

# O uso de algoritmos de classificação para determinar estoques de segurança

Felipe Norato Sanches <sup>a</sup> e Celso Ap. de França <sup>b</sup>

*Departamento de Engenharia Elétrica da Universidade Federal de São Carlos*

**Resumo** – Este trabalho analisa a aplicação de diferentes algoritmos de Redes Neurais Artificiais com o objetivo de classificar produtos candidatos à parametrização de estoque de segurança baseado no histórico de compra desses produtos. O estudo traz discussões sobre a importância da qualidade dos dados tratados e a importância da análise do problema, dos objetivos e do equilíbrio entre o nível de serviço ao cliente, ou seja, o tempo esperado de execução, e o custo de estoque. Foram estudados os algoritmos de K-médias, propagação por afinidade, deslocamento médio e agrupamento hierárquico, que engloba os métodos Ward e de ligação completa. Através da aplicação desses algoritmos, foi possível gerar gráficos de distribuição de pontos classificados e calcular a correlação dos grupos encontrados pelos diferentes algoritmos. Para o problema apresentado, foi determinado um valor de número ótimo de grupos para uma melhor classificação dos produtos. Os algoritmos que apresentaram a maior correlação foram os algoritmos de K-médias e Ward, que proporcionaram uma classificação eficiente dos dados em 3 grupos.

**Palavras-Chave** – agrupamento hierárquico, classificação, deslocamento médio, estoque de segurança, K-médias, ligação completa, método Ward, propagação por afinidade, redes neurais.

## 1. INTRODUÇÃO

Para uma organização, a otimização do fluxo de materiais é de vital importância, pois os estoques representam grande parte dos seus custos logísticos. Através da gestão apropriada de inventários, a empresa terá uma melhor visão de como se encontra seu fluxo financeiro, uma vez que a manutenção de estoques retém o capital de giro da empresa, enquanto que o controle do estoques deve permitir a redução de investimentos [1].

A determinação do estoque de segurança é um importante pilar para a gestão do estoque. O estoque de segurança, também chamado de estoque mínimo, por definição, é a quantidade mínima que deve existir em estoque, que se destina a cobrir eventuais atrasos no ressurgimento, com o objetivo de garantir o funcionamento ininterrupto e eficiente do processo produtivo, sem o risco de falta de insumos [2].

Existem diversos estudos, desde que as linhas de produção surgiram, sobre como determinar quais materiais devem ser classificados com estoque de segurança e a quantidade de estoque mínimo necessário. Muitos desses cálculos são relacionados a dados estatísticos.

Nos dias atuais, com uma evolução global da digitalização e indústria 4.0, existe uma ferramenta que pode trazer inúmeras possibilidades para tratar dados estatísticos, que é a inteligência artificial.

O principal objetivo deste trabalho é trazer uma visão dos estudos existentes sobre como promover uma melhor estimativa de estoques de segurança utilizando inteligência artificial para tratar dados históricos e realizar previsão de demandas, com o intuito de manter a satisfação do cliente enquanto se reduz o custo relacionado ao estoque. Para atingir este objetivo, as questões abaixo serão analisadas para melhorar a contextualização e os desafios deste assunto.

Verificar se é possível analisar múltiplas variáveis logísticas para melhorar a detecção de padrões de riscos existentes em uma cadeia de suprimentos, para entender quais são os componentes, processos e suprimentos mais críticos para as organizações, possibilitando uma identificação generalizada das ameaças potenciais e vulnerabilidades relevantes. Entender como a aprendizagem não supervisionada pode ser uma ferramenta útil para encontrar relações estatísticas e oportunidades. Através de algoritmos de classificação, determinar possíveis candidatos a estoque de segurança.

Este tema foi idealizado e proposto pelo autor devido à sua experiência no mercado de trabalho no setor de pós-vendas, mais especificamente em um centro de reparos de equipamentos industriais. A rotina deste ambiente de trabalho consiste em atender clientes que têm seus processos impactados devido a falhas inesperadas em determinados equipamentos, afetando a linha de produção e gerando prejuízos. A maioria dos clientes possuem peças sobressalentes para contornar estes eventos, mas ainda estão sujeitos à parada total. Nestes casos, a manutenção ou substituição do equipamento danificado deve ser realizada da maneira mais rápida possível. Do ponto de vista de uma oficina de reparos, a manutenção de equipamentos que causam parada de produção é priorizada, porém, existe a dependência de peças de reparos em estoque. Dessa forma, possuir gestão eficiente desse estoque de segurança de peças críticas é essencial para satisfazer as necessidades dos clientes. Porém, é preciso atentar-se ao custo que esse estoque pode gerar para a área.

Baseado neste problema cotidiano, surgiu o interesse na pesquisa para o entendimento de como esse assunto é tratado globalmente e como ferramentas atuais, como a inteligência artificial, são empregadas para trazer benefícios ao processo.

## 2. TRABALHOS RELACIONADOS

Existem muitos trabalhos publicados que destacam a importância da acuracidade do cálculo de estoque de segurança no gerenciamento de inventário e planejamento da cadeia de suprimentos, e esses trabalhos discutem diferentes metodologias para resolver este problema. Enquanto alguns artigos propõem novos métodos ou modelos, outros focam na implementação de técnicas já existentes e buscam detalhar a literatura existente.

Doraiswamy *et al.* [3] apresenta uma revisão dos principais modelos e métodos de pesquisa operacional para determinação de estoque de segurança. O artigo apresenta os principais tipos de incerteza que afetam a gestão de estoques, como demanda incerta e prazo de entrega incerto, e discute a importância da determinação correta do estoque de segurança para minimizar o custo total de estoque e garantir o atendimento ao cliente.

<sup>a</sup> E-mail autor: felipens@estudante.ufscar.br

<sup>b</sup> E-mail orientador: celsofr@ufscar.br

Diferentes modelos são apresentados, desde os mais simples até os mais avançados, como o modelo de demanda incerta. A integração de diferentes modelos e métodos para determinação de estoque de segurança e o uso de dados precisos e confiáveis para a tomada de decisões são destacados como elementos importantes para uma gestão de estoque eficiente.

Fernandes *et al.* [4] apresentam uma análise de diferentes estratégias de aprendizado de máquina para aprimorar a estimativa de estoque de segurança na cadeia de suprimentos. O artigo reafirma, assim como Doraiswamy *et al.* [3], a importância do estoque de segurança na gestão de estoques e os desafios enfrentados para estimar corretamente o nível necessário de estoque de segurança. É discutido então a aplicação de modelos de aprendizado de máquina para previsão de demanda na cadeia de suprimentos. Esses modelos incluem regressão linear, árvores de decisão, redes neurais e algoritmos de séries temporais, entre outros, apresentando as vantagens e desvantagens de cada modelo, destacando a importância de escolher o modelo correto para cada situação.

Os autores [4] concluem que o modelo de árvore de decisão é mais adequado para dados com várias variáveis e pode ser usado para entender a importância relativa de cada variável na previsão de demanda. O modelo de rede neural, por outro lado, é mais adequado para previsão de demanda de séries temporais com padrões complexos. O modelo de regressão linear é simples e rápido, mas pode não ser adequado para dados com alta variabilidade.

Também, em [4], Fernandes *et al.* discutem a importância da integração de diferentes fontes de dados na previsão de demanda, como dados históricos de vendas, dados de marketing e dados meteorológicos. A integração desses dados pode melhorar a precisão de previsão da demanda e, conseqüentemente, melhorar a estimativa de estoque de segurança.

Além disso, é apresentado pelos autores [4] um estudo de caso em que diferentes modelos de aprendizado de máquina foram aplicados para previsão de demanda em uma empresa de varejo. Os resultados mostraram que a utilização de modelos de aprendizado de máquina pode melhorar significativamente a precisão da previsão e da determinação do estoque de segurança.

O artigo [4] ressalta que a aplicação de modelos de aprendizado de máquina requer um conhecimento sólido em programação e análise de dados, e que a qualidade dos dados é fundamental para a precisão da previsão de demanda e da estimativa de estoque de segurança.

O trabalho de Varkalys [5] busca reduzir a quantidade de taxas que são pagas a fornecedores através de pedidos de produtos. A melhoria de processo proposta por Varkalys utiliza algoritmos de aprendizado de máquina para prever níveis mínimos e máximos de estoque. O autor testa diversos algoritmos, como Regressão de Suporte de Vetores, KNN (*K-nearest neighbors*, traduzido do inglês como K-vizinhos mais próximos), Floresta Aleatória e Redes Neurais Artificiais.

