

## **Análise do market share e previsão de demanda de equipamentos importados para o mercado de saúde**

**Market share analysis and demand forecasting for the imported equipment to the healthcare market**

**Análisis del market share y previsión de demanda de equipos importados para el mercado de salud**

Recebido: 10/04/2022 | Revisado: 17/04/2022 | Aceito: 24/05/2022 | Publicado: 28/05/2022

**Reginaldo Pereira da Silva**

ORCID: <https://orcid.org/0000-0002-1040-0150>

Centro Paula Souza, Brasil

E-mail: [rpereir@bol.com.br](mailto:rpereir@bol.com.br)

**Napoleão Verardi Galeale**

ORCID: <https://orcid.org/0000-0003-2228-9151>

Centro Paula Souza, Brasil

E-mail: [nvg@galeale.com.br](mailto:nvg@galeale.com.br)

### **Resumo**

Entender o comportamento econômico de um mercado ou de um segmento específico requer inúmeros processos. Estes processos abrangem desde a captura de cada fonte de dados, as normatizações tecnológicas que percorrem o formato do dado de sua origem até sua consolidação, sua homogeneização e ainda o enriquecimento que possa transformá-lo em informação de mercado e aferir a demanda e níveis adequados de inventários. O presente trabalho tem por objetivo desenvolver um protótipo e apresentá-lo como uma aplicação com base em algoritmos de *machine learning*, que permita determinar o *market share* das indústrias de equipamentos importados para o mercado de saúde no Brasil e também melhorar a gestão da demanda e inventário destes sistemas produtivos. A natureza do objeto dessa pesquisa é de *Design Science Research* (DSR) para produzir o referido protótipo, que foi desenvolvido com base nos requisitos levantados por meio de um estudo de campo com empresas importadoras de equipamentos médico-hospitalares. A base de dados foi obtida por meio dos dados governamentais abertos (DGA) sobre importação de produtos, disponíveis no website da Receita Federal Brasileira. O protótipo apresentou como resultados: 90% de acurácia no cálculo de *market share*, e um fator R2 na regressão linear simples de 0,97 na previsão de demanda para um crescimento de mercado estimado de 50%.

**Palavras-chave:** Ensino; Equipamentos médico-hospitalares; Dados governamentais abertos; Market share; Machine learning; Data analytics; Sistemas produtivos.

### **Abstract**

Understand the market economic behaviors of a market or a specific segment requires innumerable processes, which goes from each source of data capture, technological standardization. From the data format on the origin to the consolidation itself, its homogenization and even in the enrichment that can transform it into market information, as well as gauge the demand and adequate levels of inventories. The current work aims to develop a prototype and present it as a computational solution based on Machine Learning algorithms, which allows determining the Market Share of the equipment industries imported to the health market in Brazil as well as improving demand management and inventory of these productive systems. The nature of the object of this research is Design Science Research (DSR) to produce the referred prototype, which was developed based on the requirements raised through a field study with companies that import hospital medical equipment. The database was obtained through open government data (DGA) on product imports, available on the website of the Brazilian government website, using Robotic Process Automation (RPA) resources. The prototype presented as results: 90% accuracy in the calculation of Market Share, and a R2 factor in the simple linear regression of 0.97 in the demand forecast, for an estimated market growth of 50%.

**Keywords:** Teaching; Medical products; Open government data; Market share; Machine learning; Data analytics; Productive systems.

### **Resumen**

Entender el comportamiento económico de un mercado o de un segmento específico se requiere inúmeros procesos. Estos procesos abarcan desde la captura de cada fuente de datos, las normalizaciones tecnológicas que van desde el formato del dato de su origen hasta su consolidación, su homogeneización y aún el enriquecimiento que pueda transformarlo en información de mercado y evaluar la demanda y niveles adecuados de inventarios. El presente trabajo tiene por objetivo desarrollar un prototipo y presentarlo como una aplicación con base en algoritmos de

*machine learning*, que permita determinar el *market share* de las industrias de equipos importados para el mercado de salud en Brasil y también mejorar la gestión de demanda e inventario de estos sistemas productivos. La naturaleza del objeto de esa pesquisa es de *Design Science Research* (DSR) para producir o referido prototipo, que fue desarrollado con base nos requisitos levantados por medio de uno estudio de campo con empresas importadoras de equipos médico hospitalario. La base de datos fue obtenida por medio dos datos gubernamentales abiertos (DGA) sobre importación de productos, disponibles no sitio de la Aduana Federal Brasileira. O prototipo presentó como resultados: 90% de exactitud no cálculo de *market share*, e u factor R2 na regresión linear simples de 0,97 na previsão de demanda para un crecimiento de mercado estimado de 50%.

**Palabras clave:** Enseñanza; Equipos medico-hospitalares; Datos Gubernamentales abiertos; Market share; Machine learning; Data analytics; Sistemas productivos.

