

Modelos Preditivos para o Setor Têxtil: estudo de caso de uma empresa de confecções do polo Agreste de Pernambuco

Henrique Pablo Pinheiro dos Santos Pimentel, Universidade Federal Rural de Pernambuco
<https://www.orcid.org/0000-0002-9327-2261> - henrique__pablo@hotmail.com

Edson Moura Silva, Universidade Federal Rural de Pernambuco
<https://www.orcid.org/0000-0001-8084-610X> - edsoninhomais@gmail.com

Ermeson Carneiro de Andrade, Universidade Federal Rural de Pernambuco
<https://www.orcid.org/0000-0002-9614-4492> - ermeson.andrade@ufrpe.br

Danilo Ricardo Barbosa de Araújo, Universidade Federal Rural de Pernambuco
<https://www.orcid.org/0000-0002-4822-0390> - danilo.araujo@ufrpe.br

Resumo – O setor têxtil tem apresentado crescimento constante nos últimos anos e o Brasil ocupa a quarta posição mundial no nicho de vestuário. A crescente demanda de têxteis reforça a importância de tecnologias e sistemas inteligentes que contribuam para a continuidade de expansão do setor. Neste sentido, este artigo analisa diferentes abordagens para predição de variáveis importantes para uma empresa têxtil, de modo a permitir o uso dos modelos preditivos obtidos como auxiliares em futuras ferramentas de otimização e planejamento. Foi desenvolvido um sistema com interface gráfica para facilitar a visualização e manipulação dos dados e a proposta foi avaliada com sobre os dados de uma empresa do Polo Agreste considerando a técnica de predição com melhor desempenho nos estudos anteriores. Os resultados obtidos reforçam que a abordagem é promissora, apresentando um erro quadrático médio de $1,20 \times 10^{-2}$ para a predição do valor total produzido e $4,37 \times 10^{-2}$ para o custo de produção.

Palavras-chave: Indústria Têxtil, Inteligência Artificial, Predição.

Forecasting for the Textile Sector: Case Study for a Clothing Company at the Agreste Pole of Pernambuco

Abstract – The textile sector has shown constant growth in recent years and Brazil occupies the fourth position in the world in the clothing niche. The growing demand for textiles reinforces the importance of technologies and intelligent systems that contribute to the continued expansion of the sector. In this sense, this paper analyzes different approaches for predicting important variables for a textile company, in order to allow the use of the predictive models obtained as auxiliaries in future optimization and planning tools. A system with graphical interface was developed to facilitate the visualization and manipulation of the data and the proposal was evaluated on the data of a partner company of the Polo Agreste considering the technique with better performance according to previous studies. The results obtained reinforce that the approach is promising, presenting a mean square error of 1.20×10^{-2} for the prediction of the value produced and 4.37×10^{-2} for the production cost.

Keywords: Textile Industry, Artificial Intelligence, Forecasting.

Data da Submissão: 31/8/2022

Data de aceitação: 08/12/2022

Este artigo está licenciado sob forma de uma licença Creative Commons
Atribuição-Não Comercial-Sem Derivações 4.0 Internacional (CC BY-NC-ND 4.0).

<https://creativecommons.org/licenses/by-nc-nd/4.0/>

<https://doi.org/10.51359/2317-0115.2022.256847>



1. Introdução

O setor têxtil está crescendo como um todo dentro dos parâmetros industriais. De acordo com dados atualizados em fevereiro de 2022, o Brasil o está entre os quatro maiores produtores de malha do mundo e entre os cinco maiores produtores de denim. Além disso, o setor têxtil é o segundo maior empregador da indústria de transformação nacional, perdendo apenas para alimentos e bebidas (juntos) (ABIT, 2022).

O consumo histórico de têxteis continua em crescente expansão e o setor é identificado como um dos responsáveis pela retomada econômica pós-pandemia. Nesse contexto, a tendência para o setor nos próximos anos é associar automação de processos e sustentabilidade. Mais especificamente, a indústria têxtil nacional possui muito espaço para aplicação dos conceitos de indústria 4.0, minimização de impacto ambiental decorrente das fábricas do setor, melhoria da experiência do consumidor e vestuário inteligente (LUIS, 2022).

O planejamento da produção e outros eventos decisórios em uma empresa do setor têxtil geralmente é realizado por meio da experiência prévia dos envolvidos, expectativa subjetiva de demandas de consumo, proximidade de datas comemorativas, e assim por diante. Ou seja, há uma carência de estudos e soluções que possam fornecer de forma automática indicadores objetivos que possam auxiliar o tomador de decisão no processo de planejamento de produção e investimentos de uma empresa do setor. Um exemplo de iniciativa neste sentido seria a criação de modelos preditivos para alinhar o número de peças a serem produzidas em um intervalo de tempo considerando uma expectativa de demanda, evitando assim o desperdício de matéria prima e da força de trabalho.