Através da combinação de diferentes algoritmos, Varkalys [5] mostra resultados positivos de redução de gastos com taxas de pedidos, advindas da redução do número de pedidos a fornecedores e redução da falta de estoque, mantendo o mesmo

giro de inventário.

Porém, Varkalys [5] mostra a dificuldade de lidar com a complexidade computacional e como isso pode influenciar no tempo de obtenção dos resultados, uma vez que, segundo o autor, a simulação do algoritmo para 1120 itens com dados de um ano demoraria 16 dias para ser executada. O trabalho também destaca a importância do histórico e do tratamento de dados.

No trabalho de Goncalves *et al.* [6] é destacado que a maioria dos modelos da literatura existentes são baseados em sistemas de estoque de um único produto, mas a maioria das cadeias de suprimentos interagem com vários produtos, de forma que os modelos não conseguem capturar a dinâmica real dos ambientes. Os autores sugerem o uso de aprendizado não supervisionado para abordar interações entre as variáveis logísticas de diversos produtos, bem como para identificar perfis de risco entre esses produtos.

Goncalves *et al.* [6] concluem que o problema do dimensionamento do estoque de segurança continua a ser um tópico de pesquisa importante que apresenta desafios tanto para acadêmicos quanto para profissionais e incentiva o desenvolvimento de novas abordagens de modelagens.

Portanto, a literatura é muito clara com relação à importância de análise e determinação de estoque de segurança e dos impactos que a melhoria de processos pode trazer para os negócios. Porém, trata-se também de um problema complexo que exige tratamento de grandes volumes de dados e interpretação de processos de multivariáveis.

### 3. FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão apresentados os principais conceitos deste trabalho, que possui três pilares: estoque de segurança, redes neurais artificiais e algoritmos de classificação não-supervisionados.

#### i) Estoque de segurança

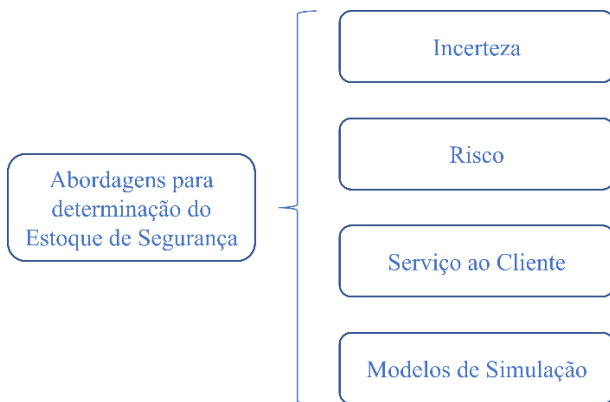
Estoque de segurança é uma das ferramentas da gestão de estoque e é definido pelo estoque mantido como uma reserva para o estoque em trânsito, para atender as demandas futuras e para lidar com as incertezas na demanda, tempos de entrega ou mudanças nos requisitos do produto [7]. O estoque de segurança é uma das principais estratégias utilizadas pelas empresas para garantir o equilíbrio entre o nível de serviço ao cliente, ou seja, o tempo esperado de execução do serviço, e os custos de estoque, reduzindo os riscos de falta de estoque e garantindo a disponibilidade dos produtos [8].

Existem diferentes abordagens para determinar o estoque de segurança, algumas delas são destacadas na Figura 1. A abordagem baseada na incerteza se concentra na análise histórica da incerteza da demanda e no tempo de reposição para definir a quantidade adequada de estoque de segurança [9], assim, utiliza técnicas estatísticas para garantir um tempo de resposta de atendimento desejado.

Outra abordagem, baseada em risco, leva em consideração os custos associados à falta de estoque, bem como a probabilidade de que a demanda exceda a previsão ou que os tempos de reposição sejam maiores que o esperado [10]. Já a abordagem de estoque de segurança baseada em serviço ao cliente utiliza o nível de serviço desejado como ponto de partida para determinar o estoque de segurança necessário [11]. Existe também a abordagem baseada em modelos de simulação, que permitem que

as empresas testem diferentes cenários e políticas de estoque de segurança em um ambiente virtual.

Figura 1 - Tipos de abordagens para a determinação do estoque de segurança necessário.



Fonte: Autor.

A principal vantagem de um estoque de segurança é a redução do risco de falta de estoque e da conseqüente insatisfação dos clientes. Além disso, o estoque de segurança também pode permitir que as empresas negociem melhores preços com os fornecedores, reduzindo os custos totais de aquisição de estoque [12]. Também, a manutenção de um estoque de segurança adequado permite uma melhor utilização da capacidade produtiva, uma vez que a empresa não precisará interromper a produção para aguardar o recebimento de suprimentos ou matéria-prima [13].

No entanto, o estoque de segurança também pode ter algumas desvantagens. A manutenção de um estoque de segurança pode levar ao aumento dos custos de armazenagem, aumento do capital de giro e obsolescência de produtos. Inclusive, o excesso de estoque de segurança pode levar a problemas como falta de espaço para armazenamento, deterioração da qualidade do produto e maiores riscos de roubo ou perda [14].

Desta forma, determinar o nível adequado de estoque de segurança requer a consideração de diversos fatores, como o objetivo de sua implementação, quais são as variáveis existentes, quais serão os custos para a empresa e a estratégia de produção e distribuição. Porém, esses fatores não são estáticos e podem variar de forma acelerada dentro da economia globalizada.

O estoque de segurança é um complemento da previsão de estoque, importante área da gestão de estoque, que se baseia na análise de dados e em técnicas estatísticas para realizar uma predição da necessidade futura de insumos. A previsão do estoque será responsável pela demanda padrão enquanto o estoque de segurança lidará com as incertezas da demanda.

As principais técnicas para a realização de cálculos de previsão de estoque são análises de séries temporais e análises de dados de mercado. Enquanto as análises de séries temporais fazem uso de modelos matemáticos, como média móvel, suavização exponencial e modelos de regressão, as análises de dados de mercado se baseiam nas tendências de mercado, mudanças comportamentais do consumidor e eventos sazonais. Todas essas análises podem ser trabalhadas através de ferramentas de inteligência artificial (IA), que é o campo da ciência e da engenharia que busca desenvolver agentes

inteligentes capazes de realizar tarefas que normalmente exigiriam a inteligência humana [15]. Uma das abordagens fundamentais da IA é o aprendizado de máquina (*Machine Learning*), que possibilita que os modelos treinem e aprendam a partir de uma base de dados e façam modificações para melhorar o desempenho em tarefas específicas.

Deste modo, a previsão de estoque pode ser feita por meio de técnicas de aprendizado de máquina, como redes neurais e árvores de decisão. Essas técnicas são capazes de analisar grandes conjuntos de dados e identificar padrões que podem ser usados para prever a demanda futura. Porém, em um mercado globalizado, nenhuma técnica poderá prever todos os fatores e mudanças inesperadas e específicas. Assim, é recomendado que as empresas utilizem técnicas de previsão em conjunto com outras estratégias de gestão de estoque, como o estoque de segurança, para garantir o objetivo desejado.

#### ii) Redes Neurais Artificiais (RNAs)

As redes neurais artificiais (RNAs) são um subconjunto da inteligência artificial que buscam emular o funcionamento do cérebro humano. Essa abordagem é baseada no conceito de que, assim como o cérebro, a inteligência artificial também pode aprender a partir de dados e melhorar seu desempenho com o tempo.


As RNAs são compostas por unidades básicas chamadas de neurônios artificiais, que recebem entradas, processam as informações e geram saídas. A interconexão desses neurônios forma uma rede, na qual a informação flui em direção à camada de saída da rede. Cada neurônio é conectado a outros neurônios através de conexões sinápticas, que possuem pesos associados que podem ser ajustados durante o treinamento da rede para melhorar seu desempenho [16].

Existem três classes de arquiteturas fundamentalmente diferentes: redes de propagação para frente (*feedforward*), redes recorrentes e redes reticuladas [17].

As redes *feedforward* podem ser de camada simples ou de múltiplas camadas e o fluxo de informação é unidirecional. A primeira camada é a entrada e a última camada é a saída. Se houver mais de uma camada escondida, a arquitetura é chamada de rede neural profunda (*Deep Learning*). Essas redes aplicam uma função sobre as camadas anteriores, realizando diversas transformações para definir as semelhanças entre os casos. São empregadas em problemas de aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica e controle de processos [18]. Na Figura 2 há uma representação de uma rede multicamadas de propagação para frente.