## 1. Introdução

Diversos segmentos de mercado, onde se incluem também as indústrias de equipamentos para a saúde, têm crescido de forma exponencial, ano após ano, nos mercados emergentes, como o Brasil. O principal foco desse mercado tem sido a priorização da modernização por meio de tecnologias como o aprendizado de máquina (em inglês, *machine learning*), Robótica, Inteligência artificial, entre outras, como aponta um estudo da consultoria Deloitte (Global Healthcare Outlook, 2020).

Entender a participação de mercado (em inglês, *market share*) das empresas que comercializam equipamentos médicos no Brasil é fundamental para compreender o posicionamento dos concorrentes e com isso criar vantagens competitivas. Planejar de maneira mais assertiva a demanda e a necessidade de estoque desses equipamentos, de alto valor agregado, é fundamental para as empresas desse setor, além de um diferencial devido ao alto (*lead-time*) tempo de importação. Tendo como objetivo o ganho de *market share*, é necessário avaliar a relação dessa métrica com métricas de rentabilidade, já que os custos necessários para o aumento desse indicador podem ser altos a ponto de não compensar os investimentos (Kotler & Keller, 2012).

De maneira objetiva, a medida de *market share* representa a participação de uma empresa em relação aos seus concorrentes. Principalmente a partir de 1970, a medida passou a ter sua importância reconhecida e investigada em estudos acadêmicos, e tem se mostrado como uma métrica relevante também em estudos mais recentes (Bronnenberg et al., 2000); (Srinivasan et al., 2000).

A partir de então, os estudos têm buscado identificar a relação do *market share* com a métrica como satisfação e retenção de clientes (Rust & Zahorik, 1993), bem como os efeitos de decisões de marketing, como promoção, propaganda e distribuição no *market share* (Ataman et al., 2010); (Bronnenberg et al., 2000); (Srinivasan et al., 2000).

A participação de mercado dos equipamentos médico-hospitalares onde aproximadamente 75% dos produtos são importados (Associação Nacional de Hospitais Privados [ANAHP], 2015), pode ser calculada por meio dos dados de importação, disponibilizados pela RFB (Receita Federal Brasileira) em seu website. Esses dados são considerados dados governamentais abertos.

Diante do exposto, apresenta-se a questão de pesquisa: como, por meio de um protótipo de aplicação, baseada em *machine learning*, pode-se calcular o *market share* de equipamentos importados para o mercado de saúde brasileiro, visando melhorar a gestão de demanda e os níveis de inventário?

Dessa maneira, o objetivo desse artigo é como por meio da metodologia DSR, apresentar e desenvolver um protótipo de uma aplicação, baseada em *machine learning*, que permita determinar o *market share* das empresas de equipamentos médicos hospitalares importados para o mercado de saúde no Brasil.

## 2. Metodologia

O Referencial teórico foi elaborado por meio de pesquisas bibliométricas, e foram selecionados artigos relevantes, de acordo com o foco da pesquisa. Foi realizada a leitura de inúmeros resumos e foram selecionados os artigos alinhados com a linha de pesquisa do artigo, efetuando-se uma contribuição teórica nas áreas de mercado de saúde, dados governamentais abertos, *market share* e *machine learnig*, que são os temas principais do artigo, para criação do protótipo da aplicação, por meio da metodologia DSR (Design Science Research).

### 2.1 Mercado de equipamentos médico-hospitalares

Os equipamentos médico-hospitalares são essenciais para o diagnóstico, tratamento, prevenção e reabilitação da saúde, viabilizando a oferta de serviços de qualidade à vida do usuário, atentando às exigências da ANVISA no que diz respeito à qualidade e segurança (Brasil, 2016).

Os Estados Unidos concentram mais da metade (56,0%) dos produtores de dispositivos médicos. A Europa e o Japão também têm participação importante no mercado, ambos com 18,0% dos fabricantes, gerando um ambiente altamente dinâmico e competitivo, o que exige das empresas investimento na inovação (ANAHP, 2015). Nesse alinhamento reflexivo, as empresas brasileiras se encontram em maior nível de dificuldade, pois apresentam menos incentivo ao desenvolvimento tecnológico quando comparadas com as grandes empresas estrangeiras do setor. Esses fatores interferem no valor do produto, pois o material estrangeiro absorve grandes taxas tributárias, além de estar vinculado a fatores como a política da marca, concorrência e transparência no mercado (ANAHP, 2015).

### 2.2 Dados Governamentais Abertos

Dados governamentais abertos (DGA) ou governo aberto são termos utilizados mais recentemente para denominar a “disponibilização, por meio da internet, de informações e dados governamentais de domínio público para a livre utilização pela sociedade” (Agune et al., 2010). Este conceito remete à defesa dos dados públicos como pertencentes ao cidadão, que deveria ter acesso irrestrito às informações governamentais, é defendido por vários autores, como Laporte et al. (2000), Agune et al. (2010) e Diniz (2010).

Em 2007, um grupo de especialistas denominado OpenGovData desenvolveu os oito princípios dos dados governamentais abertos (OPEN GOV DATA, 2007). O Quadro 1 exibe os oito princípios que consideram os dados governamentais abertos.