A produção têxtil local, por mais que faça uso de recursos fabris e máquinas modernas, está associada com um processo complexo e que se utiliza de intervenção humana em várias etapas de confecção. Com o auxílio de modelos preditivos é possível aferir com mais precisão aspectos diversos do processo, como por exemplo o estoque de matéria-prima e tempo em cada etapa da produção, considerando as peças previstas para um dado mês (CAY, 2007). A principal hipótese deste trabalho é de que as técnicas de aprendizagem de máquina podem ser úteis para relacionar diversas métricas da etapa de produção, permitindo uma otimização inteligente futura do processo completo.

Diversos domínios de aplicação têm se beneficiado com o uso de técnicas de inteligência artificial (IA) (DOLLIN, 2021) e o setor têxtil também tem sido beneficiado por tais técnicas sob algumas perspectivas, como em (KAPUT, 2022) e (YASIR, 2022). Muitos estudos no setor procuraram aplicar técnicas de inteligência artificial para apoiar o conceito de vestuário inteligente, algumas vezes em cenários associados com Internet das coisas (IoT) e considerando que as peças de roupa possam estar conectadas à Internet. Neste sentido, Fernández-Caramés e Fraga-Lamas (FERNÁNDEZ-CARAMÉS; FRAGAS-LAMAS, 2018) fornecem um panorama geral da área, apresentando os principais requisitos para o desenvolvimento deste tipo de

vestuário e o potencial do setor de vestuário inteligente, incluindo propostas de modelos de negócio. Wei (WEI, 2018) também se propõe a introduzir o potencial de IA em vestuário inteligente, apresentando as principais tendências e elementos-chave de projeto para aplicação de IA no setor. Contudo, embora o setor de vestuário inteligente seja promissor, o setor têxtil tradicional e da forma como conhecemos hoje pode ser igualmente beneficiado por técnicas de IA. Wong e Chan (2001) aplicaram algoritmos genéticos no planejamento do processo de manufatura para indústria têxtil. Em (SUZUKI, 2011) é feita uma explanação extensa sobre a aplicação de redes neurais artificiais (SIKKA, 2022) em aplicações de Engenharia de Controle e Industrial e três capítulos inteiros são devotados para a indústria têxtil. Huang e Liu (2017) estudaram a predição de vendas para novos produtos de vestuário e realizaram um estudo de caso com uma empresa canadense (HUANG; LIU, 2017). Embora possam ser citados diversos estudos no setor, há uma carência de estudos que se proponham a aplicar propostas inteligentes que considerem a realidade de empresas do setor têxtil regionais. Por exemplo, as empresas de pequeno e médio porte do Polo Agreste do Estado de Pernambuco possuem várias especificidades em comparação com grandes empresas internacionais, como: volume de produção; capacidade logística local; especificidades na matéria-prima base para a fabricação dos produtos; qualidade e atualidade do maquinário e assim por diante (LIMA, 2019).

Neste artigo foi avaliada a eficiência de modelos baseados em rede neural artificial (RNA) para predição de métricas de produção e vendas em comparação com técnicas clássicas, ilustrando os resultados do estudo para uma empresa têxtil local que foi parceira na pesquisa. O melhor modelo de RNA obtido poderá ser usado como um meta-modelo (*surrogate model*) em futuras ferramentas de otimização e planejamento para o setor têxtil. Os resultados obtidos reforçam que a abordagem é promissora, apresentando um erro quadrático médio de $1,20 \times 10^{-2}$ para a predição do valor total produzido e $4,37 \times 10^{-2}$ para o custo de produção. o restante do trabalho está organizado da seguinte forma: a seção 2 apresenta os trabalhos relacionados a esta pesquisa; a seção 3 detalha a metodologia usada no trabalho; a seção 4 apresenta os resultados; a seção 5 faz as considerações finais, incluindo sugestão de trabalhos futuros.

2. Trabalhos Relacionados

Com o objetivo de identificar os principais problemas enfrentados pela indústria têxtil (CAY, 2007) e lacunas tecnológicas, foi realizada uma pesquisa bibliográfica empírica, incorporando termos de busca ligados ao setor pesquisado, à indústria 4.0, e ao uso de inteligência artificial na área em questão. Exemplos de trabalhos encontrados nessa linha incluem desde preocupações com a matéria-prima (SIKKA, 2022) até o processo de vendas das peças confeccionadas (YULDOSHEV, 2018).

Yuldoshev (2018) foca no uso de IA para o planejamento operacional do setor têxtil. Neste trabalho foi considerado o gerenciamento de uma empresa em vários níveis, como: administração de pessoal, administração de recursos, e assim por diante. Dentre os diversos níveis considerou-se o algoritmo de IA mais adequado em termos de tempo de execução, custo e otimização do processo em cada nível. Os algoritmos considerados foram: algoritmo de inteligência de formigas (ACO); o algoritmo genético; e redes neurais artificiais. ACO é um algoritmo que permite encontrar o caminho mais rápido entre uma origem e destino. O algoritmo genético realiza busca por meio de evolução contínua de soluções candidatas, inspirado na teoria da evolução das espécies. A técnica de redes neurais artificiais (RNA) inspira-se no sistema neural humano para criação de modelos que podem aproximar relações

não lineares entre diversas grandezas. No artigo foi usada uma RNA simples composta por 3 camadas.