As redes recorrentes, ou realimentadas, têm ligações com os neurônios sem restrições, de maneira que a camada de saída pode ser realimentada para camadas de entrada. Esse comportamento dinâmico é fundamental para o sucesso desse modelo, porém, essa complexidade pode dificultar o treinamento. As redes neurais recorrentes são uma maneira de modelar dados sequenciais mais semelhantes aos processos naturais. São empregadas em previsões de séries temporais, otimização, identificação de sistemas e controle de processos [18]. A rede Hopfield é uma rede auto-associativa onde todos os neurônios são tanto neurônios de entrada como neurônios de saída, conforme Figura 3.


Figura 2 – Rede multicamadas *feedforward* com  $l$  camadas ocultas.



Fonte: Kröse e Smagt [18].

As redes reticuladas consideram a disposição espacial dos neurônios com o propósito da extração de características do sistema, ou seja, sua localização espacial serve para ajuste de seus pesos e limiares. São empregadas em problemas de agrupamento, reconhecimento de padrões, otimização de sistemas etc.

Figura 3 – Rede de Hopfield. Todos os neurônios são tanto neurônios de entrada como neurônios de saída.



Fonte: Kröse e Smagt [18].

Uma rede neural precisa ser configurada de forma que a aplicação de um conjunto de entradas produza o conjunto desejado de saídas. Quando não há conhecimento sobre a definição dos pesos, é necessário treinar a rede, alimentando-a com padrões de ensino e permitindo que ela altere seus pesos de acordo com alguma regra de aprendizado [18]. Os treinamentos podem ser classificados como aprendizado supervisionado ou aprendizado não-supervisionado.

Aprendizagem supervisionada ocorre quando a rede é treinada com padrões de entrada e saída correspondentes, ou seja, através das amostras e das respectivas saídas, os pesos e limiares são ajustados continuamente pelo algoritmo. Na aprendizagem não-supervisionada, a saída deve se auto-organizar em relação às particularidades do conjunto de amostras e assim identificar subconjuntos similares, de modo que os seus pesos e limiares são ajustados pelo algoritmo de aprendizagem de modo a refletir estas particularidades.

As RNAs são amplamente utilizadas em várias áreas, incluindo reconhecimento de fala, reconhecimento de imagem, processamento de linguagem natural, previsão de séries temporais e muitas outras. Devido à sua capacidade de aprender a partir de dados e adaptar-se a novas situações, as RNAs têm o potencial de revolucionar muitos campos de aplicação, impulsionadas também pelo aumento da capacidade computacional, disponibilidade de grandes conjuntos de dados e aprimoramento das técnicas de treinamento [19].

### iii) Algoritmos de classificação não-supervisionados

Uma possibilidade para a determinação dos componentes essenciais de uma cadeia de suprimentos é a utilização de algoritmos de RNAs de classificação com treinamentos não-supervisionados. Dessa maneira, através de uma base de dados com múltiplas variáveis logísticas é possível realizar o agrupamento dos componentes e, com o treinamento não-supervisionado, o próprio algoritmo irá se ajustar ao longo das iterações para obter o agrupamento dos dados. Com o agrupamento realizado, é possível analisá-los de acordo com as variáveis logísticas e determinar os grupos essenciais.

Existem diversos algoritmos de classificação não-supervisionados, proporcionando a implementação de diferentes modelos para comparação dos resultados e análise de eficiência entre os métodos. Alguns dos algoritmos são: K-médias, propagação de afinidade, deslocamento médio, e agrupamento hierárquico.

#### (1) K-médias (*K-means*)

O algoritmo de K-médias agrupa os dados através de uma separação de amostras em  $n$  grupos de igual variância, minimizando o critério conhecido como inércia ou “soma de quadrados dentro do grupo” (do inglês, *within-clusters sum-of-squares* - WCSS), conforme equação (1). O algoritmo requer a especificação da quantidade de grupos. O K-médias consegue escalar bem para dados com grande quantidade de amostras e tem sido usado em diversas áreas de aplicação [20].

O algoritmo K-médias divide o conjunto  $N$  de  $X$  amostras em  $K$  grupos separados  $C$ , cada um descrito pela média  $\mu_j$  das amostras do grupo. As médias são também conhecidas como “centroides do grupo” (do inglês, *cluster centroids*), e, em geral, não são pontos de  $X$ , mesmo estando no mesmo espaço [20].

O algoritmo tem como objetivo escolher centroides que minimizem a inércia.

$$\sum_{i=0}^n \min_{\mu_j \in C} (\|x_i - \mu_j\|^2) \quad (1)$$


O K-médias é frequentemente chamado de algoritmo de Lloyd e, de maneira sucinta, possui três etapas. A primeira etapa escolhe os centroides iniciais, sendo que o método mais básico é escolher  $k$  amostras do conjunto de dados  $X$ . A segunda etapa agrupa cada amostra ao seu centroide mais próximo. A terceira etapa determina novos centroides considerando o valor médio de todas as amostras atribuídas a cada centroide anterior. A diferença entre o centroide antigo e o novo é calculada e o algoritmo repete essas duas últimas etapas até que esse valor seja menor que um limite definido. Em outras palavras, ele se repete até que os centroides não se movam significativamente [20].

Um dos grandes desafios da implementação do algoritmo de

K-médias é a determinação do número  $K$  de grupos. Para solucionar este problema, uma das soluções é o uso do método do cotovelo (do inglês, *Elbow Method*). O método do cotovelo consiste na execução do algoritmo K-médias para diferentes valores de  $K$  para determinar o número ótimo de grupos. Normalmente, poucos grupos geram uma alta inércia (WCSS – *within-clusters sum-of-squares*, traduzido para o português como “soma de quadrados dentro do grupo”), porém, para números elevados de grupos, a diferença da WCSS é mínima e as separações dos dados em grupos podem ser não muito diferentes [21].

Aplicando-se a teoria em um gráfico, tem-se uma curva, onde o eixo  $x$  indica o número  $K$  de grupos e o eixo  $y$  indica o valor da WCSS. Visualmente, o ponto do cotovelo é onde a curva começa a apresentar uma variação mínima de WCSS entre os grupos. Na Figura 4, tem-se que o ponto de cotovelo, ou seja, o número ótimo de grupos, é 3.

Figura 4 – Ponto de cotovelo de uma curva com as inércias de K-médias de grupos variando entre 1 e 8. O ponto de cotovelo é dado em 3.



Fonte: Adaptado de *Elbow Method* [22].

Caso não seja possível identificar o ponto visualmente, é possível calcular qual é o ponto ótimo através do cálculo do ponto da curva mais distante de uma reta traçada entre o ponto inicial e final da curva, que é dada pela Equação (2), sendo  $d$  a distância entre a reta e o ponto,  $P_0(x_0, y_0)$  o ponto inicial,  $P_1(x_1, y_1)$  o ponto final e  $x$  e  $y$  as coordenadas do ponto [23].

$$d(P_0, P_1, (x, y)) = \frac{|(y_1 - y_0)x - (x_1 - x_0)y + x_1y_0 - y_1x_0|}{\sqrt{(y_1 - y_0)^2 + (x_1 - x_0)^2}} \quad (2)$$

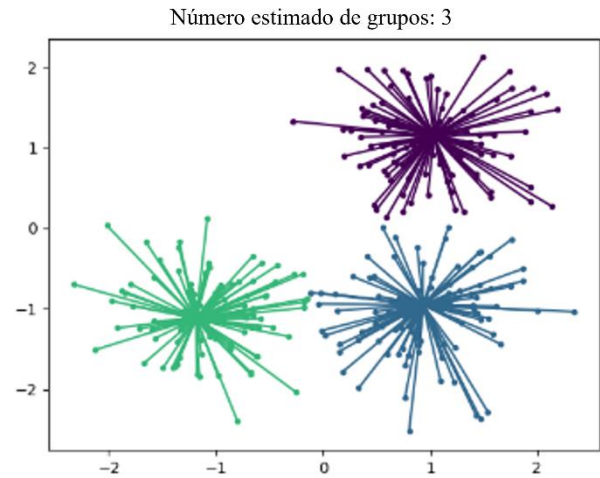
### (2) Propagação de afinidade (*Affinity Propagation*)

O algoritmo de propagação de afinidade cria grupos enviando mensagens entre pares de amostra até a convergência. Um conjunto de dados é determinado a partir de um pequeno número de exemplares, que são os que possuem maior representatividade de outras amostras. As mensagens enviadas entre pares representam a compatibilidade de uma amostra ser o exemplar de outra, que é atualizada em resposta aos valores de outros pares. A atualização é iterativa e ocorre até a convergência, onde os exemplares finais são escolhidos e o agrupamento definitivo é determinado [20].

