja feita a referência bibliográfica completa.

Os conceitos expressos neste trabalho são de responsabilidade do autor.

DEDICATÓRIA

Dedico este trabalho aos meus pais, Sonia e Niraldo, pois seus esforços e trabalho duro me incentivaram a ir além, possibilitando a conclusão deste curso.

AGRADECIMENTO

Primeiramente, sou grato a Deus por ter me concedido força e perseverança para superar todas as dificuldades, me colocando diante de situações que me acrescentaram como pessoa.

Ao professor Manoel Villas Boas, obrigado pela orientação, apoio e confiança.

Aos meus pais e irmãos, que sempre acreditaram em mim e me incentivaram quando para mim parecia difícil. São as pessoas pelas quais me levanto todo dia para vencer os desafios e deixá-los orgulhosos.

À minha namorada Amanda, que foi a pessoa que mais me incentivou para que eu realizasse esse curso e compreendeu minha ausência enquanto eu me dedicava à realização deste trabalho. Agradeço também pelas horas dedicadas a revisão do texto desse trabalho.

Aos meus amigos Vinicius Araujo, Ieso Banov e Paulo Guerreiro que sempre estiveram ao meu lado quando precisei e compartilharam comigo da mesma jornada no mundo da tecnologia.

RESUMO

O comércio *online* está cada vez mais presente no cotidiano, tendo sido intensificado em razão da quarentena imposta pela pandemia de covid-19 que ocorre desde 2019, pois as pessoas se viram obrigadas a permanecer em casa, ocasionando o crescimento das vendas *online* em um curto espaço de tempo. Nesse cenário, nem mesmo as empresas mais consolidadas estavam preparadas, seja em relação ao estoque, logística ou a segurança da informação. Conseqüentemente, as fraudes virtuais também aumentaram, inclusive aquelas onde a pessoa que realiza a compra não é, de fato, a titular do cartão de crédito utilizado para o pagamento. Em muitos casos, a vítima (titular do cartão), ao perceber que seus dados foram indevidamente utilizados por terceiro, solicita o cancelamento da compra junto à operadora do cartão, que encaminha o pedido ao *e-commerce* (processo denominado *chargeback*). Paralelamente, os prazos de frete estão cada vez mais curtos, dificultando o bloqueio da entrega em tempo hábil. Logo, há o risco de a vítima receber o estorno e ainda assim o fraudador receber o produto, ocasionando um duplo prejuízo ao vendedor. Diante disso, o intuito do presente trabalho é apresentar uma solução para melhorar a efetividade dos bloqueios de entrega mediante o uso da tecnologia de automação via *robotic process automation* (RPA) na empresa objeto deste estudo. Também se utilizou das tecnologias de banco de dados, *data lake* e *dashboards* de forma complementar para eliminar o trabalho manual e não tempestivo que a área de negócios realizava. Os resultados alcançados apontaram que a solução implementada reduziu 72% (setenta e dois por cento) das entregas indevidas ao fraudador, enquanto a expectativa da área de negócios era de 40% (quarenta por cento), demonstrando que a solução foi eficaz para melhorar o processo de bloqueio de entrega e evitar mais perdas ao vendedor.

Palavras-Chave:

E-commerce, Fraudes, *Chargeback*, Cancelamento de compra, Automação, RPA.

ABSTRACT

Online commerce is increasingly present in everyday life, having been intensified due to the quarantine imposed by the covid-19 pandemic that has occurred since 2019, as people were forced to stay at home, causing online sales to grow in a short period of time. In this scenario, not even the most consolidated companies were prepared, whether in relation to inventory, logistics or information security. Consequently, virtual fraud has also increased, including those which the purchaser is not, in fact, the holder of the credit card used for payment. In many cases, the victim (cardholder), when realizing that his data was improperly used by a third party, requests the purchase cancellation to the credit card company, which forwards the request to the e-commerce (process called chargeback). At the same time, delivery times are getting shorter and shorter, making it difficult to block delivery in a timely manner. Therefore, there is a risk that the victim will receive the reversal money and yet the fraudster receives the product, causing a double loss to the seller. Therefore, the aim of this work is to present a solution to improve the effectiveness of delivery blocks through the use of automation technology via robotic process automation (RPA) in the company object of this study. It also used database, data lake and dashboards technologies in a complementary way to eliminate the manual and non-timely work that the business area performed. The results showed that the implemented solution reduced 72% (seventy-two percent) of improper deliveries to the fraudster, while the expectation of the business area was 40% (forty percent), demonstrating that the solution was effective to improve the delivery blocking process and avoid further losses to the seller.

Key words:

E-commerce, Fraud, Chargeback, Purchase cancellation, Automation, RPA.

SIGLAS

ANSI	<i>American National Standards Institute</i>
API	<i>Application Programming Interface</i>
BI	<i>Business Intelligence</i>
CODASYL	<i>Conference on Data System Language</i>
ID	Identidade
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos
IMS	<i>Information Management System</i>
ISO	<i>International Organization for Standardization</i>
RPA	<i>Robotic process automation</i>
SFTP	<i>Secure File Transfer Protocol</i>
SLA	<i>Service Level Agreement</i>
SQL	<i>Structured Query Language</i>
UFRJ	Universidade Federal do Rio de Janeiro

LISTA DE FIGURAS

Figura 2.1	Quadrante mágico de Gartner.	12
Figura 2.2	Tela do UiPath Assistant	14
Figura 2.3	Tela de destaque UiPath Assistant.	15
Figura 2.4	Tela de monitoramento do Grafana.	23
Figura 3.1	Fluxograma do processo realizado manualmente.	27
Figura 3.2	Tela inicial do sistema <i>RightNow</i> .	29
Figura 3.3	Tela do local que o upload do arquivo é realizado no sistema <i>RightNow</i> .	29
Figura 3.4	Fluxograma da primeira etapa da automação.	31
Figura 3.5	Fluxograma da segunda etapa da automação.	32
Figura 3.6	Fluxograma da terceira etapa da automação.	34
Figura 3.7	Fluxograma completo da automação.	35
Figura 3.8	Indicadores do Grafana referentes ao monitoramento da automação.	35
Figura 3.9	Indicadores do Grafana referentes aos alertas de infraestrutura.	36

Figura 4.1	Tela de assertividade considerando pedidos que já chegam com o status de entregue.	37
Figura 4.2	Tela de assertividade considerando pedidos que não chegam com o status de entregue.	38
Figura 4.3	Tela de pedidos P1 e P3.	39
Figura 4.4	Tela de pedidos por canal.	39
Figura 4.5	Tela de exportação de planilha.	40
Figura I.1	Aba Home do UiPath Studio.	48
Figura I.2	Aba <i>Design</i> do UiPath Studio.	49
Figura I.3	Aba <i>Debug</i> do UiPath Studio.	52

LISTA DE QUADROS

Quadro 2.1	Bases que podem se conectar ao Power BI	19
Quadro 3.1	Descrição dos status do banco de dados PostgreSQL	32
Quadro 3.2	Colunas que podem ser alteradas na segunda etapa da automação	32
Quadro 3.3	Descrição dos status finais	33
Quadro I.1	Descrição das funcionalidades da aba Design do UiPath Studio	50
Quadro I.2	Descrição das funcionalidades da aba Debug do UiPath Studio	52

Sumário

Capítulo 1: Introdução	1
1.1 – Tema	2
1.2 – Justificativa	2
1.3 – Objetivos.....	3
1.4 – Delimitação.....	4
1.5 – Metodologia.....	5
1.6 – Descrição	6
Capítulo 2: Embasamento Teórico	8
2.1 – Histórico da evolução da automação de processos.....	8
2.2 – Evolução da ferramenta de RPA	10
2.3 – Solução completa da ferramenta de automação UiPath	13
2.3.1 – UiPath Assistant	13
2.3.2 – UiPath Orchestrator	15
2.4 – Ferramentas utilizadas na automatização do processo de bloqueio de entregas	16
2.4.1 – UiPath Studio	16
2.4.2 – Banco de dados	17
2.4.3 – Microsoft Power BI	18
2.4.4 – Grafana	22
2.4.5 – Azure Data Lake	24
Capítulo 3: Propostas Tecnológicas	26
Capítulo 4: Resultados Obtidos ou Esperados	37
Capítulo 5: Conclusão e Trabalhos Futuros	41
5.1 – Conclusão	41
5.2 – Trabalhos Futuros	41
Referências Bibliográficas	43
Anexo I	48

Capítulo 1

Introdução

O presente trabalho trata de fraudes que ocorrem no setor do varejo *online*. Mais precisamente em como reduzir, de maneira reativa, a perdas dos produtos quando fraudes acontecem.

Estas fraudes ocorrem quando uma compra é realizada em um site, porém o comprador não é o titular do cartão e nem mesmo tem permissão deste para realizar a compra em seu nome. Dado este fato, ao perceber que uma compra foi realizada em seu cartão de maneira indevida, o titular do cartão liga para a operadora do mesmo para informar que um terceiro utilizou do seu cartão indevidamente e solicitar o seu devido ressarcimento. Porém, em muitos casos, por não haver uma comunicação tempestiva, o produto acaba sendo entregue ao fraudador e a empresa que realizou a venda arca com o prejuízo, visto que o dinheiro terá que ser devolvido à vítima da fraude.

Esse tipo de fraude é chamado de Chargeback e acontece desde que o mercado *online* começou a se popularizar. Porém, no começo deste mercado, o roubo de dados dos cartões de terceiros não era comum, visto que poucas pessoas tinham acesso à *internet* e, principalmente, deixavam os dados de seus cartões de crédito armazenados em quaisquer sites.

A tecnologia aparece como ponto negativo e positivo nesta história. Negativo pelo fato da internet e seus *e-commerces* serem a via pela qual a fraude ocorre. Por outro lado, é através também da tecnologia que é possível encontrar uma solução que pode reduzir drasticamente o prejuízo causado pelas perdas de produtos comprados pelos fraudadores. Esta solução se dá por um conjunto de ferramentas e tecnologias que juntas e sincronizadas atuam com maior tempestividade no bloqueio de entregas indevidas.

Quando se fala das ferramentas utilizadas na solução, pode-se falar da ferramenta de automação de processos e do sistema *RightNow*. Além dela, duas diferentes plataformas de visualização de dados foram utilizadas. Já para as tecnologias, é importante ressaltar a

comunicação via *Application Programming Interface* (API) e *Secure File Transfer Protocol* (SFTP) a fim de receber os alertas das compras fraudulentas com maior tempestividade, o banco de dados relacional para ter um maior controle sobre a operação e armazenamento de *logs* e, por fim, o *data lake* que é onde são realizadas as consultas dos dados dos pedidos.

Com a junção de todos esses recursos citados, foi possível reduzir os prejuízos com este tipo de fraude, na empresa em questão, em, aproximadamente, 80% (oitenta por cento) a mais que a meta inicial estipulada pela área de negócios.

1.1 – Tema

O presente projeto aborda o desenvolvimento de uma automação que tem como objetivo otimizar o procedimento de identificação das compras fraudulentas via internet nas quais houve *chargeback*, e comunicar às transportadoras de maneira tempestiva a fim de impedir a entrega dos produtos aos possíveis fraudadores.

Chargeback, para fins da presente monografia, significa compras realizadas *online* em que o titular do cartão de crédito alega desconhecê-las ou que seus dados foram indevidamente utilizados por terceiros e, por este motivo solicita o estorno do pagamento junto à operadora do cartão. Em seguida, a operadora do cartão comunica a ocorrência à adquirente (entidade responsável pela ligação entre os compradores e o estabelecimento) que, por sua vez, comunica ao vendedor de *e-commerce* para cancelar a compra e realizar o estorno do pagamento à alegada vítima (“Chargeback”).

Este trabalho utiliza de maneira predominante a computação para solução do problema apresentado. Para tanto, foram utilizados recursos de *robotic process automation* (RPA) e *data visualization*.

1.2 – Justificativa

As fraudes sempre foram um grande problema no mercado do varejo, seja ela fisicamente ou *online*. Fisicamente as fraudes podem acontecer na utilização de cartões de terceiros, porém esse método é mais arriscado para o fraudador, visto que a necessidade de estar

presente no ato da compra e, logo, o vendedor pode identificar que o portador do cartão não se trata da mesma pessoa que é a titular do cartão e, além disso, o fraudador necessita saber a senha para concluir a compra. Já via internet, essas situações não acontecem. O fraudador não corre o risco de ser descoberto através da comparação do seu documento com o nome contido no cartão e muito menos necessita da senha do mesmo para realizar a compra.

Nesse sentido, é notável que este tipo de crime cresceu demasiadamente na última década decorrente da popularização da compra pela internet, ao amadurecimento da segurança das transações financeiras *online* e principalmente durante a quarentena ocasionada pela pandemia da covid-19. De acordo com o estudo realizado pela Associação Brasileira de Comércio Eletrônico (ABComm), em parceria com a Neotrust, no ano de 2020 houve um aumento de 68% (sessenta e oito por cento) nas vendas realizadas pela internet quando comparado com o ano de 2019. Na comparação dos quatro primeiros meses dos anos de 2020 e 2021, constatou um aumento de 612% (seiscentos e doze por cento) de fraudes digitais (TransUnion, 2021)

Um dos maiores desafios da atualidade para os bancos e empresas de *e-commerce* consiste na garantia de segurança das transações. Por esse motivo, vem sendo utilizadas as mais inovadoras tecnologias para realizar, preventivamente, a detecção e bloqueio dessas compras fraudulentas.

O caso abordado neste trabalho se trata de uma das maneiras para reduzir, no pós-venda, as perdas em compras realizadas no *e-commerce* de maneira fraudulenta, ou seja, quando o titular do cartão utilizado na compra comunica ao banco que esta não foi realizada por ele e solicita o seu dinheiro de volta.

1.3 – Objetivos

Neste contexto, o objetivo da presente monografia consiste em verificar a viabilidade de automação do processo de coleta de dados relacionados aos pedidos de compra potencialmente indevidos em razão da comunicação de fraude no cartão de crédito pelo aparente comprador junto às adquirentes de cartão de crédito, bem como da automação de inclusão das informações coletadas junto à base de dados dos pedidos realizados via internet e

emissão de notificação para os transportadores realizarem o bloqueio das entregas das compras canceladas pela alegada fraude.

Além disso, foi verificado se as automações propostas serão eficazes para otimizar o processo de Chargeback na empresa de *e-commerce* estudada e, assim, diminuir o prejuízo ocasionado pela demora na coleta de informações de Chargeback e o posterior pedido de cancelamento da entrega dos produtos junto à transportadora, evitando a perda dos produtos para o potencial fraudador.

1.4 – Delimitação

O objeto de estudo da monografia foi realizado com a premissa de ser elaborado pelas áreas de prevenção a fraudes, inteligência operacional e *data visualization* da empresa de *e-commerce* estudada que atua no setor de varejo em larga escala em todo o território brasileiro, a fim de aprimorar os processos de troca de informações entre adquirentes de cartão de crédito, a própria empresa e a transportadora responsável pela entrega dos produtos mediante a utilização de tecnologia de automação, conforme descrito nos Objetivos apresentados anteriormente.

A pesquisa foi realizada no ano 2021, no cenário de pandemia da Covid-19, e considerou fundamentalmente a grande quantidade de solicitações de Chargebacks pelas adquirentes, o que ocasionou prejuízos financeiros à empresa devido a fraquezas no processo de bloqueio de entregas dos pedidos cancelados nesse contexto em razão da demora no processo de troca de informações aqui exposto.

Ao longo do projeto, algumas situações inesperadas foram sendo encontradas, como, por exemplo, adquirentes sem estrutura tecnológica para um envio imediato dos pedidos nos quais ocorreram o Chargeback, além do cadastro mal realizado de algumas transportadoras nos sistemas da empresa, ou seja, para alguns pedidos não era possível identificar a transportadora responsável pela entrega do produto, impossibilitando o pedido de bloqueio do transporte.

Contudo, as duas adquirentes que tinham relação com a empresa de varejo em questão detinham a maior volumetria de casos de Chargeback (em torno de 80% dos casos analisados),

possuíam tecnologia eficiente para informar tais pedidos em no máximo 1 (um) dia após a alegação do titular do cartão acusar que a aquela compra se tratava de uma fraude.

Dessa forma, foi identificada uma oportunidade de melhoria para a reparação dos registros mal realizados no sistema de dados da empresa, o que somente não foi realizado por limitação de tempo e falta de priorização diante dos ganhos possíveis de se obter com os dados que já estavam registrados. Ou seja, mesmo com as questões citadas, ainda sim o projeto era altamente rentável e esses problemas poderiam ser solucionados em um segundo momento, potencializando ainda mais o retorno financeiro.