O estudo de Sikka (2022) apresentou um enfoque de uso de IA para validação e coloração de tecidos. No trabalho foi utilizado uma RNA para desenvolver um método de mistura de cores de forma mais precisa e conseguir prever diversas combinações futuras antes mesmo delas serem fisicamente estabelecidas. Além disso, também foi utilizada a técnica de processamento de imagens em conjunto com a RNA para realizar a validação na coloração das peças. O estudo considerou mais de 1430 peças de roupas com 10 cores cada para treinamento, resultando em apenas 1% de falha nas peças de algodão. Por fim, os resultados obtidos pela técnica proposta foram comparados com a inspeção visual de especialistas da área.

Finalmente, o trabalho apresentado por Cay (2007) focou na predição da permeabilidade do ar nas roupas e diversos modelos preditivos são considerados. No artigo é conduzido um estudo sobre a relação do tamanho dos poros do tecido com a permeabilidade do ar nas roupas. Para a tarefa de predição foi utilizada RNA, considerando no treinamento dados como largura, espessura e massa por unidade de área dos fios, e tendo como comparação a quantidade de água remanescente. Foram consideradas 30 peças de roupa com 6 tipos diferentes de espessura e 5 tipos diferentes de largura dos fios, deixados estes encharcados em uma banheira e passados pelo processo de secagem a vácuo. O modelo treinado permitiu o patamar 3,3% de variação de permeabilidade em todos os casos de teste.

Embora possam ser citados diversos estudos no setor, há uma carência de estudos que se proponham a aplicar propostas inteligentes que considerem a realidade de empresas do setor têxtil regionais. Por exemplo, as empresas de pequeno e médio porte do Polo Agreste do Estado de Pernambuco possuem várias especificidades em comparação com grandes empresas internacionais, como: volume de produção; capacidade logística local; especificidades na matéria-prima base para a fabricação dos produtos; qualidade e atualidade do maquinário e assim por diante (LIMA, 2019). Além disso, os trabalhos levantados não apresentaram um estudo paramétrico detalhado sobre o melhor modelo de RNA a ser escolhido para um problema semelhante. Este trabalho representa esforços iniciais neste sentido e a partir dos modelos preditivos obtidos já é possível direcionar novos estudos com foco em otimização da produção.

3. Metodologia

Este trabalho foi realizado com base em pesquisa bibliográfica e experimental, sendo os experimentos realizados por simulações computacionais e técnicas de IA. Foi usada uma abordagem qualitativa e quantitativa na qual além de explicar os métodos utilizados e o motivo da utilização de cada um deles, apresentou resultados numéricos que sustentam a utilização desses métodos (TUMELERO, 2019). Uma visão geral da metodologia usada pode ser visualizada na figura 1.

A primeira parte desta pesquisa considerou um levantamento bibliográfico sobre fundamentos e técnicas de IA em geral, sendo elas desde as mais tradicionais como regressão linear e árvores de decisão até técnicas mais atuais como as redes neurais, além disso, foi realizado um levantamento sobre trabalhos relacionados ao uso de tecnologia no setor têxtil. Em seguida foi realizada reuniões com parceiros regionais do setor para apresentar o projeto de pesquisa e estabelecer uma parceria que viabilizasse a aplicação das técnicas de IA em um cenário prático real e regional. Após a confirmação da cooperação com uma empresa do Polo Agreste de confecções do Estado de Pernambuco, foi produzido um sistema com interface

gráfica com funcionalidades básicas para facilitar a visualização e organização dos dados importados da fábrica desta empresa. O sistema foi feito na linguagem *Python* (PYTHON, 2022), que foi a linguagem utilizada para realização dos experimentos dos modelos de IA, com uso da biblioteca *Tkinter* (TKINTER, 2022) para a criação da interface gráfica.

Figura 1. Visão geral da metodologia usada na pesquisa.



Depois de desenvolver a interface gráfica do sistema, as técnicas de regressão/predição foram incorporadas ao sistema, incluindo: regressão linear; árvore de decisão; *random forest* com e sem *gridsearch*; ARIMA; e redes neurais artificiais. Após ser realizado os testes com cada modelo citado anteriormente, o modelo de RNA obteve o melhor resultado baseado em uma base de dados pública americana, sendo ele o escolhido para a realização dos testes com os dados reais da empresa local.