**Quadro 1** – Oito princípios de dados governamentais abertos.

1. **Completo:** todos os dados públicos são disponibilizados. Dados públicos são dados que não estão sujeitos a limitações válidas de privacidade, segurança ou privilégio.
2. **Primário:** os dados são coletados na fonte, com o maior nível possível de granularidade, não em formas agregadas ou modificadas.
3. **Oportuno:** Os dados são disponibilizados o mais rápido possível para preservar o valor dos dados.
4. **Acessível:** os dados estão disponíveis para a maior variedade de usuários para a maior variedade de finalidades.
5. **Compreensíveis por máquina:** os dados são razoavelmente estruturados para permitir o processamento automatizado.
6. **Não discriminatório:** os dados estão disponíveis para qualquer pessoa, sem necessidade de registro.
7. **Não proprietário:** os dados estão disponíveis em um formato sobre o qual nenhuma entidade possui controle exclusivo.
8. **Livres de licença:** Os dados não estão sujeitos a nenhum regulamento de direitos autorais, patente, marca comercial ou segredo comercial. Restrições razoáveis de privacidade, segurança e privilégios podem ser permitidas.

Fonte: [https://public.resource.org/8\\_principles.html](https://public.resource.org/8_principles.html) adotado em dezembro de 2007.

### 2.3 Market share

Sobre o seu cálculo, *Market Share* é a porcentagem de um mercado que uma empresa, marca ou produto possui em relação aos seus concorrentes. Esse cálculo pode ter tanto a perspectiva de volume de vendas quanto de faturamento, ou valor, que uma empresa possui em relação aos seus concorrentes em um mercado ou segmento específico (Farris, Bendle, Pfeifer & Reibstein, 2006).

De acordo com Kotler e Keller (2012), as grandes empresas, cada vez mais, não se limitam a analisar apenas a receita de vendas, passando a examinar também indicadores de participação de mercado. Além de estimar o potencial total e o potencial da área, é importante conhecer as vendas que ocorrem em seu mercado, identificando e monitorando o desempenho dos concorrentes.

Ademais, outra forma de se conseguir dados, é por meio da compra dessa informação por empresas especializadas, ou, no caso de nosso protótipo, por meio de dados disponibilizados pelo governo (Kotler & Keller, 2012).

Com isso, define-se então o Market Share como a porcentagem de um mercado que uma empresa, marca ou produto possui em relação aos seus concorrentes. Esse cálculo pode ter tanto a perspectiva de volume de vendas quanto de faturamento, ou valor, que uma empresa possui em relação aos seus concorrentes em um mercado ou segmento específico, conforme apresentado na Equação 1 (Farris et al., 2006). Assim,

$$\text{Market Share Volume (\%)} = \frac{\text{Vendas da Empresa para um produto ou marca (\#)}}{\text{Total de vendas da categoria do produto ou marca (\#)}} \quad (1)$$

E o respectivo cálculo em faturamento é dado pela Equação 2:

$$\text{Market Share Valor (\%)} = \frac{\text{Vendas da Empresa para um produto ou marca (\$)}}{\text{Total de vendas da categoria do produto ou marca (\$)}} \quad (2)$$

### 2.4 Machine Learning (ML)

Segundo Hurwitz e Kirsch (2018), *Machine Learning* tornou-se um dos tópicos mais importantes nas organizações de desenvolvimento que procuram maneiras inovadoras de alavancar ativos de dados para ajudar a empresa a obter um novo nível de entendimento. Com os modelos apropriados de *machine learning*, as organizações têm a capacidade de prever continuamente as mudanças nos negócios, para que possam ter uma previsão do que virá a seguir. Como os dados são constantemente adicionados, os modelos de *machine learning* garantem que a solução seja atualizada constantemente. O valor é claro e evidente: se você usar as fontes de dados mais apropriadas e em constante mudança no contexto do *machine learning*, terá a oportunidade de prever o futuro.

Para Witten e Frank (2005), *machine learning* tem a preocupação em formular modelos que podem ser generalizados, com intuito de responder questões a partir de possíveis hipóteses. O início do *machine learning* foi reconhecido nos trabalhos pioneiros de quatro estatísticos (Breiman, Friedman, Olshen & Stone, 1984), que publicaram um livro sobre “*classification and regression trees*” em meados de 1980, e ao longo dos anos 1970 e 1980, um pesquisador de *machine learning*, J. Ross, estava desenvolvendo um sistema para inferir árvores de classificação por meio de exemplos.

A Figura 1 apresenta o típico ciclo de *machine learning*, alinhado com as questões de algoritmos que podem aprender e fazer predição de dados. O ciclo é composto por 3 fases:

a) Detecção: nessa fase os dados são coletados de diferentes maneiras, uma vez que atualmente existem várias formas nas quais os dados podem ser capturados e armazenados. Esses dados serão utilizados como fonte para treinamento dos algoritmos de *machine learning*.

b) Processamento: segunda fase do ciclo, aqui os dados são agregados, harmonizados, enriquecidos, para em seguida possam ser processados pelo algoritmo de *machine learning*.

c) Aprendizado: nessa última fase do ciclo, padrões e tendências são revelados, gerando *insights*. Também são avaliados os resultados, possivelmente com ajuda humana ou não, dependendo do método de aprendizagem, para que sejam adaptados e melhorados os algoritmos.