1.5 – Metodologia

Primeiramente, foi realizada uma pesquisa na base histórica de Chargeback da empresa estudada para levantar a quantidade média em que ela era notificada por mês, bem como, de todas essas notificações, quantas eram pertinentes às adquirentes nas quais tinham a tecnologia de envio de alerta em até 24 horas. Posteriormente, foi levantado se as tecnologias das duas adquirentes em questão eram compatíveis com a da empresa de *e-commerce*, visto que a etapa de comunicação entre a empresa varejista e as adquirentes era fundamental para o restante do projeto. Constatou-se neste estudo que ambas as adquirentes tinham tecnologia compatível com o *e-commerce* e com o RPA, a que tinha maior volume entre as duas poderia repassar as informações via API e a outra via SFTP.

Com o primeiro passo concluído, percebeu-se que, para realizar o bloqueio da entrega do produto, era necessário informar o número do pedido em questão e foi neste momento que se notou que as adquirentes não enviavam os números dos pedidos, uma vez que o número do pedido de uma compra é pertinente apenas a empresa varejista que realizou a venda do produto.

Logo, um estudo foi realizado a fim de validar se com as informações que as adquirentes enviavam via API e SFTP, era possível, de maneira segura, encontrar o número do pedido no qual houve o Chargeback. Para se assegurar disto, através do cruzamento de informações que são enviadas por ambas as adquirentes como valor da compra, data da compra, número do cartão utilizado e a identidade (ID) da compra, foi possível validar que, na enorme maioria dos

casos, os números dos pedidos foram corretamente encontrados e para os pedidos que não foram encontrados, estes passariam por tratamento manual.

A partir desse momento, foi necessário, naquele momento, realizar o levantamento das tecnologias que complementaríamos a solução. Logo, o banco de dados se viu necessário para registrar as transações que seriam processadas pela automação na tentativa de bloqueio da entrega, além de servir como base para criação de um *dashboard* para que a área de negócios tivesse uma visão estratégica da operação.

Com a definição das tecnologias que seriam utilizadas na captura dos alertas de Chargeback, seguido do grande volume de acerto na realização do cruzamento das informações entre os dados dos Chargebacks e os dados do *data lake* para obter o número do pedido e o ID da loja e, por fim, com as tecnologias complementares acima referidas, o projeto de aumento da eficácia do bloqueio de entrega se tornou viável. Isso porque o último passo já estava desenvolvido sistemicamente, tratando-se da comunicação com as transportadoras, via sistema *RightNow*, para que fosse realizado o bloqueio da entrega.

1.6 – Descrição

O capítulo 2 é baseado em apresentar o embasamento teórico de cada ferramenta utilizada na solução do processo. Logo, este capítulo abrange sobre as funcionalidades e potenciais de cada ferramenta e tecnologia utilizada.

O capítulo 3 abrange a situação antes e depois da implementação da solução dando a contextualização da empresa nesses dois momentos. Também apresenta o papel de cada ferramentas e tecnologias que foi utilizada na solução do problema de bloqueio de entregas apresentado no presente trabalho.

No capítulo 4 são apresentados os resultados obtidos na automatização do bloqueio de entregas através dos *dashboards* criados. Neste capítulo também é mostrado uma tratativa realizada no *dashboard* a fim de evidenciar o real resultado da automação, ou seja, considerando apenas os casos nos quais eram possíveis a realização do bloqueio da entrega.

Por fim, no capítulo 5, é apresentada a conclusão do trabalho evidenciando que a solução foi concluída com êxito e até mesmo superando as expectativas da área de negócio em relação a automação do processo apresentado. Ainda no capítulo 5, são apresentadas duas propostas de trabalhos futuros para otimizar ainda mais a assertividade da automação, potencializando o retorno financeiro do processo.

Capítulo 2

Embasamento Teórico

2.1 Histórico da evolução da automação de processos

Há mais de um século, mais precisamente desde a primeira revolução industrial que ocorreu entre os anos de 1760 e 1860, de acordo com o historiador Eric J. Hosbsbawm (2003), as empresas vêm passando por grandes transformações em seus processos e rotinas, e isso se deve muito ao avanço da tecnologia.

Com o avanço desta, tarefas que antes eram realizadas por muitos trabalhadores, foram substituídas por máquinas nas quais executavam as mesmas atividades, com maior produtividade, em menor tempo, com menor risco de acidentes e, por consequência, gerando maior retorno financeiro para o proprietário.

Ainda de acordo com Hosbsbawm (2003), com a percepção de que com o avanço da tecnologia potencializava os retornos financeiros, os investimentos na automatização de tarefas e em tecnologia aumentaram notoriamente. Além da primeira, houve outras duas revoluções industriais, a segunda na metade do século XIX até meados do século XX, onde a quantidade de maquinários e inovações aumentou, o que garantiu maior produtividade e lucro para as indústrias.

Já a terceira revolução industrial iniciou-se por volta dos anos de 1950. Esta revolução ficou marcada pela criação de computadores, robôs, celulares, chips, circuitos eletrônicos, softwares. Portanto, as tecnologias mecânicas e analógicas foram superadas pela digital. Isto significou que as mudanças trazidas pela computação e sua expansão marcaram o início da era da informação (CHATFIELD, 2013). Empresas e indústrias ratificaram o seu pensamento de que o trabalhador era um complemento das novas tecnologias que não era mais aceitável voltar atrás.

A terceira revolução ficou notada por modificar a maneira na qual as pessoas se comunicavam. Com a criação da *internet*, o paradigma de se comunicar a distância foi quebrado, as relações internacionais foram facilitadas e isso potencializou ainda mais o capitalismo. Com tais avanços, a robótica começava a ser implementada nas empresas e, com isso, a substituição de algumas atividades, o que fez com que a mão de obra humana fosse, de certa forma, desvalorizada em algumas situações. (SILVA; SILVA; GOMES, 2002).

Mesmo com todo esse avanço da tecnologia, grandes e longínquas empresas e indústrias que não se reinventaram e não melhoraram seus processos foram definhando e dando lugar a outras com uma mentalidade mais adepta à mudanças e inovações. Junto às empresas que não acompanharam tais avanços, cargos e funções manuais foram deixando de existir uma vez que tinham sido totalmente automatizadas. Porém, por outro lado dezenas de novos empregos surgiam, visto que se fazia necessário para suprir a grande demanda tecnológica.

Logo, surgiu o que é chamada de quarta revolução industrial, também conhecida como a revolução dos robôs, ou ainda como indústria 4.0. A característica dessa etapa da revolução industrial tem como foco a automatização de fábricas, indústrias e empresas de forma a trazer mais eficiência à execução de suas atividades. Algumas dessas tecnologias que surgiram tem como base softwares inteligentes, tais como o RPA. O RPA é um termo utilizado quando se trata de ferramentas que operam na interface do usuário em diversos sistemas de computadores imitando o que um ser humano faria. Portanto, essa tecnologia tem como objetivo a substituição de atos humanos pela automação (VAN DER AALST, 2018).

A sociedade atual está assistindo a uma enorme mudança no modo de interagir, comunicar, produzir e trabalhar que está relacionada a referida revolução industrial. O surgimento de novos modelos de negócio e o desaparecimento de outros consiste em um dos marcos desta etapa, além da dispensa de operadores humanos para o desempenho de determinadas funções (SCHWAB, 2019).

Com todas as revoluções que ocorreram ao longo da história, centenas de processos que exigiam trabalhos manuais foram substituídos por automações robóticas físicas. E isto não é diferente para os trabalhadores que ficam atrás dos computadores. Junto com a indústria 4.0, a automação de atividades em sistemas e computadores que são repetitivas e baseadas em regras bem definidas, com alto volume de trabalho, que consomem muito tempo dos trabalhadores e que, conseqüentemente, pelo cansaço mental, podem gerar riscos de erros operacionais também

estão sendo automatizadas. Porém, todo esse avanço acompanha o receio de gerar perda de empregos em um curto espaço de tempo. Essa é a preocupação apresentada por da Silva et al. (2018) quando, ao citar Schwab, explicitam que:

Schwab (2017, p.41) defende que, apesar de existir uma expectativa positiva com relação à capacidade de as tecnologias da Quarta Revolução Industrial contribuírem para o desenvolvimento econômico, deve-se gerenciar os possíveis impactos negativos da perda líquida de empregos no curto prazo, de forma a mitigar a possibilidade de que os processos da economia e das empresas sejam desfrutados apenas por uma pequena parcela da sociedade.

2.2 Evolução da ferramenta de RPA

A partir dos anos 2000, surgiram softwares dedicados a automatização de processos na modalidade de RPA, tais como aqueles desenvolvidos por empresas como UiPath em 2005 e Automation Anywhere em 2003. Tendo em vista a inovação que os referidos *softwares* de automação de processos trouxeram, houve a necessidade de padronização deste novo tipo de ferramenta. Nesse contexto, em 2017, o Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE), através do *Standards Association*, elaborou o guia IEEE 2755-2017 para Termos e Conceitos em Automação Inteligente de Processos.

Segundo o IEEE, o guia IEEE 2755-2017 considera as funcionalidades e recursos deste novo tipo de ferramenta de automatização de processos, de modo que o guia tem a seguinte finalidade:

“Utilizando a terminologia estabelecida no IEEE Std 2755-2017, definidos e classificados neste guia, há aproximadamente 150 recursos e funções em cinco áreas principais de capacidade de tecnologia na família de novos produtos de tecnologia, denominados coletivamente como Intelligent Process Automation. Este guia foi publicado para criar clareza para os indivíduos envolvidos com produtos de automação inteligente de processos baseados em software, para que os participantes da indústria possam confiar nas reivindicações de funcionalidade de um fabricante de produto e compreender os métodos tecnológicos subjacentes usados para produzir essas funções e como alguém pode avaliar a sofisticação relativa e importância de cada função ou recurso. Este guia representa o consenso de um painel diversificado de participantes do setor.”

Com isso, iniciou-se a corrida das empresas na automatização das atividades de escritório, ou seja, atividade aquelas que profissionais passavam horas e, talvez, dias executando nos computadores das empresas. Todas as maiores empresas do mundo já adotaram o RPA em suas companhias. Além disso, em 2020, em meio a pandemia de COVID-19, as

empresas foram obrigadas a adotar o *home office*, o que reforçou ainda mais a necessidade da automação dos processos. No Brasil, segundo dados levantados pela PNAD COVID-19 de maio de 2020, 8,7 milhões de profissionais estavam trabalhando de forma remota.

Como em todas as revoluções, a implementação da automação de processos (RPA) também foi criticada por muitos e levantou um alerta na qual elas poderiam perder o emprego para o chamado robô. Mas da mesma maneira que aconteceu no passado, algumas funções deixam de existir para que outras surjam, assim como mencionado por Schwab.

O RPA tem como um dos fins a automação de processos pouco cognitivos que não geram valor ao funcionário para que este profissional possa, de fato, realizar uma outra atividade mais intelectual. Com isso, as implementações das automações podem trazer muitos benefícios para as empresas e, segundo Florentina, M. (2020):

The benefits of tasks automation are costs reduce, lower operational risk (data entry errors), improved internal processes and execution time, increase productivity and data quality, reduced workload, employee satisfaction increase, the solutions of RPA could be used by non-IT people.¹

Kirchmer e Franz (2019, p. 11) defendem que a automação de processos seja utilizada em processos com alta volumetria na qual os profissionais necessitam repetir os mesmos passos diversas vezes ao longo do dia, que contenham entradas e saídas de dados de aplicações e com fácil acesso aos sistemas (sem softwares de segurança), com baixas alterações de negócio e sistêmico e em processos maduros e bem definidos.

Como já mencionado neste presente trabalho, quando as ferramentas de RPA surgiram, suas interações com os sistemas das empresas não eram simples, existiam poucas interfaces, bibliotecas, e funcionalidades muito simples, que não proporcionavam a experiência de uma automação simples e ao mesmo tempo robusta.

Dito isto, a empresa de UiPath, entendeu a necessidade de suas empresas parceiras e aprimorou sua plataforma a ponto de ser, por muitos anos consecutivos, a líder deste mercado,

¹ “Os benefícios de automatizar tarefas são a redução de custos, redução de riscos operacionais (erros na entrada de dados), aprimoramento dos processos internos e tempo de execução, aumento da produtividade e qualidade dos dados, redução da carga de trabalho, aumento na satisfação do funcionário, as soluções de RPA podem ser usadas por pessoas que não trabalham com TI” (tradução autor).

conforme evidenciado na figura 2.1. Por isso e pelo fato desta plataforma ter sido a escolhida como ferramenta para desenvolver o tema deste projeto, este sub tópico abordará as mais importantes das centenas de funcionalidades que a plataforma de RPA da UiPath oferece juntamente com os três produtos que compõe a solução de automação como um todo, formando um completo ecossistema.



Figura 2.1 – Quadrante mágico de Gartner.

Fonte: UiPath, 2021

Estas funcionalidades que fizeram com que a automação via RPA se tornasse mais amigável para leigos ou com pouca experiência em desenvolvimento e fosse largamente adotada em empresas de todo o mundo.

2.3 Solução completa da ferramenta de automação UiPath

A ferramenta da UiPath pode ser implementada localmente (*on-premisses*) ou na nuvem (*cloud*). Além disso, a UiPath, assim como outras plataformas de automação, disponibiliza duas maneiras de trabalho que são classificadas como *Attended* (atendidos) e *Unattended* (não atendidos) (LEIBOWITZ; KAKHANDIKI, 2018).

O modo de trabalho *Attended* é usualmente utilizado em processos ou atividades nas quais não se é possível automatizar todo o processo, ou seja, em atividades denominadas *front-office*. Dessa maneira, este modo de trabalho elimina parte da atividade, mas ainda necessitando de decisões humanas no decorrer do processo. (LEIBOWITZ; KAKHANDIKI, 2018).

Já o modo de trabalho *Unattended*, que consistem em *bots* independentes que executam os processos nos quais interagem com sistemas sem a necessidade de serem supervisionados. Estes robôs podem ser acionados por diferentes tipos de gatilhos. (LEIBOWITZ; KAKHANDIKI, 2018). Nesse contexto, esse modo de trabalho é utilizado nos processos e atividades que são totalmente automatizáveis, ou seja, de ponta a ponta. Os profissionais só terão interação em casos de exceção e, caso estes não ocorram, o processo não necessitará mais de intervenção humana.

Como parte da solução, a UiPath se divide outros três importantes produtos para que possa suportar tanto a necessidade das áreas de negócio, podendo executar diversos processos em uma mesma licença, quanto da equipe técnica na qual monitora e suporta todos os *bots*. Os produtos em questão são UiPath Studio, UiPath Assistant e UiPath Orchestrator (TRIPATHI, 2018). Estas são elucidadas nos próximos tópicos, exceto o UiPath Studio que é explicado no anexo deste presente trabalho.

2.3.1 UiPath Assistant

UiPath Assistant é um programa que abriga o processo que foi desenvolvido no UiPath Studio e que possibilita a execução dos *bots* em qualquer máquina, com ou sem monitoramento humano (ou) supervisão (MALATHI, 2021).

É uma aplicação que é instalada em um computador que possibilita o gerenciamento dos robôs, mesmo que estes estejam salvos apenas na máquina local e não no UiPath Orchestrator. Esta ferramenta permite que, com poucos cliques, inicie, pause, retome ou encerre uma automação quando desejar, como pode ser visto na figura 2.2.

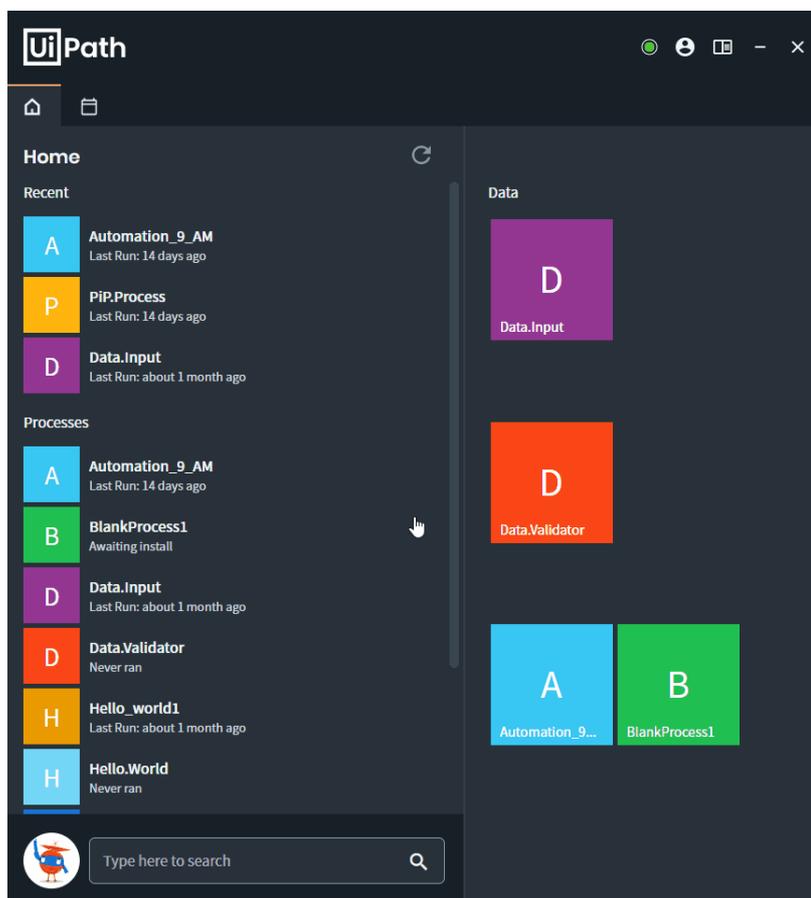


Figura 2.2 – Tela do UiPath Assistant.