Após a escolha do modelo de IA para regressão/predição que seria utilizado, foi feito um tratamento nos dados da fábrica de duas linhas de produção da empresa parceira (dois produtos/vestuários diferentes) e aplicado esses dados no *software* de predição baseado em redes neurais. Os testes foram realizados utilizando uma coluna da tabela como resultado a ser predito e as outras colunas para treinamento do modelo. Além disso, todos os dados foram normalizados para evitar que números muito grandes ou muito pequenos atrapalhem na aprendizagem supervisionada e no resultado final.

Por fim, a maioria das avaliações de soluções / algoritmos considerou uma análise quantitativa das métricas relacionadas a cada cenário, sendo esses algoritmos de aprendizado para aproximação de função gerando relatório de pontuação de correlação (*R2-score*), erros quadráticos médios (MSE) e raiz de erros quadráticos médios (RMSE) (JIERULA, 2021). Além disso, todos os novos algoritmos produzidos nessa pesquisa estarão disponíveis na Internet usando repositórios públicos como o GIT. Isso ajuda a garantir à pesquisa é reproduzível. Foram utilizados de forma acessória na pesquisa, principalmente para a divulgação científica, *software*

de uso geral como MS Office®, Google Workspace® e assim por diante. A seguir será feito um maior detalhamento de algumas etapas específicas do processo.

3.1 Revisão bibliográfica e estudos

Com o objetivo de identificar os principais problemas enfrentados pela indústria têxtil (CAY, 2007) e lacunas tecnológicas, foi realizada uma pesquisa bibliográfica empírica, incorporando termos de busca ligados ao setor pesquisado, à indústria 4.0, e ao uso de inteligência artificial na área em questão. Exemplos de trabalhos encontrados nessa linha incluem desde preocupações com a matéria-prima até o processo de vendas das peças confeccionadas. Sabendo do benefício em potencial do uso de IA para as empresas do setor têxtil, foi realizada uma pesquisa mais aprofundada sobre como IA vem sendo aplicada atualmente na área e os avanços sobre técnicas para regressão/predição.

Logo, uma parte desse estudo foi para atualização sobre as técnicas de IA no geral, sendo utilizado como base de estudo de Keras (2021) e o de Tensorflow (2021). Tensorflow (2021) é uma biblioteca de código aberto criada para aprendizado de máquina, computação numérica e muitas outras tarefas e o Keras (2021) é uma API alto-nível para construir e treinar modelos no *TensorFlow*. Além disso, o estudo bibliográfico também incorporou a busca por alternativas técnicas para implementação do sistema em si e da interface gráfica. Várias alternativas foram levadas em consideração como o Kotlin (2022) que é uma linguagem de tipos estáticos e por isso fornece algumas vantagens como segurança e desempenho; e a API *swing* (JAVA SWING, 2022) que é uma API que fornece vários componentes padrão de uma *graphic user interface* (GUI) que podem ser combinados para criar sua interface. Como opção escolhida, ficou a biblioteca Tkinter (2022) da linguagem *Python* (2022). De forma complementar, foram levantadas alternativas para manipulação de dados estruturados, como o formato CSV (2022), e conversores de arquivo, visto que os dados da empresa parceira vinham em formato não-estruturado PDF. Neste eixo foi considerado o *pdftable_api* (PDFTABLE, 2022) e o Tabulasy (TABULAS-PY, 2022). No estudo sobre manipulação de dados também foram consideradas técnicas para pré-análise dos dados, incluindo o uso do conceito de matriz de correlação de Pearson (BOCK, 2018).

3.2 Dados usados para treinamento e validação dos algoritmos considerados

Uma etapa preliminar do estudo foi realizada sobre bases de dados públicas como uma base de vendas do setor têxtil nos Estados Unidos (KAGGLE, 2022). Essa fase preliminar permitiu uma análise geral das técnicas de regressão/predição quando aplicadas aos dados têxteis, embora ainda não contextualizados para uma empresa regional. A partir das conclusões obtidas após esse estudo preliminar, um estudo mais aprofundado foi realizado com os dados de uma empresa parceira.

Foi recebido dados de duas linhas de produção de uma empresa do estado de Pernambuco que continham diversas informações sobre a produção mês a mês da fábrica. A base de dados continha informações sobre matéria-prima, cor, custo, quantidade etc. Inicialmente, foi realizada uma filtragem nos dados para permanecer apenas com os dados relevantes para o modelo. Dessa forma, o *dataset* usado na pesquisa ficou com as seguintes informações: data, peças produzidas, quantidade de materiais utilizados e valor dos materiais utilizados.

Na figura 2 é apresentado um recorte dos dados da linha de produção de um produto A da empresa e na figura 3 é apresentado um recorte dos dados da linha de produção de um produto B da empresa. Os *datasets* usados representam 6 meses de operação da fábrica e as imagens ilustrativas apresentam os dados normalizados, devido a questões de sigilo/confidencialidade do termo de parceria.

Figura 2. Recorte de dados do *dataset* da linha de produção do produto A.