Na propagação de afinidade é o algoritmo que determina o número de grupos, baseando-se no conjunto de dados disponibilizado (Figura 5). Por esse motivo, existem dois parâmetros importantes que são a preferência, que determina quantos exemplares serão usados, e o fator de amortecimento, que suprime as mensagens de responsabilidade e de disponibilidade para evitar oscilações numéricas durante a

atualização.

Figura 5 – Exemplo de resultado de um algoritmo de propagação de afinidade com três grupos determinados. Os pontos são meramente ilustrativos e os eixos  $x$  e  $y$  não representam medidas reais.



Fonte: Adaptado de *Affinity Propagation* [20].

A principal desvantagem do algoritmo de propagação de afinidade é a sua complexidade, que escala em relação ao número de amostras e ao número de iterações. Por isso, é um algoritmo mais apropriado para conjuntos de dados pequenos ou médios.

### (3) Deslocamento médio (*Mean Shift*)

O agrupamento por deslocamento médio é um algoritmo baseado em centroides que funciona atualizando os candidatos a centroides a serem a média dos pontos de uma determinada região. Os candidatos são então filtrados para eliminação de possíveis duplicatas e determinação dos centroides definitivos [20].

O algoritmo determina o número de agrupamentos de forma automática, dependendo do parâmetro de largura de banda (*bandwidth*) que delimita o tamanho da região pesquisada nas iterações. Esse parâmetro pode ser definido manualmente ou utilizando uma função que estima uma largura de banda apropriada.

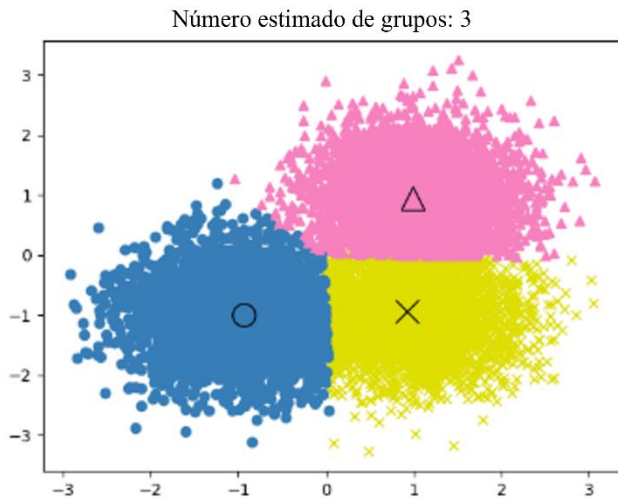
O algoritmo é pouco escalável uma vez que realiza muitas buscas aos vizinhos mais próximos, porém, a convergência é garantida, ocorrendo quando a diferença dos centroides entre uma iteração e outra é mínima. Um exemplo de resultado pode ser observado na Figura 6.

### (4) Agrupamento hierárquico (*Hierarchical Clustering*)

O agrupamento hierárquico cria grupos aninhados, mesclando-os ou dividindo-os sucessivamente. Essa hierarquia de grupos é representada como uma árvore (ou dendrograma). A raiz da árvore é o único grupo que reúne todas as amostras, e as folhas são os grupos com apenas uma amostra [20].

O algoritmo executa um agrupamento hierárquico usando uma abordagem de baixo para cima: cada observação começa em seu próprio agrupamento, e os agrupamentos são sucessivamente unidos. O critério de ligação determina a métrica usada para a estratégia de agrupamento.

Figura 6 – Exemplo de resultado de um algoritmo de deslocamento médio com três grupos determinados. Os pontos são meramente ilustrativos e os eixos  $x$  e  $y$  não representam medidas reais.



Fonte: Adaptado de *MeanShift* [20].


O método Ward minimiza a soma das diferenças quadráticas em todos os grupos. É uma abordagem de minimização de variância e, nesse sentido, é semelhante à função objetiva do K-médias, mas tratada com uma abordagem hierárquica aglutinada.

O método de ligação máxima, ou completa, minimiza a distância máxima entre as observações de pares de grupos.

O método de ligação média minimiza a média das distâncias entre todas as observações de pares de grupos.

O método de ligação única minimiza a distância entre as observações mais próximas de pares de grupos.

Figura 7 – Exemplo de agrupamentos utilizando diferentes critérios de ligação do agrupamento hierárquico para diferentes conjuntos de dados.



Fonte: Adaptado de *Hierarchical clustering* [20].

O agrupamento hierárquico tem um comportamento no qual “ter mais ganha mais”, gerando grupos de tamanhos variados. Nesse sentido, a ligação única é a pior estratégia, e o método Ward oferece os tamanhos mais regulares. No entanto, a afinidade (ou distância usada no agrupamento) não pode ser variada com o método Ward, portanto, para métricas não euclidianas, a ligação média é uma boa alternativa. A ligação única, embora não seja resistente a dados ruidosos, pode ser calculada com muita eficiência e, portanto, pode ser útil para fornecer agrupamento hierárquico de conjuntos de dados maiores [20].

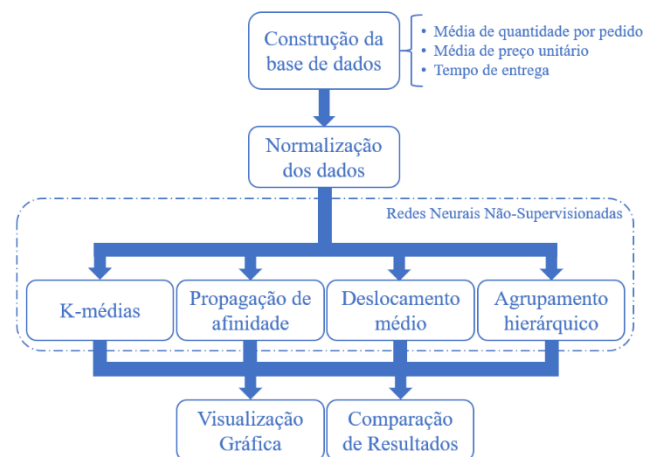
Na Figura 7 tem-se uma representação visual de como funciona o agrupamento hierárquico dependendo dos dados e dos métodos utilizados. Nessa matriz, as linhas representam diferentes conjuntos de dados enquanto as colunas representam os diferentes métodos, em ordem: ligação única, ligação média, ligação completa e ligação Ward.

#### 4. METODOLOGIA

Para realizar a aplicação dos modelos de inteligência artificial foi utilizada a linguagem de programação Python. O programa em Python foi escrito e executado na plataforma Colab, da Google. O Colab é um serviço hospedado de *Jupyter Notebook* que não requer configuração para ser usado e fornece acesso gratuito a recursos de computação, incluindo GPUs (Unidades de Processamento Gráfico, do inglês, *Graphics Processing Units*) e TPUs (Unidades de Processamento de Tensor, do inglês, *Tensor Processing Units*). O Colab é especialmente adequado para aprendizado de máquina, ciência de dados e educação [25].

O trabalho foi construído conforme diagrama de blocos representado na Figura 8, iniciando-se com a construção e tratamento da base de dados relacionado à gestão de estoque. Então, os dados foram tratados para em seguida serem aplicados em diferentes algoritmos de redes neurais não-supervisionadas. Através dos resultados obtidos pelos algoritmos, foi possível construir gráficos 3D e comparar os resultados obtidos para discussão dos métodos e definição de possibilidades para determinação de classificação de estoque de segurança. Os detalhes de cada parte do processo serão detalhados ao longo desta seção.

Figura 8 – Diagrama de blocos das etapas executadas neste trabalho.



Fonte: Autor.

O primeiro passo para o desenvolvimento dos modelos foi entender e estudar o problema a ser resolvido: classificar uma

série de itens em grupos e assim poder definir quais são os itens que potencialmente podem ser classificados como estoque de segurança.