Fonte: UiPath, 2021

Além disso, para os processos que devem ser executados com maior frequência ou aqueles que não podem ser deixados de serem executados por serem altamente críticos ao negócio, existem as funcionalidades na qual o robô fica um espaço em destaque à direita da aplicação, evitando perda de tempo na busca dele na lista de automações à esquerda, e a possibilidade de criação de um lembrete, vide figura 2.3, para que informe o usuário que chegou o momento de executar a rotina (UIPATH, 2021).

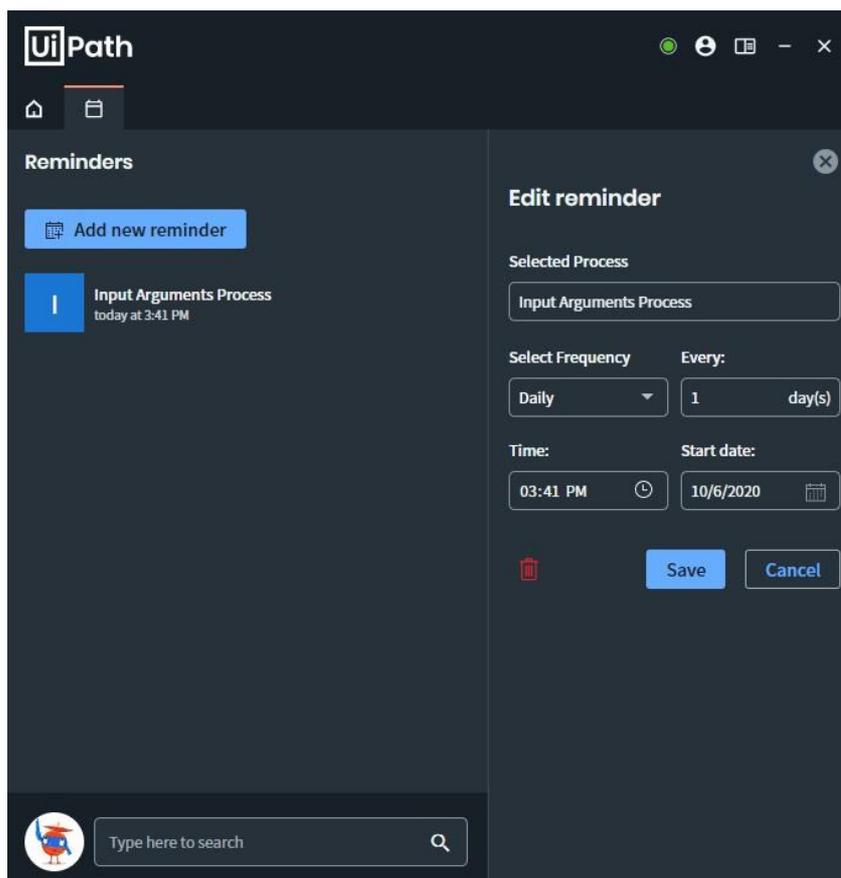


Figura 2.3 – Tela de destaque UiPath Assistant.

Fonte: UiPath, 2021

O UiPath Assistant pode ser conectado também ao UiPath Orchestrator (citado e explicado no tópico 2.2.1.3), o que gera a capacidade de executar as rotinas dos *bots* disponibilizados no UiPath Orchestrator na máquina em questão (UIPATH, 2021).

2.3.2 UiPath Orchestrator

UiPath Orchestrator é uma plataforma *web* ou *on premisses* que possibilita o gerenciamento, monitoramento e implantação de todos os recursos dos robôs e máquinas criados. Permite agendar a execução, iniciar no ato e parar os *bots* em tempo real em máquinas físicas ou máquinas virtuais. Além disso, possibilita controlar o status do *bot*, avaliar os *logs* gerados e analisar os resultados da execução do robô (MALATHI, 2021).

Os robôs são criados no UiPath Studio e, a partir da conexão com o UiPath Orchestrator, são salvos em armazenamento em nuvem ou na máquina em que está sendo executado, depende do modelo do UiPath Orchestrator, se este é *web* ou *on premisses* (MALATHI, 2021).

Com o UiPath Orchestrator é possível conectar-se a sistemas terceiros via API para que, caso um evento pré-determinado aconteça, uma transação é adicionada na fila de processamento. A fila de processamento é um serviço que consiste em organizar as transações que chegam para o processamento da automação, ou seja, a partir da entrada de uma transação na fila de processamento, já é gerado um gatilho para a automação iniciar sua execução, reduzindo, assim, a necessidade de agendamento de execução do robô visto que, quando o gatilho da automação é baseado em agendamento de horário, este método pode fazer com que o *Service Level Agreement* (SLA) da demanda não seja atendido como esperado. Além disto, as filas reduzem em grande escala o consumo de memória das máquinas nas quais a automação é executada, uma vez que as transações são armazenadas na nuvem e não na memória do equipamento em questão (UIPATH, 2021).

Outros dois métodos importantes de integração que a o UiPath Orchestrator abrange são o *Webhook* e conexão direta com o *Enterprise AD*. *Webhook* consiste em uma tecnologia na qual pode-se enviar e receber mensagens a partir de algum evento, logo, caso algum evento pertinente a automação aconteça, o *bot* pode ter sua execução iniciada através de uma comunicação *Webhook* ou realizar alertas aos profissionais interessados via plataformas corporativas. Já a funcionalidade *Enterprise AD*, permite que as automações tenham uma conexão direta com o Active Directory (AD) das empresas, ou seja, permite que a automação trabalhe diretamente com os usuários e grupos do Enterprise AD no Uipath Orchestrator, ou seja, não sendo necessário importá-los ou gerenciar um segundo diretório, à medida que eles mudam com o tempo (UIPATH, 2021).

2.4 Ferramentas utilizadas na automatização do processo de bloqueio de entregas

2.4.1 UiPath Studio

As funcionalidades dessa ferramenta são descritas no anexo deste trabalho.

2.4.2 Banco de dados

O banco de dados foi criado por volta dos anos 60, onde viu-se a necessidade de conseguir acessar de uma maneira mais fácil os arquivos e informações que, na época eram armazenados de uma maneira sequencial em fitas magnéticas ou cartões perfurados. Os dois principais modelos desenvolvidos na época foram o modelo de rede *Conference on Data System Language* (CODASYL) e o modelo hierárquico *Information Management System* (IMS) (BERG, 2013).

Com a criação do banco de dados as discussões sobre o melhor modelo de armazenamento dos registros nos bancos de dados ganharam força. Com isso, E.F. Codd, em 1970, criou o banco de dados relacional que revolucionou a maneira na qual os dados eram armazenados, visto que utilizava linhas colunas e *schemas* para armazenar e organizar os dados (Taylor, 2011).

No período entre 1974 e 1977, dois protótipos foram criados e ganharam notoriedade. O primeiro deles foi criado na *University of California* na cidade de Berkeley, nos Estados Unidos da América. Este banco de dados relacional utilizava a linguagem QUEL para realizar a consulta aos dados (Oppel, 2010).

O segundo foi chamado de *System R* e foi desenvolvido pela empresa IBM. Este modelo utilizava a linguagem Structured Query Language (SQL), para acessar os dados do banco (Oppel, 2010). Na década dos anos de 1980 os computadores começaram a se tornar mais populares e acessíveis às empresas. Com isso, a linguagem SQL se tornou a mais utilizada do mundo (Taylor, 2007). Conseqüentemente, houve a necessidade de padronização desta linguagem.

Inicialmente, a ideia era que a linguagem SQL fosse uma linguagem universal, porém muitas empresas realizaram incrementos nesta linguagem, o que gerou uma despadronização e confusão aos desenvolvedores. Com isso, houve a necessidade de que a linguagem fosse padronizada e as duas organizações envolvidas na padronização do SQL são o comitê americano *American National Standards Institute* (ANSI) e o comitê internacional *International Organization for Standardization* (ISO) (EISENBERG; MELTON, 1999).

2.4.3 Microsoft Power BI

Com o mercado cada vez mais acirrado, as empresas buscam na tecnologia soluções que gerem cada vez mais organização em seus dados e *insights* a fim de tomar as melhores decisões possíveis. E as ferramentas de BI conversam muito com esses desejos das empresas, visto que suas soluções atendem a essas expectativas (LARUCCIA; CHIARELLI, 2013).

Dessa necessidade, as empresas de tecnologias começaram a desenvolver as ferramentas de BI, visto que elas podem captar um grande volume de dados de diferentes fontes e processá-los. Como saída desse processamento de dados podem surgir relatórios e *dashboards* mais inteligentes e específicos para o que se quer analisar (Borges et al., 2018).

O Power BI é uma ferramenta é a junção de serviços de software, que possibilitam a transformação das fontes de dados das mais variadas bases em painéis interativos, ou seja, torna os dados compreensíveis apenas com o olhar, sem necessidade de realizar um trabalho sobre eles. Além disso, o Power BI é facilmente compartilhado com outras pessoas para que todos possam ter as mesmas visões (MICROSOFT, 2021).

As ferramentas de *Business Intelligence (BI)*² tem como objetivo expor ao devido público informações e visões que as organizações não teriam de maneira fácil. Assim, através de visões e painéis, fica mais fácil para os profissionais tomarem as decisões de maneira mais assertiva (CARVALHO, 2013,).

O Power BI conta com as plataformas, o Power BI Desktop e o Power BI Service. Usualmente, de maneira simplista, o Power BI Desktop é utilizado para conectar a ferramentas às bases de dados e desenvolver visualizações e relatórios, enquanto o Power BI Service, tem como seu diferencial, o compartilhamento e interatividade dos *dashboards* com outras pessoas, logo, com esta opção de compartilhamento todos que receberam o compartilhamento do *dashboard* podem interagir com ao mesmo tempo e até mesmo criar suas próprias visualizações a partir da base de dados que foi publicada no Power BI Desktop.

² *Business Intelligence (BI)* se trata do processo de captura, organização, crítica, exposição, compartilhamento e monitoramento de dados e informações que suporte as áreas de negócios.

Estas plataformas podem se conectar a mais de uma centena de bases de dados. Estas conexões podem ser realizadas de duas maneiras distintas, são elas: (i) importação simples; e (ii) *DirectQuery*.

A primeira maneira de realizar a importação de dados no Power BI é chamada de Importação simples. Esta, consiste em se conectar a uma base de dados na qual o Power BI irá absorver os dados para si e, caso esta base sofra alterações em um momento posterior, estas não serão replicadas diretamente no Power BI, ou seja, uma nova importação de dados se fará necessária para obter os dados atualizados (MICROSOFT, 2021).

A segunda maneira de conectar o Power BI a uma base de dados é utilizando a funcionalidade denominada de *DirectQuery*. Esta funcionalidade não absorve as informações da base de dados para si, mas cria um vínculo no qual toda vez que o *dashboard* é acessado, a ferramenta realiza uma nova consulta a essa base de dados para que sempre considere os dados atuais, ou seja, caso a base conectada sofra alterações com o passar do tempo, seja de inclusão, alteração ou remoção de dados, o *dashboard* estará sempre atualizado e mostrando os dados em tempo real (MICROSOFT, 2021).

Como já mencionado no presente trabalho, a ferramenta em questão pode se conectar a mais de uma centena de bases de dados de maneira fácil e simplificada a modo que mesmo uma pessoa sem experiência em desenvolvimento de códigos de programação consiga. No quadro 2.1 informa todas as bases de dados que o Power BI oferece conexão e se a funcionalidade *DirectQuery*, mencionada no parágrafo anterior, está ou não disponível para a cada fonte de dados.

Quadro 2.1 – Bases que podem se conectar ao Power BI (continua)

Fonte de dados	Conecta ao Power BI Desktop	Conecta ao Power BI Service	DirectQuery/conexão dinâmica
Banco de dados do Access	Sim	Sim	Não
ActiveDirectory	Sim	Sim	Não
Adobe Analytics	Sim	Sim	Não
Amazon Redshift	Sim	Sim	Sim
appFigures	Sim	Sim	Não
Cubos do AtScale	Sim	Sim	Sim
Azure Analysis Services	Sim	Sim	Sim
Armazenamento de Blobs do Azure	Sim	Sim	Não
Azure Cosmos DB	Sim	Sim	Não
Azure Data Explorer (Kusto)	Sim	Sim	Sim

Quadro 2.1 – Bases que podem se conectar ao Power BI (continua)

Fonte de dados	Conecta ao Power BI Desktop	Conecta ao Power BI Service	DirectQuery/conexão dinâmica
Azure Data Lake Storage Gen1	Sim	Sim	Não
Azure Data Lake Storage Gen2	Sim	Sim	Não
Azure Databricks	Sim	Sim	Sim
Azure DevOps	Sim	Sim	Não
Azure DevOps Server	Sim	Sim	Não
Azure HDInsight (HDFS)	Sim	Sim	Não
Azure HDInsight Spark	Sim	Sim	Sim
Banco de Dados SQL do Azure	Sim	Sim	Sim
Azure Synapse	Sim	Sim	Sim
Armazenamento de Tabelas do Azure	Sim	Sim	Não
Conector do BI	Sim	Sim	Sim
BI360 – Relatórios financeiros e de orçamento	Sim	Sim	Não
Data Virtuality LDW	Sim	Sim	Sim
Data.World – Obter Conjunto de Dados	Sim	Sim	Não
Microsoft Dataverse	Sim	Sim	Sim
Denodo	Sim	Sim	Sim
Dremio	Sim	Sim	Sim
Dynamics 365 (online)	Sim	Sim	Não
Dynamics 365 Business Central	Sim	Sim	Não
Central do Microsoft Dynamics 365 Business (local)	Sim	Sim	Não
Customer Insights do Dynamics 365	Sim	Sim	Não
Dynamics NAV	Sim	Sim	Não
Fonte de dados do Emigo	Sim	Sim	Não
Entersoft Business Suite	Sim	Sim	Não
Essbase	Sim	Sim	Sim
Exasol	Sim	Sim	Sim
Excel	Sim	Sim	Não
Arquivo	Sim	Sim	Não
Pasta	Sim	Sim	Não
GitHub	Sim	Sim	Não
Google Analytics	Sim	Sim	Não
Google BigQuery	Sim	Sim	Sim
HDFS (Arquivo do Hadoop)	Sim	Não	Não
LLAP do Hive	Sim	Sim	Sim
Consulta Interativa do HDInsight	Sim	Sim	Sim
IBM DB2	Sim	Sim	Sim
Banco de Dados do IBM Informix	Sim	Sim	Não
IBM Netezza	Sim	Sim	Sim

Quadro 2.1 – Bases que podem se conectar ao Power BI (continua)

Fonte de dados	Conecta ao Power BI Desktop	Conecta ao Power BI Service	DirectQuery/conexão dinâmica
Impala	Sim	Sim	Sim
Indexima	Sim	Sim	Sim
Industrial App Store	Sim	Sim	Não
Grade de Informações	Sim	Sim	Não
Intersystems IRIS	Sim	Sim	Sim
Intune Data Warehouse	Sim	Sim	Não
Jethro ODBC	Sim	Sim	Sim
JSON	Sim	Sim	Não
Kyligence Enterprise	Sim	Sim	Sim
MailChimp	Sim	Sim	Não
MariaDB	Sim	Sim	Sim
Marketo	Sim	Sim	Não
MarkLogic ODBC	Sim	Sim	Sim
Microsoft Azure Consumption Insights	Sim	Sim	Não
Microsoft Exchange	Sim	Sim	Não
Contas individuais do Microsoft Exchange Online 8	Sim	Sim	Não
Segurança do Microsoft Graph	Sim	Sim	Não
Mixpanel	Sim	Sim	Não
MySQL	Sim	Sim	Não
OData	Sim	Sim	Não
ODBC	Sim	Sim	Não
OleDb	Sim	Sim	Não
Oracle	Sim	Sim	Sim
Paxata 6	Sim	Sim	Não
PDF	Sim	Sim	Não
Planview Enterprise One – CTM	Sim	Sim	Não
Planview Enterprise One – PRM	Sim	Sim	Não
Planview Projectplace	Sim	Sim	Não
PostgreSQL	Sim	Sim	Sim
Fluxos de dados do Power BI	Sim	Sim	Não
Conjuntos de dados do Power BI	Sim	Sim	Sim
Fluxos de dados do Power Platform	Sim	Sim	Não
Script do Python	Sim	Sim	Não
QubolePresto	Sim	Sim	Sim
Quick Base	Sim	Sim	Não
QuickBooks Online	Sim	Sim	Não
Script R	Sim	Sim	Não
Roamler	Sim	Sim	Não
Objetos do Salesforce	Sim	Sim	Não
Relatórios do Salesforce	Sim	Sim	Não
Servidor do SAP Business Warehouse	Sim	Sim	Sim