**Figura 1** – O típico ciclo de *Machine Learning* (ML).



Fonte: Statista – Tendências Globais 2019, adaptado pelos autores.

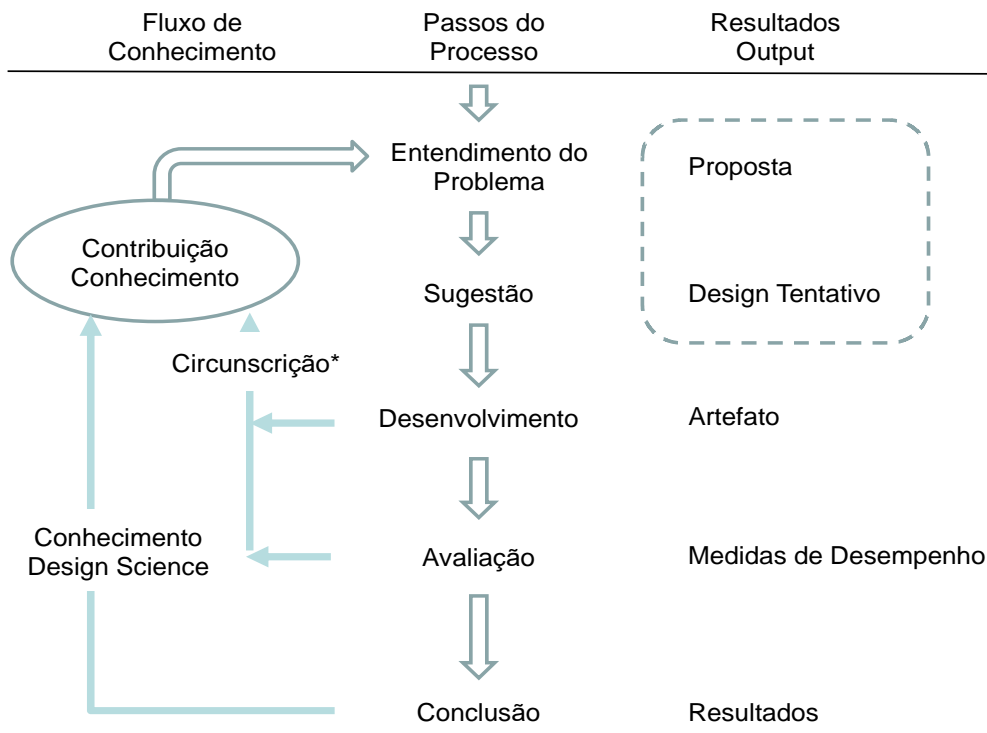
### 3. Metodologia

A metodologia de pesquisa em *Design Science Research* (DSR) foi escolhida para orientar esse trabalho de pesquisa. O DSR fornece um modelo de processo para pesquisa em sistemas de informação (SI) e outras disciplinas de recursos aplicados, bem como um modelo mental para os revisores avaliarem os pesquisadores, segundo Peffers, Tuunanen, Rothenberger e Chatterjee (2007).

O principal objetivo do DSR na pesquisa de SI é produzir e avaliar um artefato de TI que suporte a solução para um problema organizacional identificado, de acordo com Hevner (2004). A pesquisa em DSR geralmente envolve a criação de um artefato e/ou a teoria do design como um meio para melhorar o estado atual da prática, bem como o conhecimento de pesquisa existente (Baskerville et al., 2018).

Um modelo de processo geral é seguido por uma pesquisa em DSR, como se observa no modelo descrito na Figura 2. Esse modelo é uma adaptação de um modelo de design de processo computacional desenvolvido por Takeda et al. (1990).

**Figura 2** – Modelo de Processo de Pesquisa em Design Science (*DSR-Design Science Research*).



\*Circunscrição é a descoberta do conhecimento restritivo sobre as teorias obtidas através da detecção e análise de contradições quando as coisas não funcionam de acordo com a teoria (McCarthy, 1980).

Fonte: Adaptado pelos autores (*Design Science in Information Systems*).

De acordo com a metodologia de pesquisa *Design Science*, elaborou-se a Quadro 2, com os elementos propostos para o desenvolvimento do protótipo apresentado nesse artigo.