Data	PecasProd	QtdMaterias	ValorMaterias
01-04-2021	4.570	134.323,75	46.824,40
01-05-2021	19.051	275.444,02	143.806,43
01-06-2021	27.814	569.154,31	259.345,78
01-07-2021	29.555	469.722,25	291.356,86
01-08-2021	36.573	655.979,45	356.218,50
01-09-2021	18.654	1.587.538,37	5.529.876,50

Fonte: Captura de tela da interface do sistema desenvolvido para a pesquisa (2022).

Figura 3. Recorte de dados do *dataset* da linha de produção do produto B.

Data	PecasProd	QtdMaterias	ValorMaterias
01/04/2021	4.424	46.877,85	11.977,36
01/05/2021	15.135	376.052,95	105.870,10
01/06/2021	12.872	276.926,78	68.096,08
01/07/2021	21.862	581.471,76	160.063,97
01/08/2021	20.467	596.359,37	187.523,99
01/09/2021	32.831	532.404,74	370.718,30

Fonte: Captura de tela da interface do sistema desenvolvido para a pesquisa (2022).

3.3 Desenvolvimento de *software* para visualização e manipulação dos dados

Como forma de facilitar o acesso e deixar mais organizada a visualização dos dados e das predições para os tomadores de decisão, foi levantada a ideia da produção de um *software* com interface gráfica. Além disso, as bibliotecas de IA disponíveis na maior parte das vezes aceitam apenas dados estruturados (como arquivos CSV, por exemplo), e os dados brutos oferecidos pelo *software* de gestão original da empresa parceira estavam em formato PDF.

Portanto, a fase de concepção do *software* considerou funcionalidades básicas que seriam importantes para viabilizar o uso de técnicas inteligentes e oferecer um uso intuitivo para o tomador de decisão. Nesta linha, foi criado um protótipo de baixa fidelidade destacando as funções básicas para só depois ser iniciada a construção do *software* em si. O *software* com interface gráfica consistiu em um aplicativo *desktop* acessível via usuário e senha, um menu administrativo, menu de ferramentas e um menu de ajuda. No menu administrativo contém as opções de converter dados, importar dados, treinar modelo, configurações. O menu de ferramentas possui o prognóstico de vendas, otimização operacional, gráficos, tabelas. Um menu de ajuda simples possui uma tela de créditos/contato e opção de sair da aplicação.

O aplicativo foi desenvolvido em *Python* (PYTHON, 2022) já que os modelos de IA já tinham sido desenvolvidos nessa mesma linguagem. A interface gráfica foi feita a partir da biblioteca *Tkinter* (TKINTER, 2022). Na opção de conversão dos dados só são aceitos arquivos

no formato PDF, que é compatível com o leiaute do software de gestão da empresa parceira, essa função serve para converter os arquivos do formato PDF para o formato CSV, gerando um novo arquivo no formato CSV no final. Contudo, conversões para outros formatos não previstos correspondem a uma etapa simples, que pode ser realizada futuramente. A título de ilustração, a figura 4 contém um exemplo de tela do sistema desenvolvido.

Figura 4. Exemplo de tela do sistema.

MATÉRIA-PRIMA	COR	TAMANHO	UN
022991 - PLACA	OV - OURO VELHO	UN	UN
024058 - FLOR	DR - DOURADO	UN	UN
10115/18 - BOTÃO TAM 18	FO - FOSCO	UN	UN
10115/24 - BOTÃO TAM 24	FO - FOSCO	UN	UN
1041 - CHANEL	BR - BRANCO	UN	UN
	GO - GOIABA	UN	UN
	RS - ROSA	UN	UN
1071002931 - RIBANA 2X1	A/P - ALHOV/PRETO	KG	KG
1181 - PLACA TAM 42	PA - PRATA	UN	UN
	RS - ROSA	UN	UN
118201325 - COTTON RAPPORT DIBÉ	1367 - FOSCO/NATURAL	KG	KG
	16050 - INDIGO/MESCLA	KG	KG
1185 - RIBANA 5X1 PA	20553 - MARINHO 20553	KG	KG
	21509 - ROSA 21509	KG	KG
	21516 - BORDO 21516	KG	KG
	21524 - CORAL 21524	KG	KG
	27 - PRETO 27	KG	KG
	7803 - GOIABA 7803	KG	KG
11911/20 - CORAÇÃO TAM 20	BR - BRANCO	UN	UN
1193004259 - GOLA LISA 26/66	35529 - PRETO/SUMAC	UN	KG
	35536 - HAMUS/MARINHO	UN	KG
119301929 - JACQUARD MAHAM	21120 - DARK 21120	KG	KG
	23021 - CRAVO 23021	KG	KG
119301933 - CREPE COLOR	20110 - PRETO 20110	KG	KG

Fonte: Captura da tela do protótipo desenvolvido para a pesquisa (2022).

3.4 Arranjo experimental

Dois principais fatores para a construção de um modelo preditivo baseado em RNA são: a seleção e organização dos dados para aprendizado; e a escolha dos parâmetros. O processo decisório e variações consideradas sobre esses dois aspectos será detalhado a seguir.