Foi utilizada uma base de dados de pedidos de peças sobressalentes de diferentes tipos de veículos. A base de dados consiste de 2823 entradas de pedidos em um período de dois anos e as principais informações da base são: número do pedido, quantidade pedida, preço unitário, preço total, data do pedido, status do pedido, código do produto, categoria do produto e tempo de entrega. Os dados estão distribuídos entre 109 produtos e 7 categorias de produtos.

Figura 9 – Resumo da base de dados utilizadas, contendo as 5 primeiras e as 5 últimas linhas. A base contém o código do produto, a quantidade de pedidos para aquele produto, a média da quantidade de peças por pedido, o preço unitário médio e o tempo de entrega.

PRODUTO	QUANT. DE PEDIDOS	QUANT. POR PEDIDO	PREÇO UNITÁRIO	TEMPO DE ENTREGA
\$10_1678	26	36.5	92.607692	25
\$10_1949	28	34.0	100.000000	195
\$10_2016	26	38.5	94.365769	85
\$10_4698	26	35.0	98.593846	45
\$10_4757	27	33.0	94.190000	26
...	...	...	...	...
\$700_3505	26	35.0	92.877308	109
\$700_3962	26	34.0	91.812308	35
\$700_4002	27	39.0	73.621111	125
\$72_1253	27	34.0	55.897037	125
\$72_3212	26	36.5	63.865769	185

109 rows x 4 columns

Fonte: Autor.

Para desenvolver os modelos, foram elencados os 3 fatores mais relevantes, de acordo com trabalhos relacionados, de cada pedido dessa base de dados para classificação dos produtos em grupos. Esses três fatores são: quantidade pedida, preço unitário e tempo de entrega. A base de dados foi, então, tratada e resumida pelos produtos. Como o tempo de entrega do produto é sempre o mesmo, esse parâmetro é fixo para cada produto. Porém, a quantidade pedida e o valor unitário de cada um dos produtos não é constante na base dados, dessa forma, foi preciso tratar os dados e considerou-se a média de produtos pedidos e a média do valor unitário da peça. Assim, resumiu-se a base de dados em 109 linhas de produtos e 4 dimensões (contagem de vezes que o produto foi pedido, média de quantidade por pedido, média de valor unitário, tempo de entrega). Na figura Figura 9 é destacado um resumo dos 5 primeiros e 5 últimos dados tratados.

Na Tabela 1 são apresentados alguns dados estatísticos da base de dados, com a média, mínimo e máximo dos valores adquiridos.

Tabela 1 – Tabela com resumo dos dados estatísticos da base da dados que será utilizada no desenvolvimento do trabalho.

Resumo	Quantidade de Pedidos	Quantidade por Pedido	Preço unitário	Tempo de Entrega
Média	25,90	34,83	83,48	80,51
Mínimo	22	27,50	43,99	25,00
Máximo	30	43,00	10,00	27,50

Fonte: Autor.

De acordo com o resumo da Tabela 1, observa-se que a

quantidade de pedidos por produto tem um intervalo de distribuição muito baixo. Portanto, para o desenvolvimento dos algoritmos, a coluna de quantidade de vezes que o produto foi pedido foi desconsiderada, uma vez que a sua variação representará um impacto mínimo nas análises. Assim, restaram 3 dimensões, quantidade pedida, preço unitário e tempo de entrega, que podem ser impressas em um gráfico 3D.

Para otimizar ainda mais os resultados, os dados foram normalizados através de uma função do Python, *StandardScaler* [26]. Com os dados normalizados é possível reduzir a dominância de valores mais altos e a tendência ao sobreajuste (do inglês, *overfitting*), além de melhorar o tempo de resposta da convergência.

Os dados foram aplicados então a diferentes algoritmos de classificação não supervisionada, sendo eles: K-médias, propagação de afinidade, deslocamento médio e agrupamento hierárquico. Cada algoritmo necessita de parâmetros diferentes e pode retornar atributos diferentes. Entretanto, todos eles irão classificar os dados em dois ou mais grupos.

Para aplicar o algoritmo de K-médias, foi utilizada a função *sklearn.cluster.Kmeans* [27] do *Scikit Learn* [28], que é uma ferramenta de fonte aberta para implementações de aprendizado de máquina em Python. Essa função possui parâmetros que podem ser indicados para determinar o comportamento do algoritmo, como número de grupos, máximo de iterações e variantes.

Foram executados algoritmos de K-médias com dois valores diferentes para número de grupos  $K$ . Em um momento o algoritmo foi executado com parametrização de 2 grupos. No outro momento o algoritmo foi executado com a parametrização considerando o número ótimo de grupo determinado a partir do método do cotovelo.

Para aplicar o algoritmo de propagação de afinidade, foi utilizada a função *sklearn.cluster.AffinityPropagation* [29] do *Scikit Learn*. Essa função possui parâmetros que podem ser indicados para determinar o comportamento do algoritmo, como fator de amortecimento, máximo de iterações e tipo de afinidade.

Para aplicar o algoritmo de deslocamento médio, foi utilizada a função *sklearn.cluster.MeanShift* [30] do *Scikit Learn*. Essa função possui parâmetros que podem ser indicados para determinar o comportamento do algoritmo, como largura de banda, máximo de iterações e discretização dos ponto.

Para aplicar o algoritmo de agrupamento hierárquico, foi utilizada a função *sklearn.cluster.AgglomerativeClustering* [31] do *Scikit Learn*. Essa função possui parâmetros que podem ser indicados para determinar o comportamento do algoritmo, como número de grupos, tipo de ligação, conectividade e limite de distância.

Assim como o K-médias, o agrupamento hierárquico também precisa de um valor para a quantidade de grupos desejadas. Porém, não foram encontrados métodos conclusivos para a determinação do número ótimo de grupos para esse algoritmo. Dessa maneira, o algoritmo será executado duas vezes, assim como realizado para o K-médias, com o número de grupos parametrizado para 2 e com o número de grupos parametrizado para o número ótimo de grupos determinado para o K-médias, possibilitando-se, assim, comparação de resultados.

Para todos os algoritmos executados foram gerados gráficos

em três dimensões, sendo elas a média da quantidade pedida, a média do preço unitário e o tempo de entrega, que serão coloridos de acordo com o agrupamento determinado pelos algoritmos.

Os pontos são classificados em grupos através dos rótulos 0 ou 1 para os casos de dois grupos. Os rótulos não possuem maior relevância além de seu objetivo básico de segregação em grupos. O ponto ser classificado como 0 ou como 1 não significa que ele deverá ser categorizado como mais ou menos relevante. Essa análise deve ocorrer ao estudar e correlacionar os resultados obtidos.

Semelhante ocorre quando o algoritmo classifica os pontos em 3 ou mais grupos, onde são utilizados os rótulos 0, 1 ou 2, e assim sucessivamente dependendo da quantidade total de grupos.

Os resultados de agrupamento de cada algoritmo foram comparados para verificação de correlação e entendimento dos grupos gerados.

## 5. RESULTADOS E DISCUSSÕES

Foram executados os algoritmos dos quatro modelos determinados. Todos tiveram uma boa performance, uma vez que a base de dados não é extensa e a dimensionalidade da base foi reduzida previamente ao escolher-se as variáveis mais desejadas: quantidade de produtos pedidos, preço unitário do produto e tempo de entrega.

Como um primeiro teste para entendimento do comportamento dos algoritmos, todos foram executados com o mínimo parâmetros definidos. Tanto o algoritmo de K-médias quanto o algoritmo de agrupamento hierárquico necessitavam de um valor de grupos e, nesse primeiro momento, foi adotado o valor 2, para que dois grupos fossem formados. O algoritmo de propagação por afinidade chegou em um resultado contendo 12 grupos e o algoritmo de deslocamento médio teve sua execução concluída com 2 grupos criados. Dessa forma, tornou-se possível comparar os resultados dos algoritmos K-médias, deslocamento médio e agrupamento hierárquico, com 2 grupos.


Após os testes iniciais, foi executado o código do método do cotovelo. Esse código executou o algoritmo de K-médias variando-se o número do grupos  $K$ . Para cada execução de  $K$ , calculou-se o valor de WCSS (inércia). Assim, foi gerado um gráfico onde o eixo  $x$  indica o número de grupos e o eixo  $y$  o valor de WCSS (Figura 10).