Quadro 2.1 – Bases que podem se conectar ao Power BI (conclusão)

Fonte de dados	Conecta ao Power BI Desktop	Conecta ao Power BI Service	DirectQuery/conexão dinâmica
SAP HANA	Sim	Sim	Sim
Pasta do SharePoint	Sim	Sim	Não
Lista do SharePoint	Sim	Sim	Não
Lista do SharePoint Online	Sim	Sim	Não
Smartsheet	Sim	Sim	Não
Snowflake	Sim	Sim	Sim
Spark	Sim	Sim	Sim
SparkPost	Sim	Sim	Não
SQL Server	Sim	Sim	Sim
SQL Server Analysis Services	Sim	Não	Sim
Stripe	Sim	Sim	Não
SurveyMonkey	Sim	Sim	Não
SweetIQ	Sim	Sim	Não
Sybase	Sim	Sim	Não
TeamDesk	Sim	Sim	Não
TenForce	Sim	Sim	Não
Teradata	Sim	Sim	Sim
Texto/CSV	Sim	Sim	Não
Twilio	Sim	Sim	Não
tyGraph	Sim	Sim	Não
Vertica	Sim	Sim	Sim
Web	Sim	Sim	Não
Webtrends	Sim	Sim	Não
Workforce Dimensions	Sim	Sim	Não
XML	Sim	Sim	Não
Zendesk	Sim	Sim	Não

Fonte: MICROSOFT, 2021

Outro ponto que se destaca na plataforma de Power BI é o fato que, a partir do momento que está conectada a uma base de dados e foi publicada do Power BI Desktop para o Power BI Service com a funcionalidade *DirectQuery* habilitada ou não, é possível que os outros usuários que não a pessoa que realizou a publicação, crie novos painéis e relatórios, ou seja, em um cenário na qual uma empresa tem profissionais especializados em criar *dashboards* para as áreas de negócio e, com o passar do tempo, os painéis necessitem de novas visualizações em cima da base já referenciada, é possível que os colaboradores da área de negócio criem suas próprias visualizações sem ter a necessidade de solicitar à equipe que desenvolveu os painéis inicialmente (MICROSOFT 2021).

2.4.4 Grafana

Grafana é uma ferramenta formada por uma coleção de soluções que permitem monitorar e analisar métricas, logs e rastreamentos. A ferramenta é capaz de se conectar em diversas bases de dados e permite realização de consultas, visualizações e recebimento de alerta (GRAFANA, 2021).

Grafana fornece a funcionalidade de organizar painéis em pastas separadas, onde uma pasta pode ter diferentes permissões para visualização e edição (BEERMANN, 2020). Com o Grafana é possível apresentar estatísticas resumidas não apenas de bases de dados, mas também realizar monitoramento dos próprios componentes de um servidor, como, por exemplo, o desempenho do *Central Processing Unit* (CPU) da máquina (CHAN, 2019).

Um *dashboard* é um conjunto de um ou mais painéis organizados a fim de deixar a visualização dos dados mais intuitiva. O Grafana permite, quando se cria o *dashboard*, personalizar as propriedades de exibição para exibir apenas as informações que interessam aquele determinado público. Os painéis podem ser formados por dados provenientes de diversas plataformas como, por exemplo, Graphite, Prometheus, Elasticsearch, InfluxDB, OpenTSDB, MySQL, PostgreSQL, Microsoft SQL Server e AWS Cloudwatch (GRAFANA, 2021).

O Grafana é uma ferramenta de monitoramento amplamente utilizada em todo mundo. Ela auxilia, através de *dashboards*, o monitoramento de uma operação, seja ao longo do tempo ou em tempo real, vide figura 2.4.

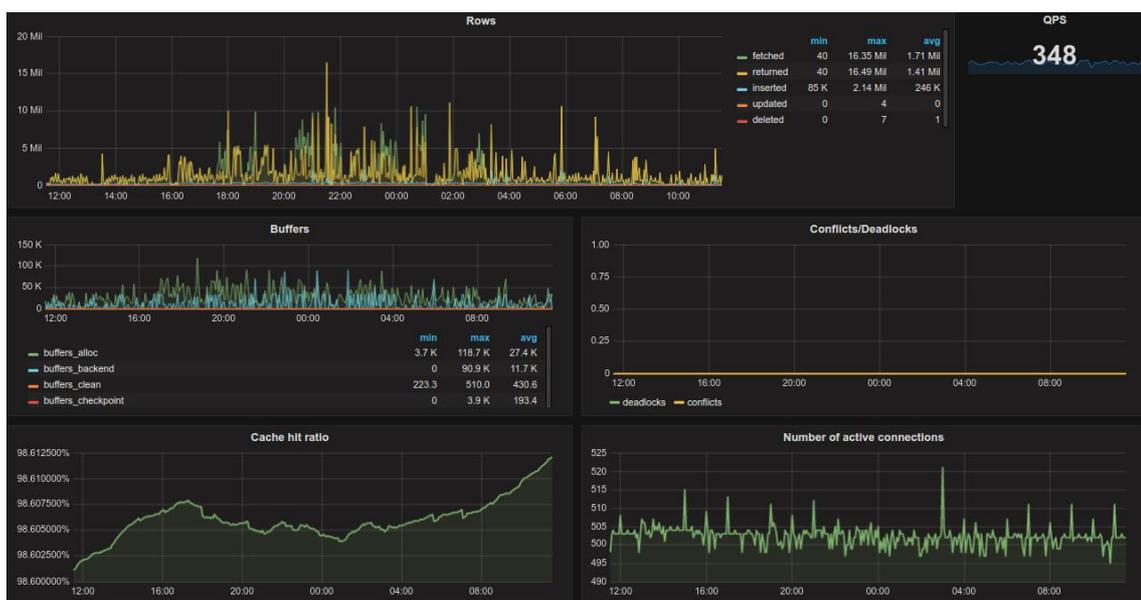


Figura 2.4 – Tela de monitoramento do Grafana.

Fonte: Grafana, 2021

Para conseguir exibir *dashboards* e realizar monitoramentos, o Grafana se conecta a uma fonte de dados através de *plugins*. Segundo o site do Grafana, atualmente, são cerca de 226 *plugins* disponíveis que se conectam as mais variadas bases como, por exemplo, banco de dados, outros painéis, bases *cloud* ou um repositório de arquivos. Usualmente, esta aplicação é conectada a um banco de dados, como por exemplo, MySQL, Oracle, Prometheus ou PostgreSQL, este último foi o banco de dados utilizado na solução do problema apresentado neste trabalho (GRAFANA, 2021).

2.4.5 Azure Data Lake

O Data Lake é considerado um repositório que pode ser escalável de maneira fácil e rápida, a depender da volumetria dos dados que são inseridos. Estes dados, após o armazenamento podem ser consultados por aplicações analíticas, e não apenas aplicações pré-definidas. Usualmente a plataforma Hadoop³ é utilizada como base no Data Lake (MILOSLAVSKAYA; TOLSTOY, 2020).

Os dados que são armazenados no Data Lake em seu formato bruto e possuem uma chave única e algumas *tags* de metadados. Os metadados tem a função de entender os relacionamentos e informações que cada dado faz (GUAMÁN; VACA; YUQUILEMA, 2018).

Uma característica marcante é que os dados não passam por nenhum tipo de tratamento ou filtro para serem inseridos no Data Lake, ou seja, o Data Lake recebe os dados brutos, como saem dos sistemas já alimentam o Data Lake e só passam por qualquer tipo de tratamento em um momento posterior, se houver necessidade. Com isso, a rapidez na entrada dos dados é um fator marcante (FANG, 2015; GUAMÁN; VACA; YUQUILEMA, 2018). O fato de os dados serem armazenados sem padrão é denominado como *No Schema*⁴ e visa o processamento dos dados apenas no momento que é necessário e não na entrada no Data Lake (FANG, 2015).

O Azure Data Lake Analytics é capaz de processar trabalho de *Big Data* em segundos sem a preocupação de ter uma infraestrutura robusta que suporte uma enorme quantidade de

³ Hadoop é uma plataforma de software *open source* utilizado para armazenamento de qualquer tipo de dados, até mesmo em grande volume, visto que tem um enorme poder de processamento de dados simultâneos.

⁴ *No Schema* significa sem esquema, sem uma padronização necessária.

dados e os processe de maneira tão rápida. Além disso, ao utilizar o Azure Data Lake só se paga pelo o que for consumido em capacidade e pelo trabalho executado sem a necessidade de se preocupar com o espaço de armazenamento, visto que este pode ser rapidamente redimensionado, de acordo com a necessidade (MICROSOFT, 2021).

Além disso, é possível realizar a integração com diversos serviços que potencializam ainda mais a utilização do Azure Data Lake com intuito de fornecer um ecossistema completo às empresas e não apenas um repositório de dados. Alguns desses exemplos de serviços que manipulam os dados armazenados no Azure Data Lake são o Azure Datafactory, Azure Databricks, Azure Logic Apps e Azure Functions. (MICROSOFT, 2021).

Por fim, e não menos importante, a segurança dos dados armazenados no Azure Data Lake é fundamental, visto que nele pode conter informações sensíveis de pessoas e de empresas de todo o mundo. Com isso, quando o serviço do Azure Data Lake é contratado, toda a segurança da Microsoft é aplicada para proteger os dados que ali serão inseridos. Portanto, a empresa que contratar tal serviço estará amparada pela segurança de uma das maiores e importantes empresas do mundo (MICROSOFT, 2021).

Capítulo 3

Propostas Tecnológicas

Como mencionado neste presente trabalho, os índices de compras fraudulentas *online* aumentaram na pandemia e o que já gerava um enorme prejuízo para as empresas ficou ainda maior e as companhias começaram a investir mais tempo e dinheiro na área de prevenção a fraudes, tanto de maneira proativa utilizando os dados históricos do comprador, do CEP, da volumetria de vendas esperada quanto de maneira reativa, no bloqueio das entregas, que é o tema principal deste trabalho.

Em paralelo a este fato, criou-se a área de inteligência operacional na empresa em questão e se viu neste processo uma grande oportunidade de ganhar visibilidade dentro da companhia e buscar o crescimento e respeito de outras áreas, visto que este é um projeto altamente rentável para companhia e de ganho imediato. Além disso, criando uma automação eficiente iria fazer com que as outras áreas sentissem confiança em trocar os processos manuais por um *bot*.

A empresa em questão se trata de uma das maiores do setor varejista no âmbito nacional, e apenas nacional, e contava apenas com uma profissional da área de Prevenção a fraudes para realizar este processo. Além de ter apenas uma pessoa na execução do processo de bloqueio de entregas, esta se tratava da supervisora da área, ou seja, era uma pessoa que tinha muitas outras demandas e responsabilidades mais estratégicas, porém necessitava realizar esta atividade de alto impacto financeiro à companhia de maneira totalmente manual. Isto acarretava na realização de apenas duas execuções semanais de um processo que deveria ser executado diariamente. Quando questionada o motivo pelo qual a profissional não demandava esta atividade à sua equipe, a resposta foi que a equipe já tinha muita demanda diária, inclusive necessitavam fazer horas extras, e não seria mais possível adicionar esta atividade. Por outro lado, ela realizar esta atividade diariamente seria inviável, visto que ela demorava, em média, de duas a três horas na preparação de todos os requisitos para a execução deste processo, visto que um erro que ela cometesse, poderia acarretar no bloqueio de um pedido no qual não deveria ser bloqueado.

Com esta primeira etapa compreendida, começaram as conversas para entender o fluxo do processo, em que ela coletava os dados, em que tabela ela cruzava os dados para obter os números dos pedidos visto que as adquirentes não enviavam, quais sistemas ela acessava e quais os caminhos que a supervisora percorria nestes sistemas para realizar o alerta do bloqueio da compra. Como resultado deste levantamento foi criado o fluxograma do processo, vide figura 3.1, que, posteriormente, fora validado pela área de negócio.

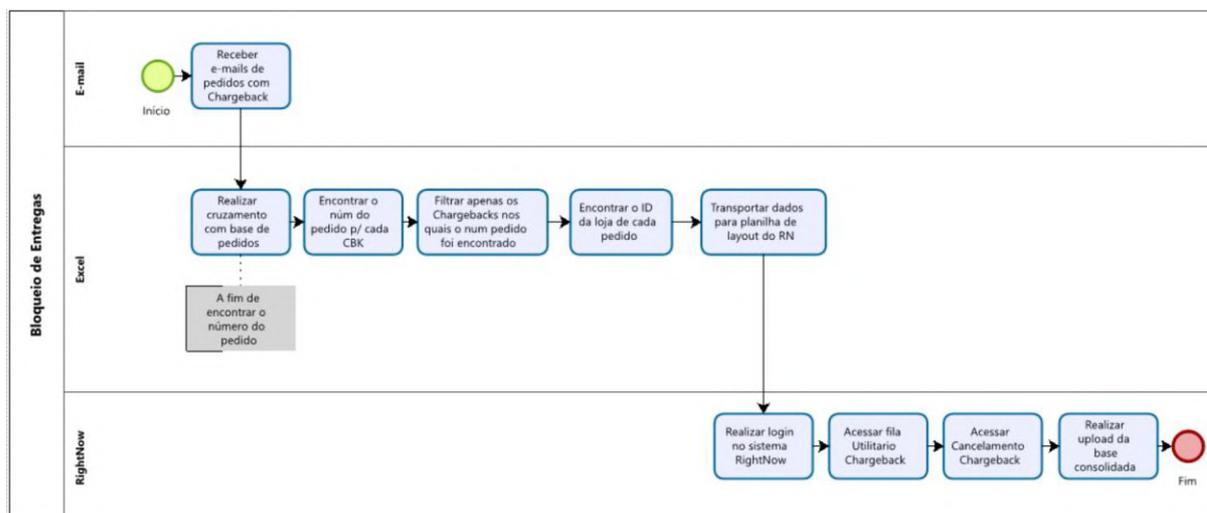


Figura 3.1 – Fluxograma do processo realizado manualmente.

Fonte: Guilherme Defanti, 2021

Após o mapeamento do fluxo do processo, era necessário entender se as adquirentes poderiam enviar os dados das compras fraudulentas através de uma tecnologia mais confiável que por *e-mail*, além de que os *e-mails* enviados não continham padrão, o que não é o ideal quando se trata de automação. Assim, viu-se a necessidade de reuniões com as adquirentes onde, depois de longas conversas, foi levantado que uma das adquirentes poderia realizar o envio, diariamente, dos dados dos pedidos com Chargeback para a empresa em questão via API e a outra adquirente também poderia enviar diariamente, porém via SFTP.

Com mais esta etapa concluída, foi necessário realizar testes de integração com o intuito de entender como estas informações chegariam via API e SFTP e se com essas informações seria possível realizar os cruzamentos necessários no *data lake* da empresa. Após a realização dos testes de integração, todos ocorreram com sucesso e os dados foram recebidos como se esperava.

O próximo passo era realizar o cruzamento destas informações que foram recebidas com as que estava no *data lake* e, a partir disso, iniciaram-se os estudos para verificar quais dos

campos recebidos retornaria um número maior de número de pedidos corretos. Como resultado dos estudos, verificou-se que quando os campos valor da compra, data da compra, número do cartão utilizado e ID da compra eram cruzados juntos na tabela de pedidos que estava contida no *data lake* da empresa, retornava um número muito próximo a totalidade de casos. Este número foi validado pela área demandante assim como a sequência do projeto.

Com essas validações iniciais, viu-se que o projeto era viável tecnicamente, visto que essas eram as etapas mais complexas pela necessidade de comunicação com outras empresas e de cruzamento de dados sem a certeza de que retornariam o número do pedido correto.

As próximas etapas da automação consistiam em montar uma planilha no formato Excel, no *layout* aceito pelo sistema *RightNow*, com os pedidos que deveriam ser bloqueados, percorrer o caminho do sistema *RightNow*, realizar o *upload* desta planilha e realizar o monitoramento da entrega através do *status* do pedido, esta informação estava contida na mesma tabela do *data lake*.

O *layout* aceito pelo sistema *RightNow* é composto por três colunas, são elas: Número do pedido, número identificador da loja (esta informação é capturada na mesma tabela do *data lake* que o número do pedido), e a data do Chargeback (a data é sempre o dia anterior, visto que as adquirentes enviam os alertas de Chargeback no dia seguinte ao ocorrido).