**Quadro 2** – Dados do desenvolvimento do protótipo utilizando DSR.

1	<b>Entendimento do Problema e Motivação</b>	Melhorar a gestão de Demanda e planejamento de inventários de equipamentos médico-hospitalares, com base em informações do mercado, <i>market share</i> e projeções de ganho e aumento de mercado.
2	<b>Sugestão e definições dos objetivos para a solução</b>	Propor o desenvolvimento de um protótipo de aplicação que, por meio dos dados de mercado, <i>market share</i> obtido pelo processamento dos dados de equipamentos importados, demanda e níveis de inventários, possa calcular os níveis de inventários e de equipamentos que devem ser importados, derivado de uma estratégia de simulação de crescimento e ganho de mercado.
3	<b>Desenvolvimento e desenho da solução</b>	Desenvolver um protótipo de solução computacional, utilizando linguagens de programação Java/HTML5 e algoritmos de <i>Machine Learning</i> (ML) de bibliotecas <i>Python</i> , capaz de importar os dados de equipamentos importados (disponibilizados mensalmente pela RFB), e por meio de palavras-chaves e NCM, possa identificar os itens desejados e calcular o % de mercado de cada fabricante. Em seguida, com os dados de demanda e inventário, e utilizando projeções de crescimento, bem como os algoritmos de ML de regressão linear simples, propor o nível ideal de inventário para esses produtos, para que não haja falta, tão pouco excessos.
4	<b>Avaliação</b>	Submeter a aplicação para validação dos dados de uma empresa de equipamentos médico-hospitalares e avaliar os resultados de acordo com as projeções propostas nos testes sobre <i>Market Share</i> e inventário. Posteriormente ao período de testes, efetuar uma entrevista semiestruturada com usuários chaves, para avaliar a usabilidade, facilidade e níveis de satisfação com a solução implementada, bem como identificar oportunidades de melhoria.
5	<b>Conclusão e Comunicação</b>	Protótipo de uma solução computacional para que possa ser introduzida no mercado, mesmo que ainda com oportunidades de melhorias.  Elaboração de artigo científico a ser apresentado em Congressos da área e submetido para publicação em periódico.

Fonte: Elaborado pelos autores.

#### 4. Resultados e Discussão

O protótipo desenvolvido, por meio da metodologia DSR, permite que o usuário selecione o período que deseja analisar, em seguida a linha de produtos, bem como a comparação entre os fabricantes/concorrentes. Com os parâmetros definidos, a solução exibirá graficamente a participação de mercado de cada fornecedor em quantidades e unidade monetária (dólar).

Uma vez que esses dados sejam apresentados, será solicitado que o usuário da plataforma indique um percentual de crescimento de mercado, e, baseado nesse parâmetro, na base inferior da tela será exibida uma série temporal com a demanda e inventários sugeridos para esse produto com mais um ano de visibilidade. E no quadrante ao lado serão exibidos os padrões/anomalias identificadas na série temporal por meio do algoritmo de *Machine Learning*, como mostra a Figura 4.

O protótipo está baseado nos dados de importação dos equipamentos médico-hospitalares, disponibilizados mensalmente no website da RFB. Os dados são disponibilizados em formato digital, mensalmente, e separados por NCM. Atualmente esses dados necessitam ser descarregados manualmente e será dessa forma, no protótipo, porém já estamos trabalhando em uma funcionalidade futura que irá buscar os arquivos automaticamente assim que estiverem disponíveis, utilizando de recursos de RPA (Robotic Process Automation).

Depois que os arquivos são baixados e armazenados, são tratados, estruturados e transferidos para tabelas em um banco de dados para que possam ser processados. Esse processo é feito por meio de scripts e instruções de banco de dados SQL.

Em seguida os dados são transformados por meio de palavras chaves hierarquizadas, as quais serão constantemente enriquecidas através de algoritmos de *machine learning* (ML) que irão determinar informações cruciais para as análises de participação do mercado.

São aplicados conceitos de *big data analytics*, também por meio de instruções SQL, para apresentação de *dashboards* executivos de posicionamento e participação de mercado, que auxiliarão nas tomadas de decisões.

Uma vez identificada a participação de mercado de um determinado produto, a plataforma oferecerá a possibilidade de simulação de crescimento de mercado, aumentando a demanda e irá sugerir o nível ideal de inventário utilizando o método de regressão linear, proporcionando ao time de *Supply Chain insights* para o planejamento dos produtos importados. Finalmente, todas as informações serão utilizadas e disponibilizadas através de ferramentas de *data analytics*. A Figura 3 mostra os passos, desde a obtenção dos dados primários, a transformação, processamento e enriquecimento dos dados, até a disponibilização para visualização.



**Figura 3** – Fases dos Processos e Tecnologias da Solução Computacional.



Fonte: Resultado da pesquisa.

Passo 1: nesse passo é efetuada a busca dos dados da RFB, por meio de ferramentas de RPA, que serão detalhadas na seção de componentes da solução computacional. Uma vez que os dados são obtidos, são armazenados em uma pasta do servidor para que sejam processados pela aplicação.