A primeira ação sobre a análise dos dados obtidos foi elaborar uma matriz de correlação entre as colunas a fim de verificar a relação inicial entre os dados disponíveis. O modelo de correlação utilizado foi a correlação de Pearson e os dados que possuíam correlação próxima a 1 ou -1 entre si foram desprezados para efeito de treinamento dos modelos preditivos, visto que iriam acrescentar pouca capacidade explicativa ao modelo final (BOCK, 2018). A ilustração gráfica da matriz de correlação está na figura 5. Os dados da figura 5 foram obtidos diretamente a partir da aplicação da correlação de *Pearson* sobre os dados de produção da empresa parceira.

Figura 5. Ilustração da matriz de correlação dos dados.



Para a parametrização dos modelos, foram considerados parâmetros numéricos e simbólicos importantes para o tipo de abordagem adotada. Por limitação de escopo e de espaço, não foi detalhado o referencial teórico subjacente aos parâmetros estudados, mas o leitor poderá obter mais informações a partir de referências teóricas de base sobre Inteligência Artificial, como em Sarkar (2018). Foram analisados os parâmetros de número de camadas ocultas, máximo de interações, ativação, frequência de aprendizado, *tol*, parada antecipada e número de interações sem mudança. Com relação ao número de camadas ocultas e quantos nós teriam em cada camada foi considerado primeiro com 2 camadas ocultas com 10, 50, 100 e 200 nós em cada uma das camadas, tendo os melhores resultados as de valores mais alto 50, 100 e 200. A mudança de 50 para 100 já apresentou uma diferença notável, enquanto a comparação entre 100 e 200 praticamente não resultou em ganhos. Logo, o parâmetro escolhido foi o de 100 nós por camada interna. Já para quantidade de camadas foram consideradas 1, 2, 4 e 8, sendo 4 e 8 possuindo os melhores resultados. Logo, mesmo possuindo diferença marginal entre 4 e 8 camadas, adotou-se 4 camadas internas com 100 nós cada levando em consideração o compromisso com o esforço computacional.

Sabendo que um modelo de rede neural, ao realizar ajustes excessivos aos dados apresentados perde a capacidade de generalização, esse efeito foi considerado como critério de parada. O número máximo de iterações foi estudado com 100, 500 e 1000, de modo a impor um limite máximo ao processamento e o número de iterações sem mudança foi estudado com 10, 20 e 50, sendo a diferença considerável entre 10 e 20 e uma diferença irrelevante na comparação entre 20 e 50. Finalmente, decidiu-se por 1000 iterações máximas com 20 iterações sem mudanças para interrupção antecipada.

Sobre o método de ativação foi decidido usar RELU, visto o seu desempenho. Já a frequência de aprendizado, foi testada com a frequência *constant* e *adaptive*, onde o

aprendizado *constant* é incrementado baseado numa taxa de aprendizado inicial fixa, enquanto o aprendizado *adaptive* ajusta essa taxa com o passar das iterações.

4. Resultados


Existem duas principais possibilidades sobre a estratégia de produção de uma empresa do setor têxtil. É possível trabalhar com produção baseada em previsões de demanda e expectativa de consumo (procedimento de produção predominantemente empurrado) ou produção sob encomenda (possivelmente *customizada*). A empresa parceira se posiciona predominantemente com produção sob encomenda, proveniente de contratos estabelecidos pelos representantes comerciais. Contudo, para que esta pesquisa científica possua um caráter mais abrangente, foi feito o estudo de predição considerando diferentes variáveis resposta, de modo a simular um ambiente de produção por expectativa de consumo ou por encomenda.

Quando uma empresa produz um quantitativo de peças que serão postas à venda (procedimento de produção predominantemente empurrado), a predição do valor total ideal a ser produzido é muito importante, pois evita desperdícios e custos com estoques. Então considerando inicialmente o valor total produzido como variável-reposta, o melhor modelo preditivo obtido no estudo se mostrou bastante efetivo, visto que possui um erro quadrático médio (MSE) de 8,0385 versus 10^{-3} e uma correlação entre o resultado previsto e o resultado real de 99,21%, conforme é apresentado nas primeiras 3 linhas da tabela 1. Os dados da tabela 1 representam o valor médio de 1000 execuções independentes do treinamento da RNA.

Tabela 1 – Indicadores quantitativos da precisão dos modelos preditivos baseados em RNA para duas variáveis-reposta estudadas.

Variável resposta	Indicador	Média	Desvio padrão
Valor total produzido	MSE	$8,0385 * 10^{-3}$	$1,1077 * 10^{-2}$
	RMSE	$7,7169 * 10^{-2}$	$4,5644 * 10^{-2}$
	Rscore	$9,9210 * 10^{-1}$	$1,0649 * 10^{-2}$
Custo de produção	MSE	$4,3087 * 10^{-2}$	$5,6789 * 10^{-3}$
	RMSE	$2,0714 * 10^{-1}$	$1,3396 * 10^{-2}$
	Rscore	$9,5684 * 10^{-1}$	$5,4479 * 10^{-3}$

Figura 6. Gráfico de convergência do processo de treinamento da RNA.