Após a preparação da planilha em Excel no *layout* aceito pelo sistema *RightNow*, o próximo passo era a realização do *login* na ferramenta, percorrer o caminho até chegar no local onde o arquivo deve ser inserido, como demonstrado nas figuras 3.2 e 3.3 e a realização do *upload* do arquivo no sistema.

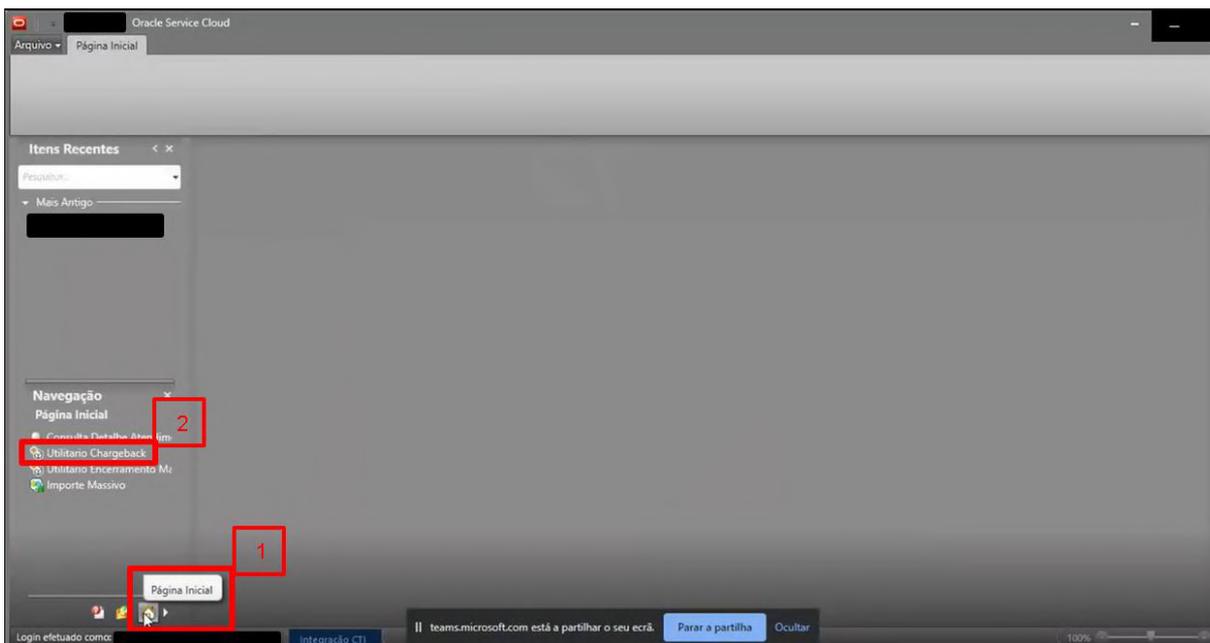


Figura 3.2 – Tela inicial do sistema *RightNow*.

Fonte: *RightNow*, 2021

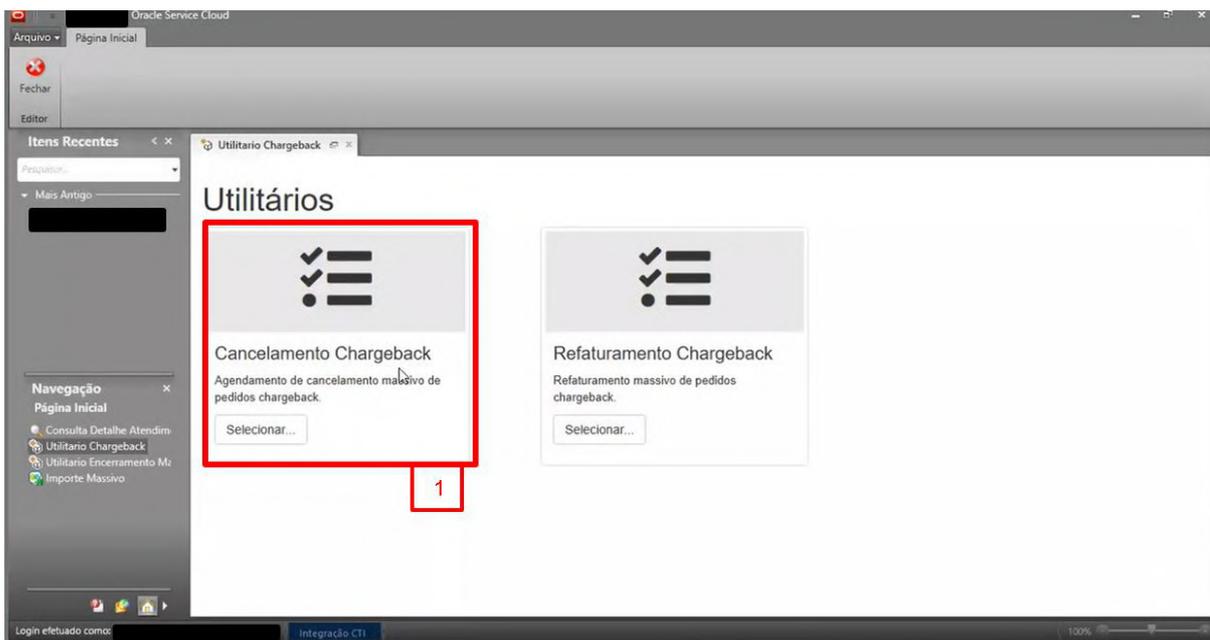


Figura 3.3 – Tela do local que o *upload* do arquivo é realizado no sistema *RightNow*.

Fonte: *RightNow*, 2021

Após o *upload* do arquivo no sistema *RightNow*, este mesmo, por conter todas as informações dos pedidos e das transportadoras, realiza a verificação de qual transportadora irá realizar ou está realizando a entrega do pedido e envia uma notificação via *e-mail* solicitando que o bloqueio da entrega seja realizado e, caso o caminhão já tenha saído para entrega, que este retorne ao centro de distribuição de onde ele saiu.

Além disso, para que a área de negócio pudesse ter métricas do sucesso e quais eram os ofensores da eficácia da automação, foi criado um *dashboard* no Power BI. Neste *Dashboard a área de negócio* consegue ter visibilidade do volume e dados financeiros dos produtos e pedidos que foram recuperados e entregues aos fraudadores, nome das transportadores que menos realizam os bloqueios da entregas em tempo hábil, volumetria e valor financeiro de Chargeback por adquirente, se os Chargebacks ocorrem em produtos da própria empresa ou se acontece em maior quantidade com as empresas parceiras que utilizam o *marketplace* como ponto de venda dentre outros indicadores importantes para o negócio. O *dashboard* será melhor detalhado no capítulo 4 deste trabalho dentro do tópico de Resultados Obtidos ou Esperados.

Para que o *dashboard* pudesse representar realmente se a automação foi efetiva no bloqueio da entrega ou não, ela deve monitorar o *status* do pedido no *data lake*, pois se o *status* se tornar entregue (ETV) ou entregue ao vizinho (ETV) significa que a automação não foi eficaz e o produto foi entregue ao fraudador. Porém, se o pedido tiver o *status* alterado para cancelado (CAN), devolvido (DEV), devolução (DVC) ou rota de devolução (RDV) significa que houve sucesso no bloqueio da entrega do pedido fraudulento. Para os pedidos nos quais os status eram diferentes dos que foram citados neste parágrafo, a automação entende que o bloqueio continua pendente.

Por fim a área de prevenção a fraudes, atualmente, tem uma visão diferente do processo, com mais informações de quais canais acontece o maior índice de Chargeback, além de quais transportadoras são ofensoras quanto ao indicador de entregas e além de desses e outros dados que serão melhor detalhados dentro do tópico de Resultados Obtidos ou Esperados no capítulo 4 do presente trabalho, a profissional que executava o processo não precisa mais e pode ter um olhar estratégico sobre a operação, o que realmente é a função dela.

Como proposta de solução técnica para o problema apresentado neste trabalho, o problema foi separado em quatro macro etapas. A primeira consiste na captação dos dados dos Chargebacks que as adquirentes enviam, realizar os cruzamentos no *data lake* com o intuito de encontrar o número do pedido e o ID da loja na qual a venda foi realizada, realizar a ingestão no banco de dados e na fila da automação RPA e montar a planilha no *layout* esperado pelo sistema. A segunda etapa, baseia-se em realizar o *upload* da planilha no sistema a fim de solicitar o bloqueio. A terceira etapa executar a etapa da automação que realiza o acompanhamento do *status* do pedido para verificar se o bloqueio foi eficaz ou não. E, por fim,

na quarta etapa, criar os *dashboards*, tanto técnico para acompanhar se a execução da automação está sendo realizada com sucesso, quanto para a área de negócios.

Para a primeira etapa, como mostrado na figura 3.4, o gatilho do processo se dá por agendamento de horário, porém, visto que as adquirentes disponibilizam os Chargebacks em horários diferentes, houve a necessidade de duas execuções diárias, a captação dos Chargebacks da adquirente Cielo ocorre a uma hora e da adquirente GetNet às onze horas. Independente da adquirente, o fluxo segue o mesmo para as duas. Logo, após a captação dos novos Chargebacks, a automação realiza o cruzamento com o *data lake* a fim de encontrar o número do pedido e ID da loja vendedora de cada Chargeback. Por fim, a automação monta o arquivo Excel no *layout* que o sistema *RightNow* aceita, realiza a ingestão de informações no banco de dados PostgreSQL e insere uma notificação na fila do próprio robô.

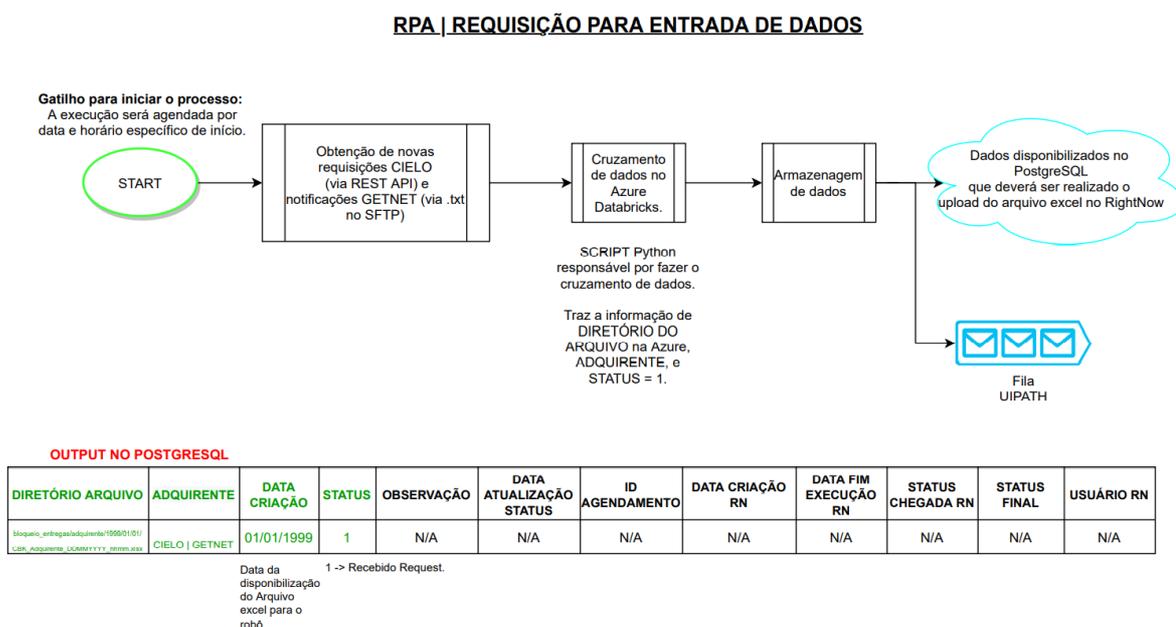


Figura 3.4 – Fluxograma da primeira etapa da automação.

Fonte: Documento técnico do processo em questão, 2021

As colunas preenchidas, na primeira etapa, no banco de dados são DIRETÓRIO ARQUIVO, ADQUIRENTE, DATA CRIAÇÃO e STATUS, que correspondem, respectivamente, o local onde o arquivo que irá ser utilizado no sistema *RightNow* está armazenado, o nome da adquirente em questão na qual os arquivos correspondem, a data que este item foi inserido no banco de dados e o *status* de andamento do item. Como demonstrado no quadro 3.1, cada *status* representa a situação do item no banco de dados.

Quadro 3.1 – Descrição dos status do banco de dados PostgreSQL

Status	Descrição
1	Chargeback recebido
2	Adicionado à fila da UiPath
3	Em processamento - upload de arquivo
4	Upload do arquivo finalizado com sucesso
5	Erro no upload do arquivo
6	Aguardando validação do upload do arquivo
7	Status final atualizado

Fonte: Guilherme Defanti, 2021

Uma vez que o robô conclui a primeira etapa, automaticamente a segunda se inicia, visto que na primeira etapa a automação insere o arquivo na fila RPA e este é o gatilho para o início da segunda etapa, como se pode ver na figura 3.5.

RPA PERFORMER/DISPATCHER | BLOQUEIO DE ENTREGAS

Quando novas requisições forem disponibilizadas na fila da UiPath, o robô é responsável por fazer o *upload* do arquivo descrito na coluna DIRETÓRIO ARQUIVO do banco de dados. O robô também alimenta o PostgreSQL, a cada requisição, com as informações geradas pelo *upload* do arquivo no sistema RightNow.

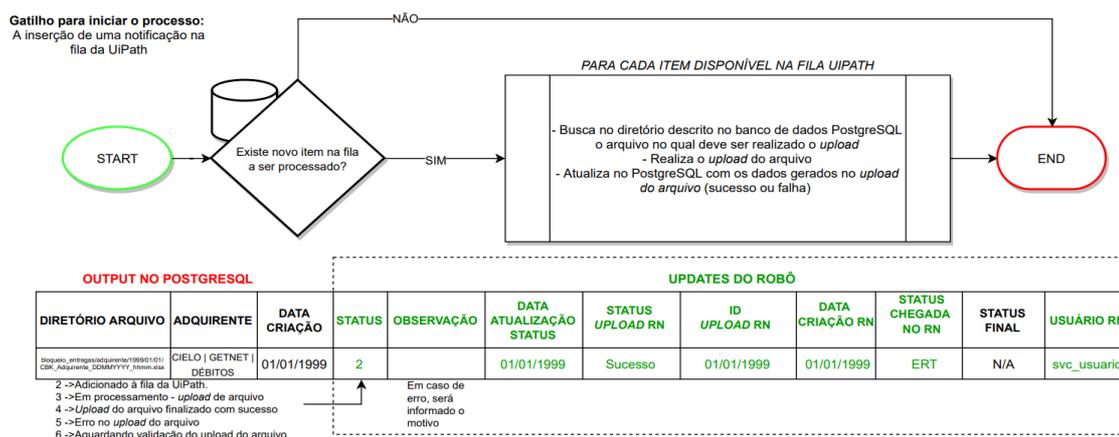


Figura 3.5 – Fluxograma da segunda etapa da automação.

Fonte: Documento técnico do processo em questão, 2021

Com o início da segunda etapa, a automação realiza o *login* no sistema *RightNow* no intuito de realizar o upload da planilha gerada na primeira etapa. Após a realização do login, a automação percorre o caminho dentro do sistema em questão, que pode ser visto nas figuras 3.2 e 3.3, realiza o *upload* e altera os valores das colunas do banco de dados PostgreSQL, como se pode ver na figura 3.5. Visto que nesta etapa, muitas colunas do banco de dados são alteradas, estas foram descritas no quadro 3.2 com o intuito de facilitar o entendimento.

Quadro 3.2 – Colunas que podem ser alteradas na segunda etapa da automação (continua)

Nome da coluna	Descrição
STATUS	Numeral correspondente as etapas que a automação está, vide quadro 3.1

Quadro 3.2 – Colunas que podem ser alteradas na segunda etapa da automação (conclusão)

OBSERVAÇÃO	Em caso de erros, este campo é preenchido com o motivo.
DATA ATUALIZAÇÃO STATUS	A cada atualização a partir da segunda etapa, a data do ocorrido é inserida neste campo.
STATUS UPLOAD RN	Recebe o valor “Sucesso” ou “Erro”, dependendo do upload no sistema <i>RightNow</i> .
ID UPLOAD RN	Recebe o número gerado pelo sistema <i>RightNow</i> após o <i>upload</i> da planilha.
DATA CRIAÇÃO RN	Recebe a data em que o <i>upload</i> da planilha foi realizado no sistema <i>RightNow</i> .
STATUS CHEGADA NO RN	Recebe o valor do <i>status</i> no momento da primeira consulta no <i>data lake</i> .
USUÁRIO RN	Recebe o nome do usuário no qual a automação utilizou para realizar o <i>login</i> no sistema <i>RightNow</i> .