Porém, através do gráfico, não foi possível determinar de maneira clara qual é o número de grupos ótimos. Visualmente o valor 4 parece, ligeiramente, ser o mais apropriado, pois a iteração seguinte possui pouca variação de WCSS, mas há alguma incerteza na definição correta.

Por este motivo, foi utilizada a Equação (2), que calcula qual é o ponto mais distante entre a reta formada pelo primeiro e último ponto da curva. Conforme descrito por [23], o ponto mais distante da reta pode ser considerado aquele que determina o número ótimo de grupos.


Adicionando-se à iteração a equação que calcula a distância dos pontos à reta, observou-se que o número ótimo de grupos é 3, conforme representado pela Figura 11.

Figura 10 – Gráfico do Método do Cotovelo para o algoritmo de K-médias.



Fonte: Autor.

Figura 11 – Gráfico do Método do Cotovelo para o algoritmo de K-médias. A linha vermelha vertical indica o ponto cuja distância para a reta entre os ponto inicial e final é a maior e, por isso, representa o número ótimo de grupos.




Fonte: Autor.

Com o número ótimo de grupos determinado, foi executado o algoritmo de K-médias com dois parâmetros diferentes. Na primeira execução, foram selecionados dois grupos para fins de comparação com os outros algoritmos, e na segunda execução foram determinados três grupos, conforme número ótimo encontrado.

Na execução com dois grupos, o algoritmo classificou os produtos como 0 ou 1, determinando assim a qual grupo cada um dos produtos pertence. Com a execução do algoritmo, 72 produtos foram classificados em um dos grupos e os outros 37 produtos foram classificados no outro grupo. A Figura 12 mostra o gráfico 3D gerado com todos os 109 pontos representando os produtos e as cores amarela e roxa representando a classificação, no eixo  $x$  é indicada a média de quantidade de produtos pedidos, no eixo  $y$  é indicada a média do preço unitário do produto e no eixo  $z$  é indicado o tempo de entrega do produto. Foram necessárias apenas 5 iterações para o algoritmo convergir.



Figura 12 – Gráfico de agrupamento dos produtos utilizando o algoritmo de K-médias para dois grupos. Os grupos estão representados pelas cores amarela (rótulo 0) e roxa (rótulo 1).



Fonte: Autor.


Na execução com três grupos, o algoritmo classificou os produtos como 0, 1 ou 2, determinando assim a qual grupo cada um dos produtos pertence. Com a execução do algoritmo, 62 produtos foram classificados no primeiro grupo, 27 produtos foram classificados no segundo grupo e os outros 20 produtos foram classificados no terceiro grupo. A Figura 13 mostra o gráfico 3D gerado com todos os 109 pontos representando os produtos e as cores amarela, roxa e verde representando a classificação, no eixo  $x$  é indicada a média de quantidade de produtos pedidos, no eixo  $y$  é indicada a média do preço unitário do produto e no eixo  $z$  é indicado o tempo de entrega do produto. Foram necessárias 8 iterações para o algoritmo convergir.

É possível observar que os pontos classificados como verde tomaram, em geral, a posição dos pontos que antes haviam sido classificados como amarelos, e que alguns pontos que antes eram roxos passaram a ser amarelos.

Para o algoritmo de propagação por afinidade o número de grupos não é definido, porém, é possível definir o fator de amortecimento, que pode variar entre 0,5 e 1,0. Foram feitos testes manuais variando-se o valor do fator de amortecimento e foi observado que, independente de seu valor, sempre foram realizadas classificações em 12 grupos.

A Figura 14 mostra o gráfico 3D gerado com todos os 109 pontos representando os produtos e as diferentes cores representando as classificações, no eixo  $x$  é indicada a média de quantidade de produtos pedidos, no eixo  $y$  é indicada a média do preço unitário do produto e no eixo  $z$  é indicado o tempo de entrega do produto. A média de pontos por grupo foi de 9,41 pontos. Foram necessárias 30 iterações para o algoritmo convergir.


Figura 13 – Gráfico de agrupamento dos produtos utilizando o algoritmo de K-médias para três grupos. Os grupos estão representados pelas cores amarela (rótulo 0), roxa (rótulo 1) e verde (rótulo 2).



Fonte: Autor.

Figura 14 – Gráfico de agrupamento dos produtos utilizando o algoritmo de Propagação por Afinidade. Foram gerados 12 grupos, cada um representado por uma cor diferente.

Algoritmo Propagação por Afinidade




Fonte: Autor.

Para o algoritmo de deslocamento médio o número de grupos também não é definido, porém, é possível definir a largura de banda. Caso a largura de banda não seja definida, o próprio algoritmo usará um estimador para definir este valor. No caso, foi utilizado o estimador do algoritmo e os dados foram classificados em 2 grupos. A classificação distribuiu 99 produtos no primeiro grupo e os outros 10 produtos no segundo grupo.

A Figura 15 mostra o gráfico 3D gerado com todos os 109 pontos representando os produtos e as cores amarela e roxa representando as classificações, no eixo  $x$  é indicada a média de quantidade de produtos pedidos, no eixo  $y$  é indicada a média do preço unitário do produto e no eixo  $z$  é indicado o tempo de entrega do produto. Foram necessárias 14 iterações para o algoritmo convergir.

Figura 15 – Gráfico de agrupamento dos produtos utilizando o algoritmo de Deslocamento Médio. Os grupos são representados pelas cores amarela (rótulo 0) e roxa (rótulo 1).



Fonte: Autor.

Assim como o algoritmo de K-médias, o algoritmo de agrupamento hierárquico também exige como parâmetro o número de grupos. Portanto, o algoritmo foi executado duas vezes, uma considerando dois grupos e outra considerando três grupos.


Além deste parâmetro, o algoritmo de agrupamento hierárquico também permite definir qual é o tipo de ligação utilizada, que são os métodos: Ward, ligação máxima, ligação média e ligação única.

Foram feitos testes com as diferentes ligações possíveis. As ligações média e única obtiveram um resultado em que mais de 90% dos pontos foram classificados em um único grupo. Por gerarem um grupo muito pequeno, estes métodos foram descartados para simplificação das análises. Então, seguiu-se com a aplicação do Método Ward e da ligação máxima.

Na execução do Método Ward com dois grupos, 72 produtos foram classificados em um dos grupos e os outros 37 produtos foram classificados no outro grupo. A Figura 16 mostra o gráfico 3D gerado com todos os 109 pontos representando os produtos e as cores amarela e roxa representando a classificação, no eixo  $x$  é indicada a média de quantidade de produtos pedidos, no eixo  $y$  é indicada a média do preço unitário do produto e no eixo  $z$  é indicado o tempo de entrega do produto. Esse algoritmo não indica quantas iterações foram realizadas para convergência.

Figura 16 – Gráfico de agrupamento dos produtos utilizando o algoritmo de Agrupamento Hierárquico com o Método Ward para dois grupos. Os grupos são representados pelas cores amarela (rótulo 0) e roxa (rótulo 1).

Algoritmo Agrupamento Hierárquico - Método Ward com dois grupos



Fonte: Autor.


Na execução do Método Ward com três grupos, 72 produtos foram classificados no primeiro grupo, 26 produtos foram classificados no segundo grupo e os outros 11 produtos foram classificados no terceiro grupo. É possível verificar que um dos grupos foi dividido em outros dois grupos. A Figura 17 mostra o gráfico 3D gerado com todos os 109 pontos representando os produtos e as cores amarela, roxa e verde representando a classificação, no eixo  $x$  é indicada a média de quantidade de produtos pedidos, no eixo  $y$  é indicada a média do preço unitário do produto e no eixo  $z$  é indicado o tempo de entrega do produto. Esse algoritmo não indica quantas iterações foram realizadas para convergência.

Na execução de ligação completa com dois grupos, 69 produtos foram classificados em um dos grupos e os outros 40 produtos foram classificados no outro grupo. A Figura 18 mostra o gráfico 3D gerado com todos os 109 pontos representando os produtos e as cores amarela e roxa representando a classificação, no eixo  $x$  é indicada a média de quantidade de produtos pedidos, no eixo  $y$  é indicada a média do preço unitário do produto e no eixo  $z$  é indicado o tempo de entrega do produto. Esse algoritmo não indica quantas iterações foram realizadas para convergência.