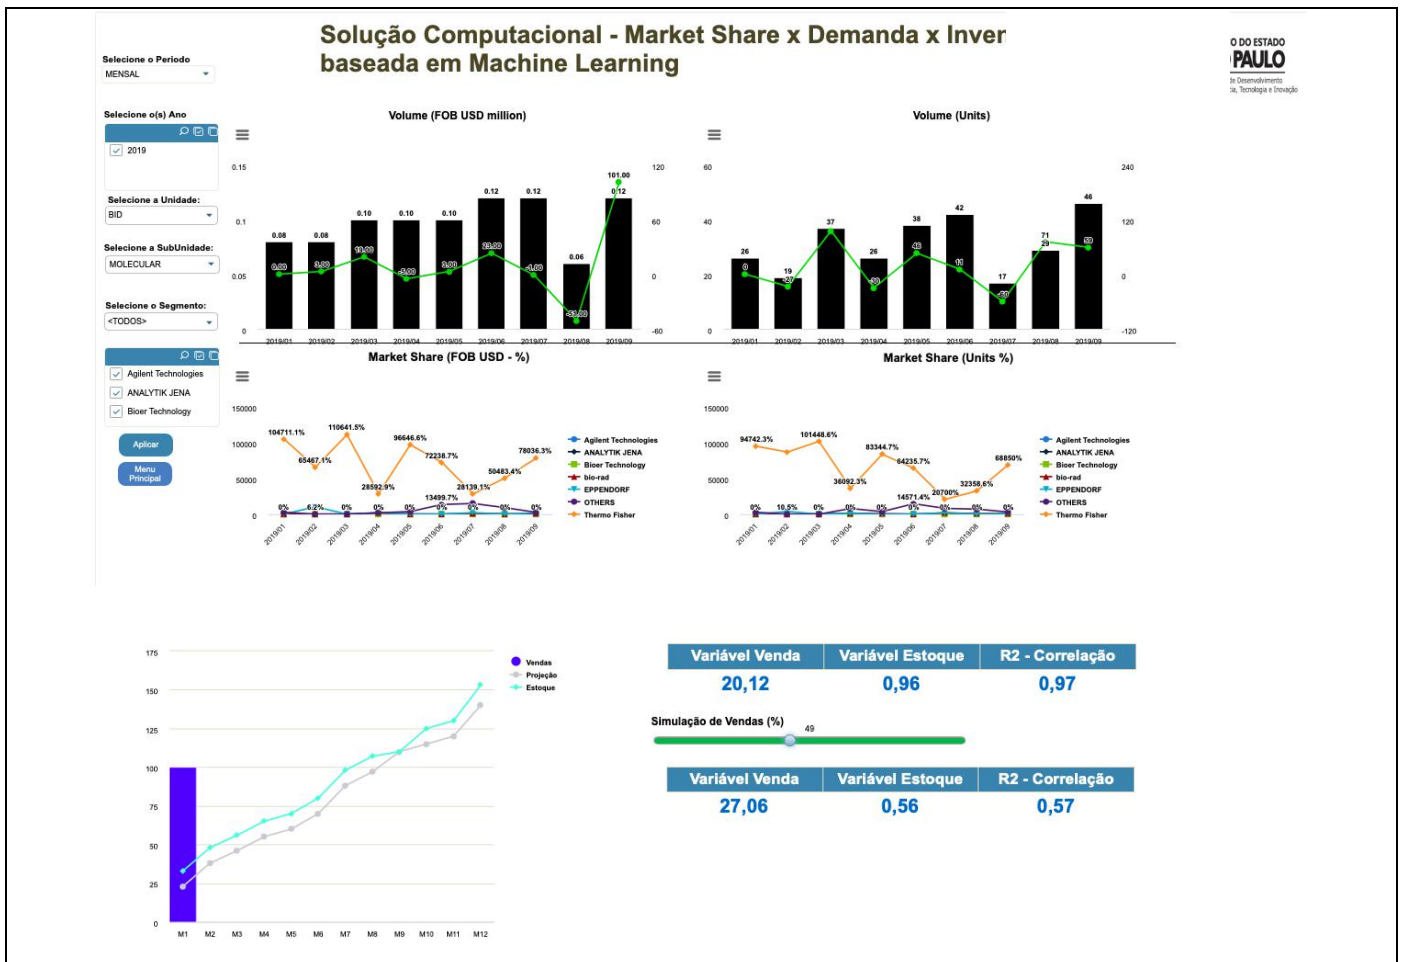
Passo 2: nesse passo, por meio de uma ferramenta open-source de ETL (Pentaho), que também será detalhada na próxima seção, os dados são transformados de acordo com as regras de negócios estabelecidas e armazenados nas tabelas de banco de dados da solução computacional.

Passo 3: nesse passo, por meio de algoritmos de machine learning de classificação, as palavras chaves são enriquecidas, para que possam ser identificados corretamente os equipamentos e seus fabricantes correspondentes.

Passo 4: nesse passo, instruções SQL e regras de big data analytics, serão apresentados dashboards executivos, referentes ao posicionamento de mercado de cada fabricante e equipamentos importados. Dessa maneira, nesse passo também é possível ao executivo simular um crescimento de mercado, e por meio de algoritmos de machine learning de regressão linear simples, é possível determinar os níveis ideais de inventários de acordo com a demanda projetada.



Figura 4 – Demonstração da Solução Computacional.