Fonte: Guilherme Defanti, 2021

Com o fim da segunda etapa, o sistema *RightNow* recebe os pedidos que houve Chargebacks, verifica em seu cadastro as transportadoras que estão realizando as entregas e dispara *e-mails* para não realizem as entregas. Porém, em muitos casos, a transportadora não consegue informar ao motorista que não necessita mais realizar a entrega do produto e, por isso, é necessário que a automação continue verificando os *status* de entrega dos pedidos nos quais houve a solicitação de bloqueio.

A terceira parte da automação é a etapa de monitoramento dos pedidos, que consiste, para todos os pedidos que não tenham a coluna *STATUS FINAL* preenchida no banco de dados PostgreSQL, checar o *status* de entrega no *data lake* até que este seja um dos descritos no quadro 3.3, visto que estes são *status* finais.

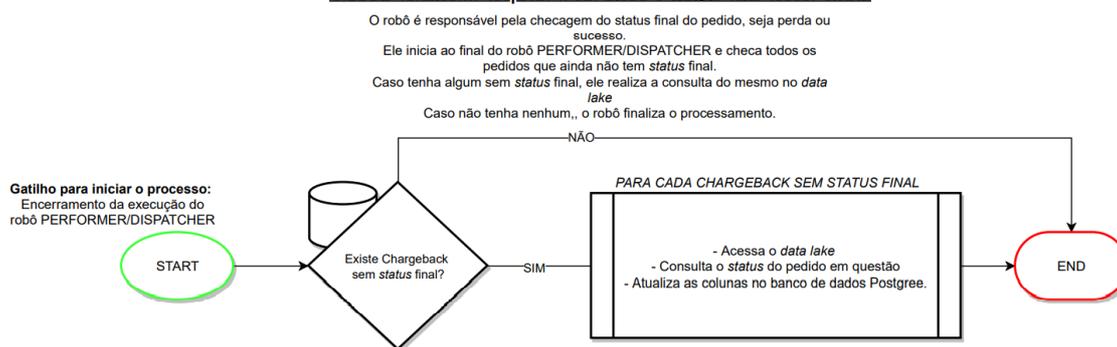
Quadro 3.3 – Descrição dos status finais

Status de entrega	Descrição para a situação de Chargeback
ENT	Produto entregue, o processo não foi eficaz para este item.
ETV	Produto entregue, o processo não foi eficaz para este item.
CAN	Produto não entregue, o processo foi eficaz para este item.
DEV	Produto não entregue, o processo foi eficaz para este item.
DVC	Produto não entregue, o processo foi eficaz para este item.
RDV	Produto não entregue, o processo foi eficaz para este item.

Fonte: Guilherme Defanti, 2021

Visto que a resposta por parte das transportadoras sobre se foi possível ou não realizar o bloqueio do pedido pode demorar dias e até semanas, a automação deve realizar este monitoramento diariamente para que quando esta informação chegue, já atualize o *dashboard* da área de negócios. Pensando nisto, no fim das duas execuções diárias este monitoramento ocorre, assim como desenhado na figura 3.6.

RPA PERFORMER | VALIDADOR BLOQUEIO ENTREGAS



OUTPUT NO POSTGRESQL

DIRETÓRIO ARQUIVO	ADQUIRENTE	DATA CRIAÇÃO	STATUS	OBSERVAÇÃO	DATA ATUALIZAÇÃO STATUS	STATUS UPLOAD RN	ID UPLOAD RN	DATA CRIAÇÃO RN	STATUS CHEGADA NO RN	STATUS FINAL	USUÁRIO RN
loquero_entregas\loquernet\1999010101	CIELO GETNET DÉBITOS	01/01/1999	7		01/01/1999	Sucesso	01/01/1999	01/01/1999	ERT	RDV	svc_usuario

7 -> Status final atualizado

UPDATES DO ROBÔ

Em caso de erro, será informado o motivo

Figura 3.6 – Fluxograma da terceira etapa da automação.

Fonte: Documento técnico do processo em questão, 2021

Após a checar se os pedidos foram bloqueados ou não, quatro colunas podem ser atualizadas no banco de dados PostgreSQL. As colunas STATUS, OBSERVAÇÃO e DATA ATUALIZAÇÃO STATUS foram explicadas no quadro 3.2. A quarta coluna que pode sofrer alteração é a STATUS FINAL. Esta coluna apenas recebe valor quando o pedido em questão está em um dos status finais, como explicado no quadro 3.3. Após receber um dos *status* finais já citados, este pedido não passa mais por monitoramento.

A quarta e última etapa da automação consistiu na criação de dois *dashboards*, um para a área de prevenção a fraudes acompanhar os indicadores de negócio e outro para a equipe de sustentação monitorar a execução da automação.

Para a criação do *dashboard* disponibilizado para a área de negócios foi utilizado a ferramenta Power BI e através da sua conectividade simplificada com o banco de dados PostgreSQL foi possível dar visibilidade de toda operação do processo através de painéis e indicadores. Estes painéis e indicadores serão melhores explicados no sub tópico Resultados Obtidos ou Esperados do tópico 4 deste presente trabalho.

Portanto, como descrito nos parágrafos acima, foi desenhado o fluxograma técnico da solução o qual compreendia todas as tecnologias supracitadas, como demonstrado na figura 3.7 abaixo:

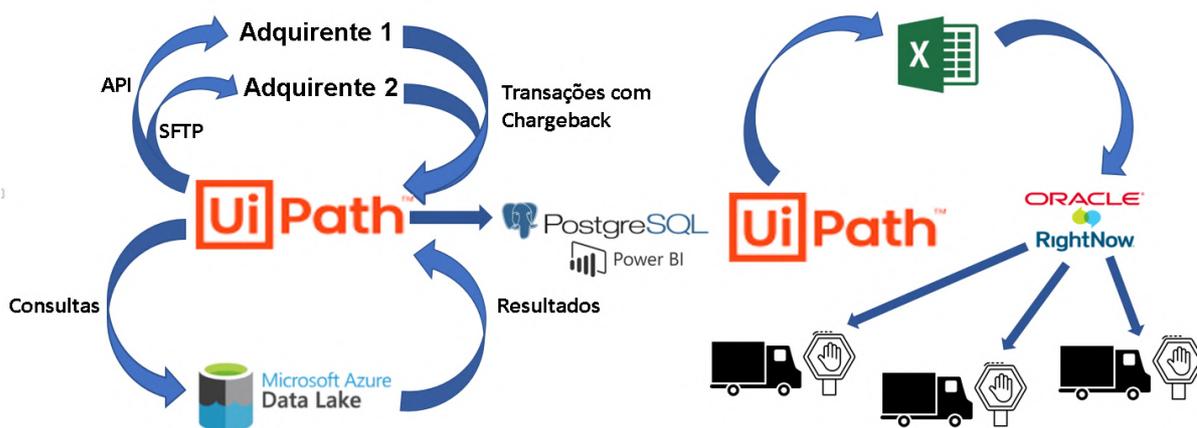


Figura 3.7 – Fluxograma completo da automação.

Fonte: Guilherme Defanti, 2021

Já para a criação do monitoramento da automação em si, Grafana foi a ferramenta utilizada, que conta com uma conexão nativa ao banco de dados PostgreSQL. Assim, foi possível criar indicadores de monitoramento que alertam a equipe responsável pela sustentação da automação através de cores e de um específico para erros denominado de Falha, como pode ser visto na figura 3.8.



Figura 3.8– Indicadores do Grafana referentes ao monitoramento da automação.

Fonte: Painel geral do Grafana do processo em questão, 2021

Além desta visualização, uma outra foi criada para facilitar o monitoramento de erros no processo. Um painel que informa a saúde da máquina virtual na qual a automação é executada. Assim como mostrado na figura 3.9, os dados analisados são o consumo do CPU e memória da computador, além dos dois discos. Caso o CPU ou a memória ultrapassassem 80% (oitenta por cento) de consumo um alerta é emitido a equipe responsável. Assim como para os discos rígidos quando ultrapassam 85% (oitenta e cinco por cento) de capacidade.



Figura 3.9 – Indicadores do Grafana referentes aos alertas de infraestrutura.

Fonte: Painel de infraestrutura do Grafana do processo em questão, 2021

Capítulo 4

Resultados Obtidos ou Esperados

Como primeira meta, a área demandante da empresa de *e-commerce* tinha o desejo de que a automação conseguisse realizar o bloqueio de, minimamente, 40% (quarenta por cento) dos casos de Chargeback.

No quadrante do *dashboard* Total Pedidos Por Status Bloqueio da figura 4.1, é possível notar que em apenas trinta e cinco mil pedidos houve o bloqueio da entrega com sucesso e em outros cinquenta e quatro mil pedidos o pedido foi entregue ao fraudador, ou seja, pouco menos de 40% (quarenta por cento) de eficácia. Isto trouxe a dúvida se a automação estava sendo realmente produtiva.

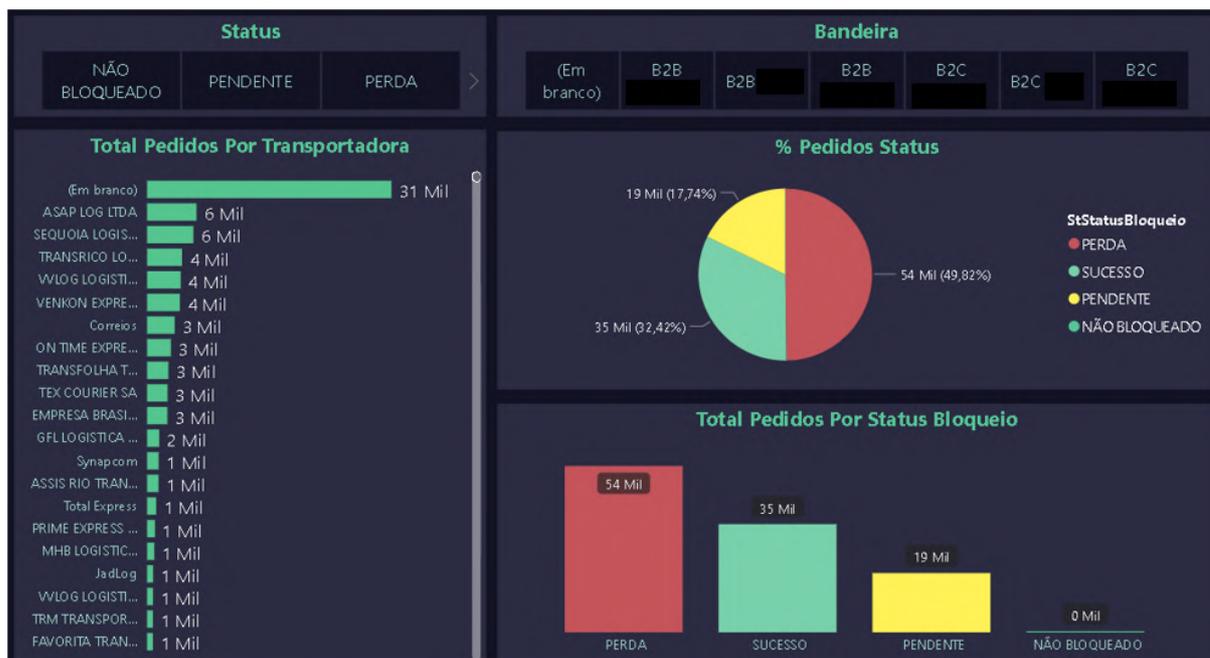


Figura 4.1 – Tela de assertividade considerando pedidos que já chegam com o *status* de entrega.

Fonte: Power BI do processo em questão, 2021

Depois de alguns meses depois da automação ter entrado em produção, iniciou-se um estudo para entender o motivo da automação ser menos eficaz que se esperava. Como resultado do estudo, notou-se que, quando as notificações eram enviadas pelas adquirentes para a empresa de *e-commerce*, estes pedidos já tinham sido entregues aos destinatários, ou seja, mesmo que a

automação realizasse o processo de bloqueio da entrega, não seria mais possível bloqueá-la e isto pesava no indicador de assertividade.

Logo, com o intuito de ter visibilidade apenas dos pedidos nos quais a automação recebia das adquirentes e ainda não tinham sido entregues, uma nova visualização foi criada no *dashboard*. Os dados dessa nova visualização contemplam apenas os casos que foram recebidos após a melhoria e, como mostra a figura 4.2, os números, até o momento, se mostram muito mais eficazes, visto que em mil e oitocentos pedidos nos quais a automação executou o processo de bloqueio e já obteve uma resposta de sucesso ou de perda, em mil e trezentos casos obteve-se sucesso e apenas quinhentos pedidos foram entregues aos fraudadores, o que representa uma taxa de sucesso de 72% (setenta e dois por cento), número próximo ao dobro que a área de negócio esperava como sucesso dentro do que era possível a automatização fazer.

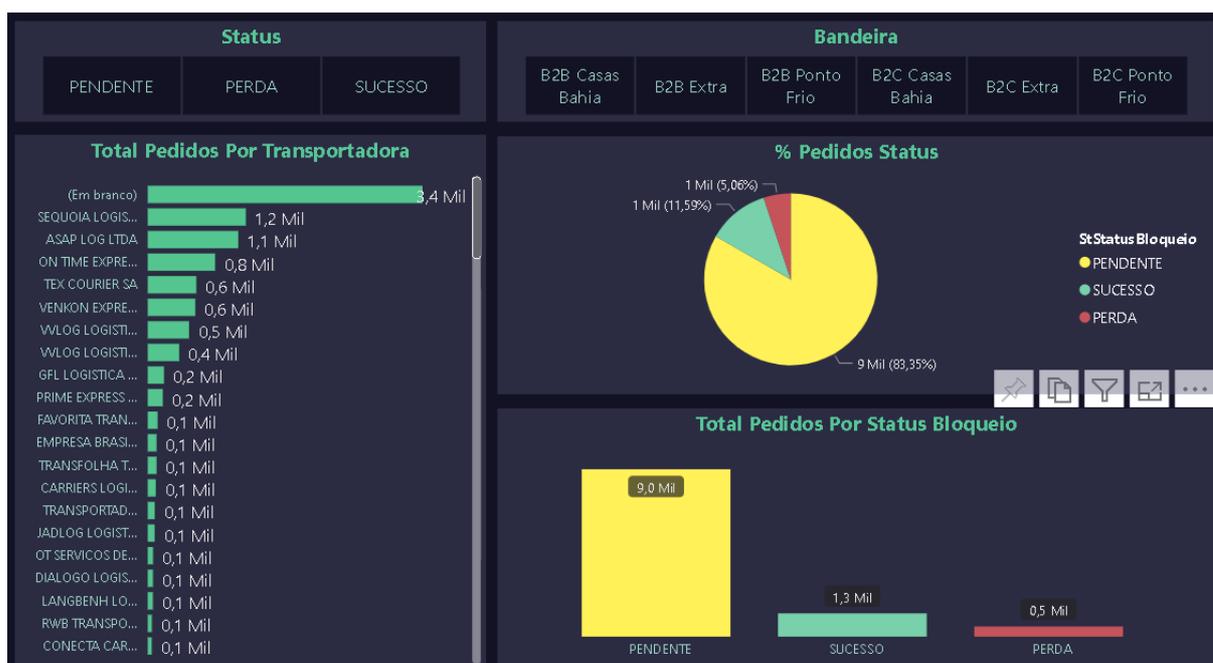


Figura 4.2 – Tela de assertividade considerando pedidos que não chegam com o *status* de entregue.

Fonte: Power BI do processo em questão, 2021

Além destas visualizações já apresentadas, outros três painéis foram criados para que a área de negócio pudesse tomar decisões baseadas em dados do processo. Na figura 4.3, por exemplo, evidencia se são as empresas de *e-commerce* ou os parceiros que vendem na plataforma de *marketplace* que estão mais expostos ao Chargeback, onde P1 significa vendas feitas pelo próprio *e-commerce* e P3 pelos parceiros.