(a) Melhor arquitetura de RNA obtida.

(b) Arranjo de 10 neurônios em 4 camadas.

Por outro lado, quando uma empresa produz a partir de uma demanda já estabelecida por contrato de representação comercial, a predição de variáveis como o custo é extremamente útil, já que é possível alocar um quantitativo adequado de recursos para cada produto. Sob esta perspectiva, o modelo preditivo baseado em RNA é bastante efetivo, visto que foi obtido um MSE de $4,3087 \times 10^{-2}$ e uma correlação entre os resultados de 95,66%, conforme é apresentado nas 3 últimas linhas da tabela 1.


Os dados da tabela 1 representam o desempenho dos modelos ao final do processo de treinamento. Contudo, uma análise importante diz respeito ao decaimento do erro ao longo das iterações, bem como o incremento do *RScore* ao longo do processo, de modo a explicitar que os modelos preditivos convergiram durante o treinamento. A figura 6 apresenta exemplos de curvas de elevação do *RScore* versus iterações e a diminuição do erro ao longo das iterações. Além disso, este trabalho conduziu uma análise paramétrica detalhada sobre a melhor configuração de RNA a ser utilizada.

A figura 6(a) apresenta a curva de convergência para a melhor configuração de RNA alcançada (4 camadas e 100 neurônios em cada). A figura 6(b) apresenta um exemplo de uma dentre as diversas configurações avaliadas, que se mostrou inferior. Perceba que é desejável obter um modelo com o valor do indicador *RScore* próximo de 1,0 para indicar que o modelo possui capacidade explicativa máxima sobre os dados apresentados, bem como o erro residual deve estar próximo ao valor zero. É possível perceber pela figura 6(a) que as curvas convergem para uma assíntota horizontal e próxima aos valores 1,0 e 0,0, conforme esperado. Ao comparar o gráfico das figuras 6(a) e 6(b) é notável a vantagem no uso do modelo obtido a partir da arquitetura de RNA com 100 neurônios.

Finalmente, é importante ilustrar a vantagem no uso de uma técnica como RNA em comparação com uma técnica de regressão clássica e mais simples como regressão linear.


A figura 7 ilustra a aproximação do valor total produzido por uma reta. Embora a aproximação possa parecer razoavelmente eficaz, um *zoom* nas amostras próximas ao ponto (0, 0) demonstra que os pontos estão muito afastados da reta, o que favorece uma técnica que consegue estabelecer relações não lineares como a RNA.

Figura 7. Ilustração da aproximação do valor total produzido usando uma reta.



A vantagem no uso da RNA fica ainda mais evidente na figura 8, que apresenta a ilustração de aproximação do custo de produção por uma reta. Por inspeção visual, é possível perceber que diversos pontos estão afastados da melhor reta obtida.

Figura 8. Ilustração da aproximação do custo de produção usando uma reta.



5. Conclusões

Este trabalho propôs modelos preditivos para métricas importantes relacionadas com o processo produtivo de uma empresa do setor têxtil. O estudo considerou diversas abordagens e culminou com o uso de rede neural artificial. Também foi objetivo do estudo encontrar a melhor arquitetura e o melhor conjunto de parâmetros da RNA para o problema considerado. Finalmente, a RNA foi usada para predição do custo total de produção e do valor produzido, considerando o histórico de 6 meses de produção de uma empresa de confecções do Polo Agreste de Pernambuco. Os resultados obtidos são promissores, visto que o melhor modelo estudado apresentou erro quadrático médio (MSE) de $8,04 \times 10^{-3}$ e uma correlação entre o resultado previsto e o resultado real de 99,21%. Estes dados numéricos sugerem que os modelos preditivos podem ser usados futuramente em uma ferramenta de planejamento de operação/produção de uma fábrica têxtil, de modo que o processo de otimização da fábrica faça uso dos modelos preditivos como um direcionador do processo de busca.

Investigações futuras podem considerar outras técnicas para obtenção dos modelos como aprendizagem profunda. Além disso, a metodologia aplicada pode ser reavaliada em outros cenários, envolvendo um período maior de operação da fábrica, bem como dados de outras linhas de produção e de outras empresas.

Referências

- ABIT - Associação Brasileira da Indústria Têxtil e de Confecção. Perfil do Setor. 2022. Disponível em: <https://abit.org.br/cont/perfil-do-setor>. Acesso em: 19/10/2022
- BOCK, Tim. What is a Correlation Matrix. Displayr, 16/08/2018. Disponível em: <https://www.displayr.com/what-is-a-correlation-matrix/>. Acesso em: 10/07/2022

CAY, Ahmet et al. Prediction of the air permeability of woven fabrics using neural networks. *International Journal of Clothing Science and Technology*, v. 19, n. 1, p. 18-35, 2007.