Na execução de ligação completa com três grupos, 40 produtos foram classificados no primeiro grupo, 36 produtos foram classificados no segundo grupo e os outros 33 produtos foram classificados no terceiro grupo. É possível verificar que um dos grupos foi dividido em outros dois grupos. A Figura 19 mostra o gráfico 3D gerado com todos os 109 pontos representando os produtos e as cores amarela, roxa e verde representando a classificação, no eixo  $x$  é indicada a média de quantidade de produtos pedidos, no eixo  $y$  é indicada a média do preço unitário do produto e no eixo  $z$  é indicado o tempo de entrega do produto. Esse algoritmo não indica quantas iterações foram realizadas para convergência.

Figura 17 – Gráfico de agrupamento dos produtos utilizando o algoritmo de Agrupamento Hierárquico com o Método Ward para três grupos. Os grupos são representados pelas cores amarela (rótulo 0), roxa (rótulo 1) e verde (rótulo 2).


Algoritmo Agrupamento Hierárquico - Método Ward com três grupos



Fonte: Autor.

Figura 18 – Gráfico de agrupamento dos produtos utilizando o algoritmo de Agrupamento Hierárquico com ligação completa para dois grupos. Os grupos são representados pelas cores amarela (rótulo 0) e roxa (rótulo 1).

Algoritmo Agrupamento Hierárquico - Ligação completa com dois grupos




Fonte: Autor.

Após a execução de todos os algoritmos, passou a ser possível realizar a comparação entre os resultados obtidos. Na Tabela 2 é possível observar a quantidade de pontos distribuídos entre os grupos gerados por cada algoritmo.

Figura 19 – Gráfico de agrupamento dos produtos utilizando o algoritmo de Agrupamento Hierárquico com a ligação completa para três grupos. Os grupos são representados pelas cores amarela (rótulo 0), roxa (rótulo 1) e verde (rótulo 2).

Algoritmo Agrupamento Hierárquico - Ligação completa com três grupos



Fonte: Autor.

Tabela 2 – Comparação entre a quantidade de pontos distribuídos em cada agrupamento dos algoritmos executados.

Algoritmo	Pontos Grupo 1	Pontos Grupo 2	Pontos Grupo 3
K-médias dois grupos	72	37	-
K-médias três grupos	62	27	20
Deslocamento médio	99	10	-
Ward dois grupos	72	37	-
Ward três grupos	72	26	11
Ligação completa dois grupos	69	40	-
Ligação completa três grupos	40	36	33

Fonte: Autor.

Entre os algoritmos que classificaram os dados em apenas dois grupos – nomeados de K-médias dois grupos, deslocamento médio, Ward dois grupos e ligação completa dois grupos – percebe-se que o algoritmo de deslocamento médio é o modelo com maior discrepância nos resultados, e que os algoritmos K-médias e Ward distribuíram os grupos com exatamente a mesma quantidade de dados.

Entre os algoritmos que classificaram os dados em três grupos – nomeados de K-médias três grupos, Ward três grupos e ligação completa três grupos – é possível observar que o algoritmo de ligação completa possui uma distribuição mais uniforme entre os grupos, enquanto que os algoritmos de K-médias e Ward possuem um grupo dominante com uma maior quantidade de pontos.

Porém, possuir a mesma quantidade de pontos em um grupo não necessariamente significa que os pontos em cada grupo são

os mesmos entre os algoritmos. Portanto, é preciso analisar a correlação entre os agrupamentos obtidos.

Para calcular a correlação entre os agrupamentos gerados pelos algoritmos, foi calculado o Coeficiente de Correlação de Pearson ( $\rho$ ), que é uma técnica para medir a relação de duas variáveis de maneira linear. O valor de  $\rho$  pode variar de -1 a 1. Quanto mais próximo dos extremos, maior é a força da correlação. Quanto mais próximo de zero, menor é a força da correlação. O sinal irá indicar somente a direção da relação, porém, como os grupos obtidos podem ser renomeados sem alterar o resultado, pode-se calcular o módulo de  $\rho$  para fins de análise da força da correlação [32].

Na Tabela 3 é dada a matriz correlação entre os pontos obtidos através de cada algoritmo que gerou apenas dois grupos.

Tabela 3 – Matriz correlação entre os pontos obtidos através de cada algoritmo que gerou dois grupos.

Matriz correlação com dois grupos	K-médias dois grupos	Desloc. médio	Ward dois grupos	Ligação completa dois grupos
K-médias dois grupos	-	0,38	<b>0,71</b>	0,3
Deslocamento médio	0,38	-	0,38	0,24
Ward dois grupos	<b>0,71</b>	0,38	-	0,51
Ligação completa dois grupos	0,3	0,24	0,51	-

Fonte: Autor.

Na Tabela 4 é dada a matriz de correlação entre os pontos obtidos através de cada algoritmo que gerou três grupos.

Tabela 4 – Matriz correlação entre os pontos obtidos através de cada algoritmo que gerou três grupos.

Matriz correlação com três grupos	K-médias três grupos	Ward três grupos	Ligação completa três grupos
K-médias três grupos	-	<b>0,80</b>	0,59
Ward três grupos	<b>0,80</b>	-	0,73
Ligação completa três grupos	0,59	0,73	-

Fonte: Autor.

Na Tabela 3 é possível observar que a correlação mais forte foi obtida entre os algoritmos de K-médias e Ward, ambos com dois grupos, no valor de 0,71. Conforme observado na Tabela 2, esses dois algoritmos já haviam classificado os dados em grupos de tamanhos iguais, porém, foi confirmado que os pontos não são os mesmo. Mesmo assim, ainda apresentam uma boa correlação.

Da Tabela 3 pode-se concluir também que o algoritmo de deslocamento médio foi o que apresentou resultados com menos correlações.

Na Tabela 4 é possível observar que a correlação mais forte foi obtida entre os algoritmos de K-médias e Ward, ambos com três grupos, no valor de 0,80.

Ressalta-se que a correlação entre os algoritmos Ward e ligação completa também é alta, no valor de 0,73.

Considerando que os algoritmos K-médias e Ward, com três grupos, obtiveram a maior correlação, e que os algoritmos Ward e ligação completa, com três grupos, obtiveram a segunda maior correlação, o algoritmo de Ward com três grupos foi selecionado para um análise dos resultados mais profunda.

Na Tabela 5 foi captado um resumo dos valores de cada grupo gerados a partir do algoritmo de Ward com três grupos.

A média da quantidade pedida pouco varia entre os grupos. Com relação à média de preço unitário, observa-se que o grupo 2 possui uma média bem inferior aos outros dois grupos. Já a média de tempo de entrega é bem definida entre os grupos, onde o grupo 1 apresenta a menor média, o grupo 2 apresenta uma média intermediária e o grupo 3 a maior média.

Tabela 5 – Tabela com resumo dos valores de cada grupo gerados a partir do algoritmo de Ward com três grupos.

Grupo	Quantidade de Produtos	Média de Quantidade Pedida	Média de Preço Unitário	Média de Tempo de Entrega
1	72	35,15	91,43	56,58
2	26	34,29	58,84	94,12
3	11	34,00	89,67	205,00

Fonte: Autor.

A partir dessas análises, pode-se concluir que o grupo 2 é composto por peças de menor custo e um tempo de entrega considerável, e o grupo 3 é composto por peças mais caras mas que possuem um elevado tempo de entrega. Por esses motivos, os dois grupos são fortes candidatos a serem considerados materiais com necessidade de estoque de segurança e representam aproximadamente 34% do produtos estudados.

Os algoritmos foram capazes de organizar os dados em grupos e gerar novas análises sobre as características de cada um dos grupos. É possível então iniciar a discussão sobre ações de parametrização de estoque de segurança. Nesse momento, é viável solicitar uma análise especializada planejadores de estoque para determinar qual o melhor grupo a ser enquadrado como estoque de segurança.

## 6. CONCLUSÕES

Através dos resultados obtidos é possível concluir que, dos algoritmos estudados, os melhores métodos para obter uma classificação eficiente dos dados trabalhados foram os algoritmos de agrupamento hierárquico e de K-médias.

Os dois algoritmos apresentaram uma distribuição de pontos parecidas e mostraram um boa correlação dos resultados, principalmente quando geraram três grupos.

Poder determinar um valor para número ótimo de grupos foi de grande valor para o desenvolvimento deste trabalho, uma vez que tornou possível parametrizar essa medida nos algoritmos e avaliar resultados de uma outra perspectiva.