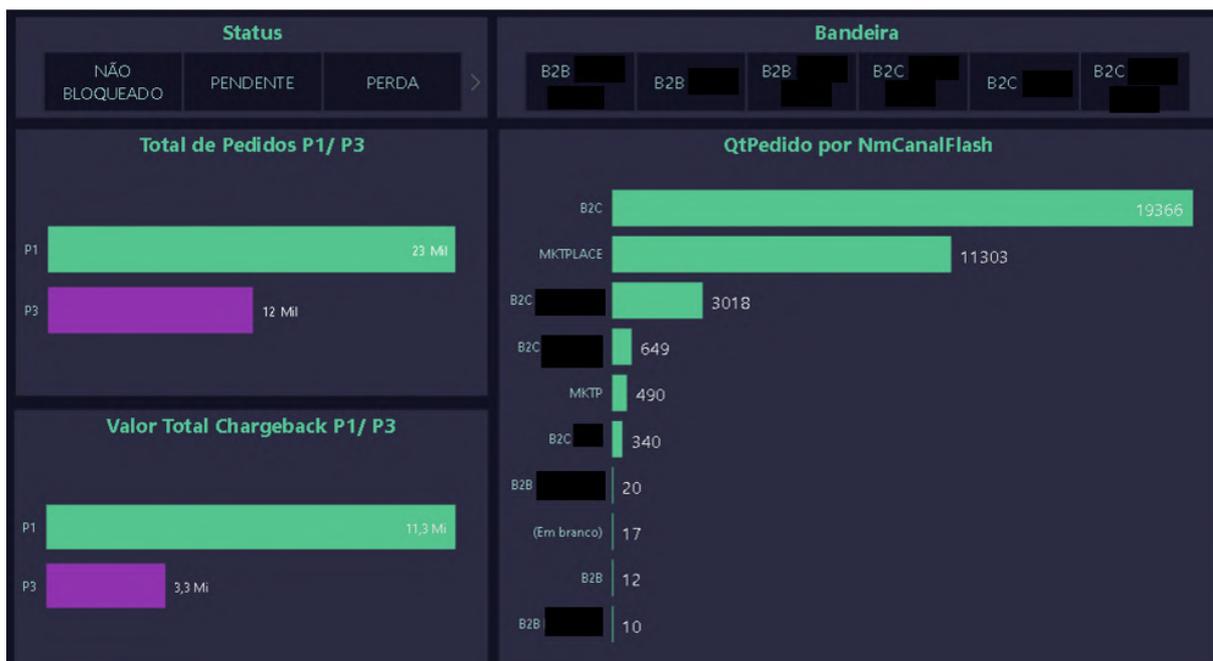


Figura 4.3 – Tela de pedidos P1 e P3.

Fonte: Power BI do processo em questão, 2021

Já a figura 4.4 evidencias duas situações. Nos dois quadrantes esquerdos do *dashboard* mostram as quantidades de Chargebacks que, no mesmo momento em houve a notificação do alerta, a adquirente já estornou o dinheiro (débitos) e os casos em que a notificação foi dada, porém o dinheiro continuou com o e-commerce.



Figura 4.4 – Tela de pedidos por canal.

Fonte: Power BI do processo em questão, 2021

Por fim, na figura 4.5, contém todos os pedidos que se tornaram Chargebacks e suas respectivas informações. Com essa funcionalidade disponibilizada no *dashboard*, a área de negócio pode exportar esta base para um arquivo no formato xls ou csv para que possa realizar análises mais detalhada dos casos.

Status			Bandeira					
NÃO BLOQUEADO	PENDENTE	PERDA	(Em branco)	B2B	B2B	B2C	B2C	B2C
Exportação								
NrPedido	NmTransportadora	NmLojista	NmCanalFlash	NmAdquirente	IdUnidadeNegocio	IdTransportadora	IdLojista	IdCompraEntreg
1718	NOWLOG LOGISTICA INTELIGENTE L		B2C	PL	8	2071207600015	10037	DVC
1756			B2C	PL	8		10037	_TMA
1768		COMPREBEL	MKTPLACE	PL	8		12299	ENT
1836		SHOPINFO	MKTPLACE	GetNet	8		11964	ENT
1840			B2C	PL	8	8723015000190	10037	CAN
1869		CENTRALAR.COM	MKTPLACE	GetNet	8		15113	ENT
1878		MANIA VIRTUAL	MKTPLACE	GetNet	8		11578	ENT
1885		GRAFA	MKTPLACE	GetNet	8		12121	ENT
1889		CONSUL	MKTPLACE	GetNet	8		17971	ENT
1901		BRASTEMP	MKTPLACE	GetNet	8		17969	ENT
1914		MEGAMAMUTE	MKTPLACE	GetNet	8		10138	ENT
1919		ACER BRASIL LOJA OFICIAL	MKTPLACE	GetNet	8		16746	ENT
1943		MADEIRAMADEIRA	MKTPLACE	GetNet	8		10798	RDV
1951		NET SOFÁS	MKTPLACE	GetNet	8		32013	ENT
1952			B2C	PL	8	1064288400056	10037	CAN
1956		LOJA ELECTROLUX	MKTPLACE	GetNet	8		24506	ENT

Figura 4.5 – Tela de exportação de planilha.

Fonte: Power BI do processo em questão, 2021

Capítulo 5

Conclusão e Trabalhos Futuros

5.1 – Conclusão

O presente trabalho utilizou ferramenta de automação de processo, banco de dados relacional, consultas no *data lake*, *dashboard* para a área de negócio ter uma visão estratégica do processo e, para a equipe de sustentação, uma ferramenta de monitoramento de incidentes baseada em *dashboards*. Todas essas tecnologias foram aplicadas com o intuito de retirar o trabalho manual e não tempestivo que a área de negócios realizava.

Além disso, a expectativa da área de negócios era que a automação bloqueasse pelo menos 40% (quarenta por cento) dos Chargebacks quando, na verdade, a automação mostrou-se eficaz em 72% (setenta e dois por cento) dos casos nos quais a informação do Chargeback chegava e os pedidos ainda não tinham sido entregues, ou seja, nos casos em que havia alguma possibilidade de que o bloqueio da entrega fosse realizado.

Os pedidos nos quais as notificações de Chargeback chegavam depois de já terem sido entregues ao fraudador foram desconsiderados para o cálculo de eficácia da automação, visto que não seria possível realizar o bloqueio destes de nenhuma outra maneira a não ser que as adquirentes realizassem um envio mais tempestivo da comunicação de fraude, caso que é abordado no tópico 5.2 do presente trabalho.

5.2 – Trabalhos Futuros

Tendo em vista que o setor do varejo está cada vez mais acirrado, com as grandes empresas criando e desenvolvendo os seus *marketplaces*, que são sites nos quais as companhias não vendem apenas produtos da própria empresa, mas também abrem espaço para empresas parceiras comercializarem em sua plataforma, recebendo uma parte da venda como comissão, um grande diferencial para se destacar neste mercado é o tempo de entrega dos produtos. Com

isso, as empresas estão realizando as entregas das compras feitas em seus *marketplaces* cada vez mais rápidas e muitas empresas já conseguem realizar, inclusive, no mesmo dia, método denominado como *same day delivery*.

Dito isto, a primeira oportunidade de melhoria se trata de uma comunicação mais tempestiva com as adquirentes. Atualmente, quando acontece o Chargeback, esta informação só é disponibilizada no dia seguinte, ou seja, em determinados casos a entrega, proveniente de uma compra fraudulenta, já foi realizada, fazendo com que, a solução apresentada no presente trabalho, não tenha eficácia.

A segunda oportunidade de trabalho futuro se identificou quando, na criação do *dashboard*, foi identificado que em, aproximadamente, 30% das compras que geram Chargeback, vide figura 4.1, ocorre um erro de integração no qual o sistema não consegue encontrar a transportadora que irá realizar ou está realizando a entrega da compra. Com isso, os alertas de bloqueio de entrega não são disparados e os fraudadores conseguem receber os produtos.

Considerando o fato de que a automação, atualmente, consegue realizar o bloqueio das entregas com sucesso em, aproximadamente, 72% das compras fraudulentas, vide figura 4.2, e levando em conta que o *bot* não pôde emitir alertas, pelo fato de o sistema não conter a informação do nome da transportadora, em 30 mil compras fraudulentas, estima-se que a automação poderia ter realizado o bloqueio efetivo de, aproximadamente, mais 21.600 pedidos caso conseguisse acessar as informações da transportadora.

Por fim, a terceira oportunidade de trabalho futuro é a criação de uma solução que faça com que, ao receber as transações de *Chargeback*, a empresa varejista envie, automaticamente, um alerta de bloqueio de entrega diretamente aos sistemas das transportadoras que fazem a comunicação com os motoristas. Dessa maneira, o risco de atraso na solicitação de bloqueio das entregas seria mitigado em grande parte dos casos, o que ocasionaria uma maior eficácia do processo.

Referências Bibliográficas

2021 Quadrante Mágico do Gartner para Automação Robótica de Processos. UiPath. Disponível em: <<https://www.uipath.com/pt/resources/automation-analyst-reports/gartner-magic-quadrant-robotic-process-automation>>. Acesso em 26 out. 2021.

About Automation Anywhere. We define the future of work. Automation Anywhere. Disponível em: <<https://www.automationanywhere.com/company/about-us>>. Acesso em 09 nov. 2021.

About Debugging. UiPath. Disponível em: <<https://docs.uipath.com/studio/docs/about-debugging>>. Acesso em 26 out. 2021.

About UiPath Assistant. UiPath. Disponível em: <<https://docs.uipath.com/robot/docs/uipath-assistant>>. Acesso em 26 out. 2021.

AUCANCELA GUAMÁN, Margarita Alejandra; NARANJO VACA, Myriam Johanna; BETÚN YUQUILEMA, José Francisco. ***Mapeo sistemático de literatura de un data lake.*** 2018.

Azure Data Lake Store. Microsoft. Disponível em: <<https://azure.microsoft.com/pt-br/services/storage/data-lake-storage/#overview>>. Acesso em 11 nov. 2021.

Backstage View. UiPath. Disponível em: <<https://docs.uipath.com/studio/docs/the-user-interface#section-backstage-view>>. Acesso em 26 out. 2021.

BEERMANN, Thomas et al. ***Implementation of ATLAS Distributed Computing monitoring dashboards using InfluxDB and Grafana.*** In: EPJ Web of Conferences. EDP Sciences. 2020.

BERG, Kristi L. et al. ***History of databases.*** *International Journal of Management & Information Systems* (IJMIS), v. 17, n. 1. 2013.

BORGES, Mirele Marques; CARDOZO, Claudio Testoni; KRONMEYER FILHO, Oscar Rudy. **Dos dados ao conhecimento: *business intelligence* como ferramenta para apoio à tomada de decisão.** *Disciplinarum Scientia| Sociais Aplicadas*, v. 14, n. 1. 2018.

CARVALHO, Rodrigo Baroni de; FERREIRA, Marta Araújo Tavares. **Tecnologia da informação aplicada à gestão do conhecimento.** 2013.

CHAN, Nicolas. *A Resource Utilization Analytics Platform Using Grafana and Telegraf for the Savio Supercluster.* In: *Proceedings of the Practice and Experience in Advanced Research Computing on Rise of the Machines (learning)*. 2019.

CHATFIELD, Tom. **Como aproveitar ao máximo a era digital.** Leya, 2013.

Com pandemia, comércio eletrônico tem salto em 2020 e dobra participação no varejo brasileiro. Globo. 26 fev. 2021. Disponível em: <<https://g1.globo.com/economia/noticia/2021/02/26/com-pandemia-comercio-eletronico-tem-salto-em-2020-e-dobra-participacao-no-varejo-brasileiro.ghtml>>. Acesso em 26 out. 2021.

DA SILVA, Elcio Brito et al. *Automação & Sociedade: Quarta Revolução Industrial, um olhar para o Brasil.* Brasport, 2018.

Dashboard overview. Grafana. Disponível em: <<https://grafana.com/docs/grafana/latest/dashboards/?pg=dashboards&plcmt=hero-btn2>>. Acesso em 27 out. 2021.

Data Lake Analytics. Microsoft. Disponível em: <<https://azure.microsoft.com/pt-br/services/data-lake-analytics>>. Acesso em 11 nov. 2021.

Deploy and manage your enterprise robot workforce centrally. UiPath. Disponível em: <<https://www.uipath.com/product/orchestrator>>. Acesso em 26 out. 2021.

EISENBERG, Andrew; MELTON, Jim. *SQL: 1999, formerly known as SQL3.* SIGMOD Record, vol. 28, n°. 4. 1999

FANG, Huang. **Managing data lakes in big data era: What's a data lake and why has it become popular in data management ecosystem.** In: 2015 IEEE International Conference on Cyber Technology in Automation, Control, and Intelligent Systems (CYBER). IEEE, 2015.

FLORENTINA, Marcu. *Web data extraction with robot process automation. Study on LinkedIn web scraping using UiPath Studio.* Annals of 'Constantin Brancusi' University of Targu-Jiu. *Engineering Series*, n. 1, 2020.

Fontes de dados do Power BI. Power BI. Disponível em: <<https://docs.microsoft.com/pt-br/power-bi/connect-data/power-bi-data-sources>>. Acesso em 27 out. 2021.

HOSBSBAWM, Eric J. **Da revolução industrial inglesa ao imperialismo.** Editora Forense Universitária. 5ª ed. 2003.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa Nacional por Amostra de Domicílios PNAD COVID19 Maio/2020 Resultados mensal.** Rio de Janeiro, 2020.

IEEE 2755-2017 - IEEE Guide for Terms and Concepts in Intelligent Process Automation. Instituto de Engenheiros Eletricistas e Eletrônicos. Disponível em: <<https://standards.ieee.org/standard/2755-2017.html>>. Acesso em 09 nov. 2021.

Introduction to Grafana. Grafana. Disponível em: <<https://grafana.com/docs/grafana/latest/introduction>>. Acesso em 11 nov. 2021.

KIRCHMER, Mathias; FRANZ, Peter. *Value-driven robotic process automation (RPA).* In: SPRINGER. *International Symposium on Business Modeling and Software Design.* [S.l.], 2019.

LARUCCIA, Mauro Maia; DA SILVA, Regiani Salvático Pereira; CHIARELLI, Gabriella Dottavio. **Discussão sobre o Business Intelligence em empresas de Tecnologia da Informação.** Augusto Guzzo Revista Acadêmica, n. 11. 2013.

MALATHI, T. et al. *An Experimental Performance Analysis on Robotics Process Automation (RPA) With Open Source OCR Engines: Microsoft Ocr And Google Tesseract OCR*. In: *IOP Conference Series: Materials Science and Engineering*. IOP Publishing, 2021.

MILOSLAVSKAYA, Natalia; TOLSTOY, Alexander. *Big data, fast data and data lake concepts*. *Procedia Computer Science*, v. 88. 2016.

O propósito da UiPath. Acelerar as conquistas humanas. UiPath. Disponível em: <<https://www.uipath.com/pt/company/about-us>>. Acesso em 09 nov. 2021.

O que é Power BI? Microsoft. Disponível em: <<https://docs.microsoft.com/pt-br/power-bi/fundamentals/power-bi-overview>>. Acesso em 11 nov. 2021.

O seu Canvas de automação: UiPath Studio. UiPath. Disponível em: <<https://www.uipath.com/pt/product/studio>>. Acesso em 26 out. 2021.

OPPEL, Andy. *Databases demystified*. McGraw Hill *Professional*, 2010.

Overview. UiPath. Disponível em: <<https://docs.uipath.com/studio/docs/the-user-interface#section-backstage-view>>. Acesso em 26 out. 2021.

Postgres Overview. Grafana. Disponível em: <<https://grafana.com/grafana/dashboards/455>>. Acesso em 27 out. 2021.

RIBEIRO, Jorge et al. *Robotic Process Automation and Artificial Intelligence in Industry 4.0—A Literature review*. *Procedia Computer Science*, v. 181. 2021.

SCHWAB, Klaus. **A quarta revolução industrial**. Edipro, 2019.

Segurança e conformidade abrangentes, internas. Microsoft. Disponível em: <<https://azure.microsoft.com/pt-br/services/storage/data-lake-storage/#security>>. Acesso em 11 nov. 2021.

SILVA, Dorotéa Bueno da; SILVA, Ricardo Moreira da; GOMES, Maria de Lourdes Barreto. **O reflexo da terceira revolução industrial na sociedade.** XXII Encontro Nacional de Engenharia de Produção Curitiba–PR, v. 23, 2002.

TAULLI, T. *The Robotic Process Automation Handbook*. New York, USA: Springer, 2020.

TAYLOR, Allen G. *Database development for dummies*. John Wiley & Sons, 2011.

TAYLOR, Allen G. *SQL for Dummies*. John Wiley & Sons, 2010.

Tentativas de Fraude Digital em Serviços Financeiros Aumentam 612% no Brasil à Medida que Transações Digitais Crescem. TransUnion. 12 ago. 2021. Disponível em: <<https://www.transunion.com.br/blog/blog-posts/fraud-trends-Q2-2021>>. Acesso em 26 out. 2021

The User Interface. UiPath. Disponível em: <<https://docs.uipath.com/studio/docs/the-user-interface#section-backstage-view>>. Acesso em 10 nov. 2021.

TRIPATHI, A. M. *Learning Robotic Process Automation: Create Software robots and automate business processes with the leading RPA tool - UiPath*. Mumbai: Packt Publishing, 2018.

VAN DER AALST, W. M. P.; BICHLER, M.; HEINZL, A. *Robotic process automation*. Bus Inf Syst Eng 60 (4). 2018.

What's the difference between "attended" and "unattended" RPA bots? LEIBOWITZ, S.; KAKHANDIKI, A. Disponível em: <<https://www.ibm.com/blogs/cloud-computing/2018/11/19/attended-unattended-rpa-bots>>. Acesso em 09 nov. 2021.

ANEXO I – Funcionalidades do UiPath Studio.

É a plataforma onde a automação é desenvolvida. O UiPath Studio é composto por três importantes partes: *Home*, *Design* e *Debug*.