CSV. Disponível em: <https://docs.python.org/pt-br/3/library/csv.html>. Acesso em 09/01/2022.

DOLLIN, Tansim. Top 10 benefits: Take your business to the next level with an AI chatbot. Nice, 2021. Disponível em: <https://www.nice.com/blog/top-10-benefits-take-your-business-to-the-next-level-with-an-ai-chatbot>. Acesso em: 25/07/2022.

FERNÁNDEZ-CARAMÉS, Tiago M.; FRAGA-LAMAS, Paula. Towards the Internet of smart clothing: A review on IoT wearables and garments for creating intelligent connected e-textiles. *Electronics*, v. 7, n. 12, p. 405, 2018.

JAVA SWING. Disponível em: <https://www.devmedia.com.br/java-swing-conheca-os-componentes-jtextfield-e-jformattedtextfield/30981>. Acesso em 09/01/2022

JIERULA, Alipujiang et al. Study on accuracy metrics for evaluating the predictions of damage locations in deep piles using artificial neural networks with acoustic emission data. *Applied Sciences*, v. 11, n. 5, p. 2314, 2021.

HUANG, He; LIU, Qiurui. Intelligent retail forecasting system for new clothing products considering stock-out. *Fibres & Textiles in Eastern Europe*, n. 1 (121), p. 10--16, 2017.

KAGGLE. US Clothing Retail Sales Dataset, 2022. Disponível em: <https://www.kaggle.com/datasets/anuraggupta29/us-clothing-retail-sales-dataset>. Acesso em: 02/09/2022.

KAPUT, Mike. AI for sales: What you need to know. *Marketingaiintitute*, 2022. Disponível em: <https://www.marketingaiinstitute.com/blog/ai-in-sales>. Acesso em: 25/07/2022.

KERAS. Disponível em: <https://keras.io/> Acesso em 07/10/2021.

KOTLIN. Disponível em: <https://kotlinlang.org>. Acesso em 09/01/2022.

LIMA, Ramalho. Representante de importadoras defende zerar taxas de importações. *Tecmundo*, 24/07/2019. Disponível em: <https://www.tecmundo.com.br/mercado/144135-representante-importadoras-defende-zerar-taxa-importacoes.htm>. Acesso em: 20/08/2022

LUIS, Anderson. Indústrias têxteis no Brasil: Perspectiva para 2022. *Labra*, 20/04/2022. Disponível em: <https://blog.labra.com.br/industrias-texteis-no-brasil>. Acesso em: 15/07/2022

PDFTABLE. Disponível em: <https://pdftables.com/pdf-to-excel-api>. Acesso em 09/01/2022.

PYTHON. Disponível em: <https://www.python.org>. Acesso em 09/01/2022.

SARKAR, Dipanjan; BALI, Raghav; SHARMA, Tushar. Practical machine learning with python. *A Problem-Solvers Guide To Building Real-World Intelligent Systems*. Berkely: Apress, 2018.

SUZUKI, Kenji (Ed.). Artificial neural networks: industrial and control engineering applications. *BoD–Books on Demand*, 2011.

SIKKA, Monica Puri; SARKAR, Alok; GARG, Samridhi. Artificial intelligence (AI) in textile industry operational modernization. *Research Journal of Textile and Apparel*, 2022.

TABULAS-PY. Disponível em: <https://pypi.org/project/tabula-py/>. Acesso em 09/01/2022.

TENSORFLOW. Disponível em: <https://www.tensorflow.org/?hl=pt-br> Acesso em 07/10/2021.

TKINTER. Disponível em: <https://docs.python.org/pt-br/3/library/tk.html>. Acesso em 09/01/2022.

TUMELERO, Naína. Um guia rápido sobre metodologia de pesquisa. Mettzer, 25/09/2019. Disponível em: <https://blog.mettzer.com/metodologia-de-pesquisa/>. Acesso em: 17/07/2022

WEI, Xiong. The application and development of artificial intelligence in smart clothing. In: IOP Conference Series: Materials Science and Engineering. IOP Publishing, 2018. p. 012017.

WONG, Wai Keung; CHAN, C. K. An artificial intelligence method for planning the clothing manufacturing process. Journal of the Textile Institute, v. 92, n. 2, p. 168-178, 2001.

YASIR, Muhammad et al. Machine learning–assisted efficient demand forecasting using endogenous and exogenous indicators for the textile industry. International Journal of Logistics Research and Applications, p. 1-20, 2022.

YULDOSHEV, Nuritdin; TURSUNOV, Bobir; QOZOQOV, Saidmuhtor. Use of artificial intelligence methods in operational planning of textile production. Journal of process management and new technologies, v. 6, n. 2, p. 41-51, 2018.