Fonte: Resultado da pesquisa.

O protótipo foi desenvolvido utilizando códigos em JAVA, HTML5 e instruções SQL, *Structured Query Language*, Linguagem de Consulta Estruturada ou SQL, que é a linguagem de pesquisa declarativa padrão para banco de dados relacional (base de dados relacional). Os dados brutos foram obtidos através do website da Receita Federal Brasileira, onde são publicados mensalmente. Para acessar os dados, basta acessar o seguinte endereço do website da RFB: <http://receita.economia.gov.br/dados/resultados/comercio-exterior>. O período utilizado foi de janeiro a outubro de 2019.

Para o cálculo de regressão linear simples, para obter os níveis ideais de inventário, baseado em uma série histórica, vamos utilizar a biblioteca de *machine learning* da linguagem de programação *Python*, conhecida como *Scikit-learn*. Por meio dela, pode-se implementar várias funções de regressão.

O protótipo foi avaliado de duas formas: quanto à acurácia dos resultados e quanto à usabilidade e utilidade.

Com relação aos resultados, o protótipo demonstrou uma acurácia de 90% no cálculo do *market share*. Esse resultado foi obtido por meio dos registros de importações da empresa fabricante, que testou a solução, e foram comparados com os dados disponibilizados pelos dados da RFB.

Com relação à usabilidade e utilidade, foi realizada uma avaliação com 3 usuários chaves do protótipo, buscando avaliar as funcionalidades/características principais do protótipo. O Quadro 3 exibe um resumo das avaliações efetuadas e os resultados obtidos:

**Quadro 3** – Avaliação das usuárias chaves do protótipo.

Função	Formação	Tempo de Experiência (em anos)	Tempo de Empresa (em anos)	Funcionalidade/Características	1 - Atende Totalmente 2 – Atende Parcialmente 3 – Não Atende
<b>Sales Operations Manager</b>	Gestão estratégica de vendas	+20	+15	Cálculo do <i>Market Share</i>	1
				Projeção de crescimento e demanda	1
				Níveis de inventários	2
				Usabilidade	1
				Facilidade	2
<b>Marketing Developer Manager</b>	Biologia aplicada a saúde	+15	+8	Cálculo do <i>Market Share</i>	1
				Projeção de crescimento e demanda	1
				Níveis de inventários	2
				Usabilidade	1
				Facilidade	1
<b>Strategic &amp; Innovation Manager</b>	Adm. negócios	+10	+3	Cálculo do <i>Market Share</i>	1
				Projeção de crescimento e demanda	1
				Níveis de inventários	2
				Usabilidade	1
				Facilidade	2

Fonte: Resultado da Pesquisa.

## 5. Conclusão

Essa pesquisa teve como objetivo principal o desenvolvimento de um protótipo de solução computacional para calcular o *market share* de empresas importadoras de equipamentos médico-hospitalares, bem como calcular a demanda de equipamentos com base em simulações de crescimento de mercado.

O mercado de saúde foi o escolhido em virtude da relevância devido ao crescimento exponencial nos últimos anos e sua representatividade no PIB (Produto Interno Bruto) do Brasil.

Segundo a ANAHP (2020), as despesas com saúde no Brasil em 2018 foram da ordem de R\$ 637 bilhões, correspondendo a 9,3% do PIB. Essa estimativa foi calculada com base nos dados da Secretaria do Tesouro Nacional, OMS e ANS. Estão disponíveis no website da ANAHP e podem ser acessados pelo endereço: <https://www.anahp.com.br/dados-do-setor/>.

O protótipo foi implementado em uma das unidades importadoras de uma empresa de equipamentos médico-hospitalares e o resultado foi considerado satisfatório, por meio de uma pesquisa com o usuário chave, com respeito às funcionalidades, facilidade de utilização e interpretação dos dados que foram validados pela área de marketing.

Diante desse cenário positivo o protótipo será convertido em um produto comercial e uma empresa será constituída para a comercialização.

**Limitações:** O foco da pesquisa para construção do protótipo foi baseado nas informações de equipamentos importados para o mercado de saúde brasileiro. Existe a possibilidade de estender a pesquisa para outros tipos de produtos importados, bem como para outros países que mantêm dados governamentais abertos.

**Trabalho Futuro:** O protótipo da solução computacional está baseado nos dados da Receita Federal do Brasil (RFB), e poderá ser base para estudos futuros, onde a solução poderá ser expandida para outros países da América Latina, como: Chile e México, entre outros, que mantêm dados governamentais abertos.