A primeira, chamada de *Home*, como se pode ver na figura I.1, oferece opções de abrir automações novas ou já criadas, salvar o código, utilizar *templates* de desenvolvimento oferecida pela própria ferramenta, escolher preferencias da ferramenta, como por exemplo, o idioma dentre outras muitas especificações e configurações do UiPath Studio.

A aba *Home* também permite que o profissional consiga iniciar um novo projeto já com uma estrutura disponibilizada pela ferramenta. Além de instalar extensões de outras aplicações, como por exemplo, Chrome, Firefox, Edge, Java, Silverlight, Citrix, Windows Remote Desktop, VMware Horizon (UIPATH, 2021).

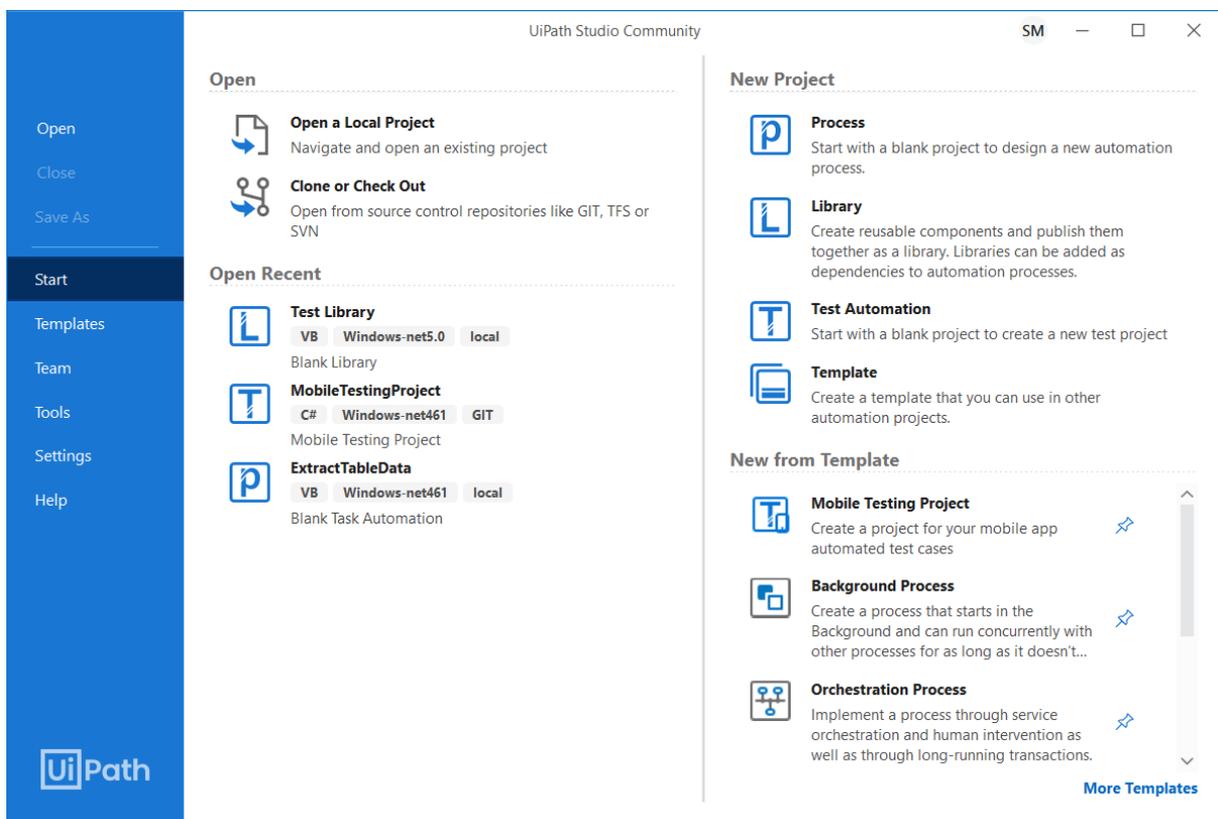


Figura I.1 – Aba Home do UiPath Studio.

Fonte: UiPath, 2021

A Segunda é a *Design*, local onde o *bot* é construído e é capaz de realizar gravações de passos para otimizar o desenvolvimento e também permite que o desenvolvedor configure de maneira customizada cada etapa (UIPATH, 2021).

A UiPath Studio possui uma interface moderna de fácil manuseio e de entendimento pois contém funcionalidades úteis, como o modo de pesquisa, alerta de erros e monitoramento de *bots*. (TAULLI, 2020).

Segundo Malathi (2021, p. 3) a UiPath Studio é uma ferramenta de designer que o profissional é capaz de transformar fluxos de trabalho em tarefas automatizadas. Contém várias atividades e bibliotecas predefinidas. Os usuários podem arrastar e soltar essas atividades a fim de modelar o *bot* que deseja desenvolver. Assim sendo, a UiPath Studio é uma plataforma que é utilizada para realizar a automação de processos repetitivos através da utilização de atividades e bibliotecas predefinidas.

A aba de *Design* conta com mais de uma dúzia de painéis e muitas funcionalidades em cada painel, como demonstrado na figura I.2 e descrito quadro I.1.

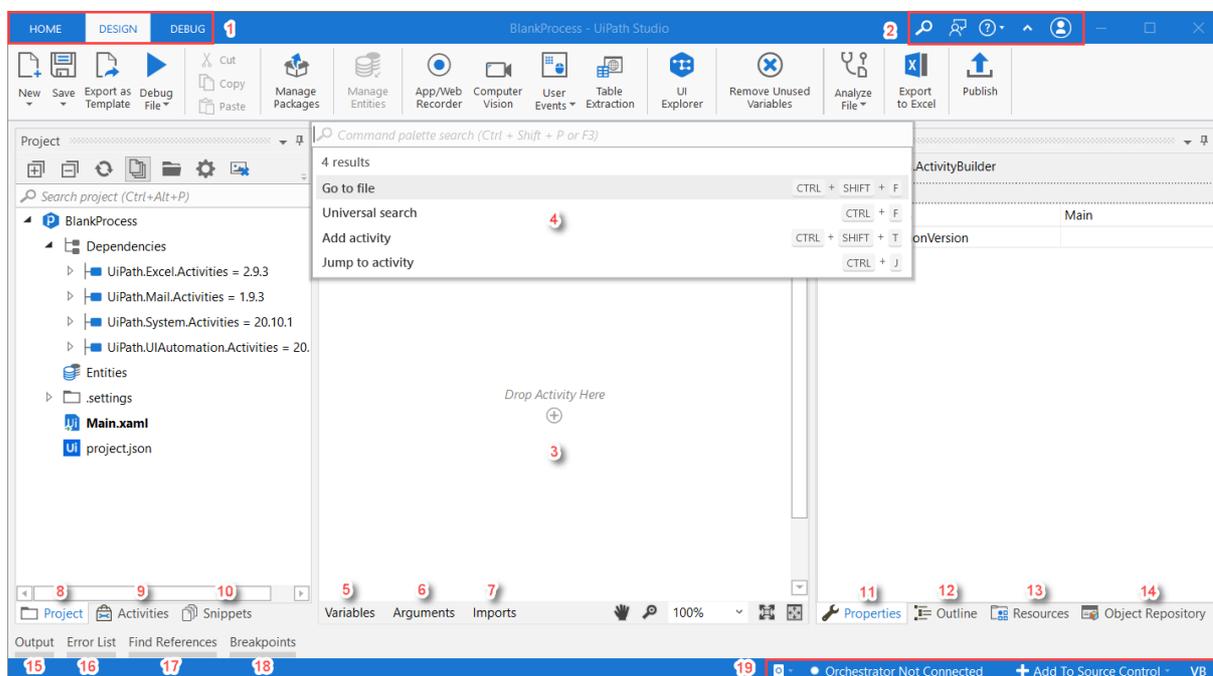


Figura I.2 – Aba *Design* do UiPath Studio.

Fonte: UiPath, 2021

Quadro I.1 – Descrição das funcionalidades da aba Design do UiPath Studio

Número	Nome	Descrição
1	Abas	<i>Home</i> - Local onde se pode abrir, criar projetos e configurar o UiPath Studio. <i>Design</i> – Local onde se constrói automações usando as ferramentas disponíveis na Paleta de Comandos e nos painéis do UiPath Studio. <i>Debug</i> - Contém um conjunto abrangente de ferramentas para depurar fluxos de trabalho.
2	Itens da barra de título	Abrir Paleta de comandos Enviar <i>feedback</i> . Acessar recursos de ajuda. Acessar conta.
3	Painel Designer	Construir automação gerenciando as atividades adicionadas ao arquivo atual de fluxo de trabalho.
4	Paleta de comandos	Pesquisar no projeto usando as barras de pesquisa disponíveis: Adicionar atividade Busca universal Vá para o arquivo Pular para a atividade
5	Painel de variáveis	Gerenciar variáveis.
6	Painel de argumentos	Gerenciar argumentos.
7	Painel de importação	Gerenciar arquivos de importação
8	Painel do projeto	Visualizar o conteúdo do projeto atual, gerenciar arquivos, pastas, dependências e ajustes das configurações do projeto.
9	Painel de atividades	Visualizar todas as atividades disponíveis e adicionar atividades à sua automação.
10	Painel de reutilização de códigos	Usar fluxos de trabalho predefinidos e adicionar às automações.
11	Painel de propriedades	Visualizar e configurar as propriedades de uma atividade específica.
12	Painel de esboço	Visualizar a hierarquia do fluxo de trabalho e todos os nós disponíveis.
13	Painel de recursos	Adicionar recursos como ativos, filas, processos e entidades do UiPath Orchestrator.
14	Painel de repositório de objetos	Criar e reutilizar taxonomias da interface do usuário dentro e entre projetos.
15	Painel de saída	Visualizar a saída através das atividades <i>Log message</i> e <i>Write Line</i> , informações de status sobre a execução do projeto, erros gerados por pacotes de atividades.
16	Painel de lista de erro	Visualizar todos os erros gerados ao executar o <i>Workflow Analyzer</i> .
17	Painel de referências	Visualizar todos os lugares onde um elemento é referenciado no projeto.
18	Painel de Pontos de Interrupção	Gerenciar pontos de interrupção adicionados ao projeto.
19	Barra de status	Visualizar informações de status e gerenciar a conexão do UiPath Orchestrator e a integração do controle de origem.

Fonte: Uipath, 2021

A solução disponibiliza centenas de ações pré-construídas, e isso auxilia na velocidade na qual os *bots* são desenvolvidos (TAULLI, 2020). UiPath Studio é fácil até mesmo para pessoas sem experiência com programação, visto que a solução é conhecida por ser *nocoding*⁵. Aprender uma nova linguagem de programação de computador pode não ser tão simples para qualquer pessoa, ou seja, algumas pessoas terão mais facilidade de aprendizado e outras menos. Porém, no aprendizado do RPA na plataforma de UiPath esse problema é reduzido, visto que não exige o conhecimento de linguagem de programação para desenvolver o código pelo fato de só ser necessário arrastar e soltar as atividades no painel de desenvolvimento (MALATHI, 2021). Apesar de conter funcionalidades de fácil utilização, o UiPath Studio também permite desenvolvimentos mais complexos e robustos, como por exemplo, a utilização de inteligência artificial, o que fazem os *bots* ganharem mais inteligência e não apenas repetir tarefas (RIBEIRO, 2021).

As *Activities*, por sua facilidade de utilização pelo fato de serem do método de arrastar e soltar, facilitam o desenvolvimento tanto das pessoas que desejam programar de maneira mais simples, sem utilizar código de programação, quanto para as que desejam utilizar. As *Activities* são funcionalidades nativas que já estão contempladas desde o *download* da ferramenta e já existem centenas de modelos de atividades e componentes prontos. É possível contar com *Activities* simples como *Click* e *Type into*, para clicar e escrever, respectivamente, como também, para automações mais sofisticadas, com *HTTP Request*, para realizar comunicação com API, e grupos de *Activities* que tornam possível que a automação se conecte com *Machine Learning*, *Chatbot* e inteligência artificial (UIPATH, 2021).

Por último, a terceira parte que compõe o UiPath Studio é chamada de *Debug*, onde é possível realizar a execução do *bot* e depurar o código da automação, em uma velocidade de execução mais lenta que o normal, a fim de encontrar erros ou realizar validações com o intuito de checar se a automação está corretamente desenvolvida e realizando o que se espera (UIPATH, 2021).

Como é possível visualizar na figura I.3, que mostra o *layout* desta aba, existem muitas funcionalidades, descritas no quadro I.2, que auxiliam e na descoberta de potenciais erros no código desenvolvido.

⁵ *Nocoding* significa, em termos gerais, uma programação sem código algum ou com pouco código.

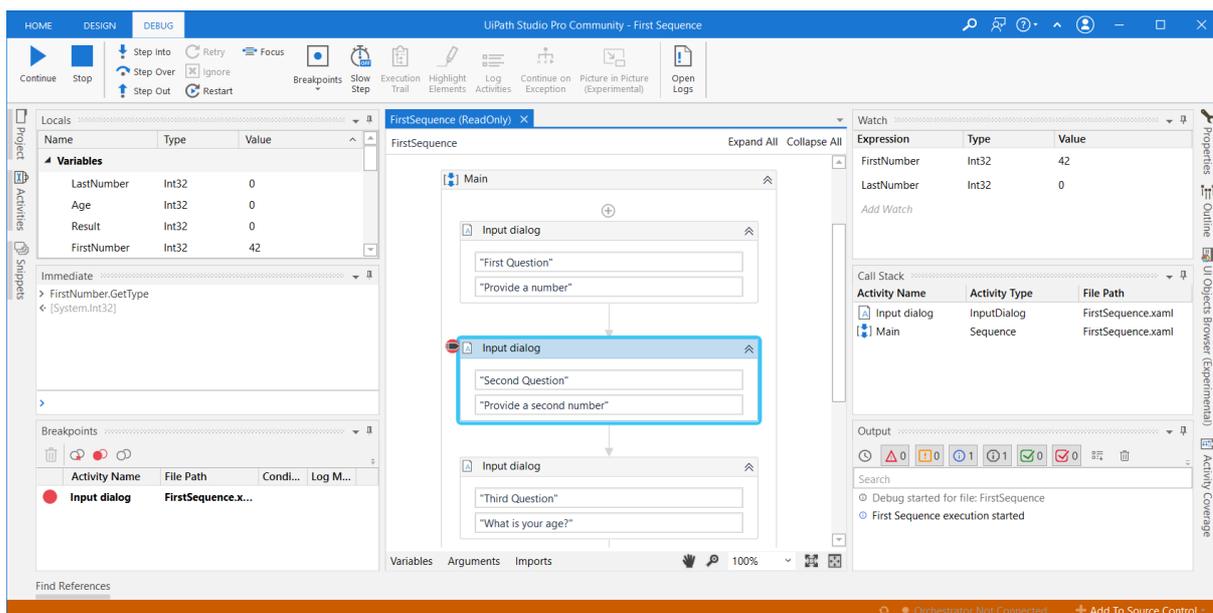


Figura I.3 – Aba Debug do UiPath Studio.

Fonte: UiPath, 2021

Quadro I.2 – Descrição das funcionalidades da aba Debug do UiPath Studio (continua)

Nome	Descrição
<i>Debug File</i>	Iniciar a depuração.
<i>Stop</i>	Parar a depuração.
<i>Step Into</i>	Depura atividade por atividade, sempre de maneira única.
<i>Step Over</i>	Depura um container, ou seja, um bloco de atividades. Caso esta opção for requerida em uma atividade única, o resultado será o mesmo do <i>Step Into</i>
<i>Step Out</i>	Sai de um container, ou seja, de um bloco de atividades.
<i>Retry</i>	Tenta executar a atividade anterior.
<i>Restart</i>	Reinicia a execução da depuração desde a primeira atividade. Esta opção fica habilitada quando uma exceção ocorre.
<i>Focus</i>	Destaca a atividade quando chega a um <i>Breakpoint</i> .
<i>Breakpoints</i>	Possibilita realizar um marco no código. A depuração é pausada cada vez que encontra um <i>breakpoint</i> .
<i>Slow Step</i>	Torna a depuração mais lenta. A velocidade de depuração varia de 1 a 4, onde 1 é a mais lenta e 4 a mais rápida.
<i>Execution Trail</i>	Informa o exato caminho que a automação está percorrendo durante a depuração.
<i>Highlight Elements</i>	Destaca as atividades durante toda a depuração.
<i>Log Activities</i>	Informa, através do Painel de saída, o log de execução da automação.
<i>Continue on Exception</i>	Quando habilitado, permite que a execução continue, mesmo em caso de erro.
<i>Picture in Picture</i>	Inicia a depuração em uma sessão de <i>Windows</i> diferente.
<i>Open Logs</i>	Abre a pasta onde os <i>logs</i> são armazenados na máquina.

Fonte: Guilherme Defanti, 2021