No algoritmo de agrupamento hierárquico foram abordados

dois métodos diferentes, o método de Ward e o método de ligação completa. Ambos apresentaram bons resultados e ficou clara a diferença entre eles. O método de ligação completa buscou agrupar os dados em conjuntos de tamanhos similares, enquanto o método de Ward buscou uma melhor semelhança entre os dados, de maneira bem parecida com o algoritmo de K-médias. Portanto, dependendo da aplicação, cada método possui seu benefício e, no âmbito de classificação de estoques de segurança, faz mais sentido um agrupamento que não prioriza a equidade do tamanho dos grupos, uma vez que nem sempre será viável parametrizar uma grande quantidade de itens como estoque de segurança, elevando os custos de estoque.

Deste modo, é muito importante ressaltar que, para aplicar os algoritmos de redes neurais em estudos de estoques de segurança, é necessário realizar uma análise do negócio e dos maiores objetivos desejados, para que seja possível garantir um equilíbrio entre a disponibilidade de atendimento ao cliente e os custos de estoque, reduzindo os riscos de falta de estoque e assegurando a disponibilidade dos produtos.

Não menos importante é o destaque da qualidade e da disponibilidade dos dados dispostos na aplicação da inteligência artificial. Através de uma base de dados consistente, e com um bom histórico, é possível extrair resultados mais precisos e exatos, pois os algoritmos terão mais embasamento para realizar suas iterações. Porém, o custo disso pode ser a força computacional, que, neste trabalho, não se mostrou uma barreira devido ao pré-tratamento dos dados e o relativo baixo volume de informações trabalhadas. Aplicações mais complexas podem exigir maior poder computacional e pode ser uma possibilidade de estudo futuro, buscando entender como cada algoritmo reagirá diante de um cenário com mais variáveis e como isso impactará na execução do modelo.

Outro estudo possível é, a partir dos resultados obtidos neste trabalho, desenvolver um código baseado em algoritmos de inteligência artificial para realizar a determinação de qual deve ser o valor do estoque de segurança que deve ser parametrizado. Uma vez determinados os produtos com melhor indicação a estoque de segurança, é possível analisar o histórico de compra desses produtos com algum método de inteligência artificial para determinação da quantidade e do momento de compra de novos itens para reposição deste estoque.

Com a combinação deste presente estudo com um futuro desenvolvimento conforme indicado, negócios que utilizam estoque de segurança podem estar munidos de ferramentas que irão determinar quais itens devem ser parametrizados como tal e qual deverá ser a quantidade definida de estoque mínimo. Assim como unidades de negócios que ainda não tenham estoques de segurança parametrizados possam analisar o seu histórico de compras de peças e passar a adotar essa estratégia de inventário. Espera-se que, com estes dados, a relação entre a disponibilidade de serviço e o custo associado ao estoque possa ser trabalhada de maneira inteligente e com resultados benéficos.

## 7. REFERÊNCIAS

- [1] SOUSA, R. C.; REIS, R. R.; SANTOS, T. S. Controle de Estoque de Materiais com Diferentes Padrões de Demanda: Estudo de Caso em uma Indústria Química. *Revista Produção Online*, v. 20, n. 2, p. 329-348, 2020. DOI: 10.14488/1676-1901.v20i2.3827.
- [2] DIAS, Marco Aurélio P. *Administração de Materiais: Uma Abordagem Logística*. São Paulo: Atlas, 2010.
- [3] DORAISWAMY, S.; MANDAL, A.; MISHRA, S. K. Operations research models and methods for safety stock determination: A review. *International Journal of Production Research*, v. 57, n. 5, p. 1445-1467, 2019. DOI: 10.1080/00207543.2018.1470057.
- [4] FERNANDES, M.; GAVUZZO, S.; RAMOS, T. Towards enhanced safety stock estimation: Exploring machine learning strategies for supply chain demand forecasting. *Journal of Industrial Information Integration*, v. 18, p. 100126, 2020. DOI: 10.1016/j.jii.2020.100126.
- [5] VARKALYS, M. Machine learning based inventory optimization respecting supplier order line fees. Suécia: KTH Royal Institute of Technology, 2021.
- [6] GONCALVES, J. N. C.; CARVALHO, S. M.; CORTEZ, P. Operations research models and methods for safety stock determination: A review. *ScienceDirect*, 2020.
- [7] HUMAIR, S.; WILLEMS, S. P. Optimizing strategic safety stock placement in supply chains with clusters of commonality. *European Journal of Operational Research*, v. 282, n. 3, p. 884-897, 2020. DOI: 10.1016/j.ejor.2019.09.026.
- [8] PIRES, S. R. I.; CAUCHICK MIGUEL, P. A. *Gestão de estoques em cadeias de suprimentos*. São Paulo: Atlas, 2010.
- [9] GONZÁLEZ, E. M.; GONZÁLEZ, E. L. Evaluation of safety stock management models in a perishable food supply chain. *Journal of Cleaner Production*, v. 232, p. 326-339, 2019. DOI: 10.1016/j.jclepro.2019.05.326.
- [10] NAHMIA, S. *Production and Operations Analysis*. Nova York: McGraw-Hill, 2015.
- [11] MENTZER, J. T. *et al.* Defining supply chain management. *Journal of Business Logistics*, v. 22, n. 2, p. 1-25, 2001.
- [12] FLEURY, P.; RIBEIRO, M. *Gestão de estoques na cadeia de logística integrada*. São Paulo: Atlas, 2017.
- [13] SLACK, N.; CHAMBERS, S.; JOHNSTON, R. *Administração da produção*. São Paulo: Atlas, 2019.
- [14] JACOBS, F. R.; CHASE, R. B.; LUMMUS, R. R. *Administração da Cadeia de Suprimentos e Operações*. Porto Alegre: Bookman, 2017.
- [15] RUSSELL, S. J.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. Pearson, 2016.
- [16] HAYKIN, S. *Neural networks and learning machines (Vol. 3)*. Pearson, 2009.
- [17] SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.; *Redes Neurais Artificiais para engenharia e ciências aplicadas*, Artliber, 2010.
- [18] KRÖSE, B. SMAGT, P. van der. *An introduction to Neural Networks*. The University of Amsterdam, v. 8, 1996.
- [19] LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436-444, 2015.
- [20] Clustering. <<https://scikit-learn.org/stable/modules/clustering.html>>, Online, acessado em 06/07/2023.
- [21] BHOLOWALIA, P. KUMAR, A. EBK-Means: A Clustering Technique based on Elbow Method and K-Means in WSN. *International Journal of Computer Applications*, v.105, 2014.
- [22] Elbow Method. <<https://towardsdatascience.com/elbow-method-is-not-sufficient-to-find-best-k-in-k-means-clustering-fc820da0631d>>, Online, acessado em 08/07/2023.

- [23] Como definir o número de clusters para o seu KMeans. <<https://medium.com/pizzadedados/kmeans-e-metodo-do-cotovelo-94ded9fdf3a9>>, Online, acessado em 08/07/2023.
- [24] QUINLAN, J. R. Induction of decision trees. Machine Learning, v. 1, n. 1, p. 81-106, 1986.
- [25] Colab, <<https://colab.google/>>, Online, acessado em 28/06/2023.
- [26] sklearn.preprocessing.StandardScaler. <<https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>>, Online, acessado em 06/07/2023.
- [27] sklearn.cluster.KMeans. <<https://scikit-learn.org/stable/modules/generated/sklearn.cluster.KMeans.html#sklearn.cluster.KMeans>>, Online, acessado em 08/07/2023.
- [28] scikit-learn. <<https://scikit-learn.org/stable/index.html>>, Online, acessado em 08/07/2023.
- [29] sklearn.cluster.AffinityPropagation, <<https://scikit-learn.org/stable/modules/generated/sklearn.cluster.AffinityPropagation.html#sklearn.cluster.AffinityPropagation>>, Online, acessado em 08/07/2023.
- [30] sklearn.cluster.MeanShift, <<https://scikit-learn.org/stable/modules/generated/sklearn.cluster.MeanShift.html#sklearn.cluster.MeanShift>>, Online, acessado em 08/07/2023.
- [31] sklearn.cluster.AgglomerativeClustering, <<https://scikit-learn.org/stable/modules/generated/sklearn.cluster.AgglomerativeClustering.html#sklearn.cluster.AgglomerativeClustering>>, Online, acessado em 08/07/2023.
- [32] ACHEN, C. H. Measuring Representation: Perils of the Correlation Coefficient. American Journal of Political Science, v.21, 1977.