## Referências

- Agune, R. M., Gregorio Filho, A. S., Bolliger, S. P (2010). Governo aberto SP: disponibilização de bases de dados e informações em formato aberto. In: Congresso Consad de Gestão Pública, III, Brasília.
- ANAHP. Observatório ANAHP. São Paulo, SP (2015). [http://www.anahp.com.br/files/observatorio\\_anahp\\_2015\\_miolo\\_210x297\\_web.pdf](http://www.anahp.com.br/files/observatorio_anahp_2015_miolo_210x297_web.pdf).
- ANAHP. Observatório ANAHP. São Paulo, SP (2020). <https://www.anahp.com.br/dados-do-setor/>.
- Ataman, M. B, Heerde, H. J. van, Mela, C. F. (2010). The long-term effect of marketing on brand sales. *Journal of Marketing Research*, 47(5), pp. 866-882.
- Baskerville, R., Baiyere, A., Gregor, S., Hevner, A. & Rossi, M. (2018). Design Science Research Contributions: Finding a Balance between Artifact and Theory. *Journal of the Association for Information Systems*, 19(5), pp. 358-376.
- BRASIL. Agência Nacional de Vigilância Sanitária – ANVISA (2016). Portaria no 2.043, de 12 de dezembro de 1994 e Portaria SVS no 686, de 27 de agosto de 1998. Conceitos técnicos, produtos para área da saúde. Inciso IV do Art. 3o, Decreto no 79.094, de 5 de janeiro de 1997. <http://portal.anvisa.gov.br/wps/content/Anvisa+Portal/Anvisa/Inicio/Produtos+para+Saude>.
- Breiman, Leo, Friedman, J.H., Olshen, R.A. e Stone, C.J. (1984). Classification of regression trees. Wadsworth & Books /Cole Advanced Books & Software, Monterey, CA.
- Bronnenberg, B. J.; Mahajan, V. & Vanhonacker, W. R. (2000). The emergence of market structure in new repeat-purchase categories: the in-terplay of Market Share and retailer distribution. *Journal of Marketing Research*, 37(1), pp. 16-31.
- Deloitte. Global Healthcare Outlook (2020). Laying a foundation for the future. Dr. Stephanie Allen. <https://www2.deloitte.com/global/en/pages/life-sciences-and-healthcare/articles/global-health-care-sector-outlook.html>.
- Diniz, V. (2010). Como conseguir dados governamentais abertos. In: CONGRESSO CONSAD DE GESTÃO PÚBLICA, III, Brasília.
- Farris, P. W; Olver, J. & Kluyver, C. (1989). The relationship between distribution and Market Share. *Marketing Science*, 8(2), pp. 107-128.
- Farris, P. W, Bendle, N. T, Pfeifer, P. E, & Reibstein, D. J. (2006). Marketing metrics 50+ metrics every executive should master. Upper Saddle River, NJ: Wharton School.
- Gill, T. G. & Hevner, A. R. (2013). A Fitness-Utility Model for Design Science Research. *ACM Transactions on Management Information Systems* 4(2), p. 5.
- Hevner, A. R., March, S. T., Park, J. and Ram, S. (2004). Design Science in Information Systems Research. *MIS Q.*, vol. 28, no. 1, pp. 75–105.
- Hurwitz, J., & Kirsch, D. (2018). *Machine Learning For Dummies®*, IBM Limited Edition. NJ, Published by John Wiley & Sons, Inc, pp. 3-20.
- Kohavi, Ron e Povost, Foster. (1998). Glossary of terms: Machine Learning 30. Disponível em: <http://bit.ly/2CIYKNC>.
- Kotler, P, Keller, K. (2012) Administração de marketing. 14a Edição. São Paulo: Pearson Education do Brasil.
- Laporte, T., Demchak, C., Friis, C. (2000). Webbing governance: national differences in constructing the face of public organizations. In: GARSON, G. Handbook of public information systems. New York: Marcel Dekker Publishers.
- March, S. & Smith, G. (1995). Design and Natural Science Research on Information Technology. *Decision Support Systems* 15, pp. 251-266.
- McCarthy, J. (1980). Circumscription—A Form of Non-Monotonic Reasoning. *Artificial Intelligence* 13(1–2), pp. 27–39.
- OPEN GOV DATA. (2007). Eight principles of open government data. [https://public.resource.org/8\\_principles.html](https://public.resource.org/8_principles.html).
- Peppers, K., Tuunanen, T., Rothenberger, M. A. and Chatterjee, S. A (2007). Design Science Research Methodology for Information Systems Research, *J. Manag. Inf. Syst.*, vol. 24, no. 3, pp. 45–77.
- RECEITA FEDERAL (2017). Disponível em: < <http://idg.receita.fazenda.gov.br/>>. Acessado em 04 de outubro de 2017.
- Rust, R. T. & Zahorik, A. J. (1993). Customer satisfaction, customer retention, and Market Share. *Journal of Retailing*, 69(2), pp. 193-215.

Srinivasan, S., Leszczyc, P. T. L. & Bass, F. M. (2000). Market Share response and competitive interaction: the impact of temporary, evolving and structural changes in prices. *International Journal of Research in Marketing*, 17(4), pp. 281-305.

Takeda, H., Veerkamp, P., Tomiyama, T. and Yoshikawam, H. (1990). Modeling Design Processes. *AI Magazine Winter*, pp. 37-48.

Witten, Ian H. e Frank, Eibe. (2005). *Data mining: practical machine learning tools and techniques*. Elsevier, pp. 29.