

Pesquisas e Inovações envolvendo Farinha de Trigo: Uma Revisão Sistemática da Literatura

Carla Adriana Pizarro Schmidt, Jandrei Sartori Spancerski, José Airton Azevedo dos Santos, Lucas Marujo, Marcelo Anderson Carlet

Resumo: O objetivo central desse artigo foi de analisar publicações científicas, visando a obtenção de dados suficientes para determinar que tipos de problemas mais afetam o setor industrial que se utiliza da farinha de trigo e se técnicas de inteligência artificial estão sendo utilizadas para solucionar esses problemas. Para tal, foi realizada uma Revisão Sistemática da Literatura, de artigos científicos disponíveis nos bancos de dados *Science Direct* e *Google Scholar*, seguindo regras de busca, inclusão de fontes e exclusão, previamente estabelecidos. Os artigos selecionados forneceram informações relevantes quanto a que tipo de problemática as pesquisas recentes estão focadas em solucionar, bem como quais técnicas de inteligência artificial vêm sendo empregadas. A síntese dos dados coletados permitiu uma visão sistemática da área de estudo da farinha de trigo.

Palavras chave: Farinha de Trigo; Inteligência Artificial; Produção de Conhecimento.

Research and Innovations involving Wheat Flour: a Systematic Literature Review

Abstract: The main objective of this paper was to analyze scientific publications in order to obtain sufficient data to determine which types of problems most affect the industrial sector that uses wheat flour and whether artificial intelligence techniques are being used to solve these problems. For this, a Systematic Literature Review of scientific articles available in the Science Direct and Google Scholar databases was carried out, following previously established search, inclusion and exclusion rules. The selected articles provided relevant information as to what type of issues recent research is focused on solving, as well as which artificial intelligence techniques are being employed. The synthesis of the collected data allowed a systematic view of the study area of wheat flour.

Key-words: Wheat Flour; Artificial Intelligence; Industry.

1. Introdução

Conforme a definição de Dresch, Lacerda e Júnior (2015), a Revisão Sistemática da Literatura (RSL) é uma das etapas fundamentais para o desenvolvimento de pesquisas científicas, pois é a partir desta que se realiza a identificação e apresentação de pesquisas pertinentes que foram desenvolvidas em determinada área, possibilitando assim que o pesquisador tenha uma visão ampla do cenário no qual pretende desenvolver seus estudos.

A presente RSL foi desenvolvida com base em um processo separado por três fases distintas, porém complementares, sendo que cada fase possui pacotes de trabalho a serem cumpridos. Na primeira fase, os pacotes de trabalho são quatro, sendo o primeiro a definição dos objetivos e quais as questões que queremos responder com a pesquisa, precedido das fontes

de busca, da definição da palavra-chave de busca e da definição dos critérios de inclusão, exclusão e qualidade dos artigos.

A segunda fase trata-se da apresentação dos resultados obtidos pela busca, através de números e imagens. A última fase é composta pela aplicação dos critérios de qualidade definidos na fase inicial, análise de todo o material coletado e síntese do conteúdo.

O intuito do presente artigo foi de levantar e analisar os dados referentes às pesquisas mais recentes relacionadas à farinha de trigo utilizadas na indústria, principalmente utilizando-se de técnicas de *machine learning*, trazendo à tona quais os maiores e que tipo de problemas que as mesmas desejam solucionar. Para tanto, realizou-se uma pesquisa de RSL disponível nos motores de busca científicos. A análise foi realizada com base apenas em artigos científicos, tanto nacionais quanto internacionais, publicados no período entre 2015 e 2019, formando assim uma base das mais recentes e relevantes pesquisas na área.

2. Contextualização

De acordo com Brasil (1996, p.1), “entende-se por farinha de trigo o produto obtido a partir da espécie *Triticum seativan* ou de outras espécies do gênero *Triticum* reconhecidas (exceto *Triticum durum*)”, obtida através do processo de moagem.

Esta farinha gerada a partir da moagem dos grãos de trigo beneficiados possui empregos diversos, tanto domésticos quanto industriais, pois com ela faz-se desde ração para animais até bolos, biscoitos e massas, ou seja, a farinha de trigo é um ingrediente presente na alimentação da população do mundo inteiro (SOUZA et al., 2019).

Com base nessas informações, é evidente que avanços científicos com relação à farinha de trigo e outros insumos alimentares geram impacto na cadeia produtiva, e identificar esses avanços agrega valor para pesquisas futuras, afinal, Dresch, Lacerda e Júnior (2015) indicam que as RSL são balizadoras para se ter uma visão abrangente das áreas de pesquisa, sendo que apresentam o que é relevante em cada meio, evitando o desenvolvimento de trabalhos que não geram impacto positivo no meio científico ou profissional.

O objetivo central deste estudo foi de analisar os dados referente à pesquisas que envolvam a farinha de trigo, buscando evidências para identificação de oportunidades de pesquisa, abordagens, processos e métodos utilizados em pesquisas relacionadas à essa área, com enfoque na parte industrial.

3. Materiais e Métodos

Uma revisão sistemática pode ser classificada como uma pesquisa bibliográfica a qual de acordo com Mattar (2017) é um tipo de pesquisa que pode ser realizado em todos os tipos de materiais científicos disponíveis, porém na era digital com a informatização das referências aumentou-se muito a facilidade de realização e a deixou mais rápida, pois na informação eletrônica pode-se pesquisar por palavras e assuntos, com a possibilidade de aplicação dos mais diversos filtros de informações.

Visando a clarificação dos conceitos e o norteamento das etapas subsequentes deste estudo, foram definidas três questões para a pesquisa:

- a) Quais pesquisas envolvendo farinha de trigo estão sendo realizadas?
- b) Existem pesquisas envolvendo inteligência artificial nessa área?
- c) Quais as oportunidades de trabalhos futuros sugeridos pelos autores dos artigos?

Para uma busca mais assertiva de fontes que se relacionam com o assunto do presente trabalho, procurou-se um conjunto de palavras-chave que conseguissem permear as três questões norteadoras.

Para tal, identificou-se que os termos “farinha de trigo”, “aprendizado de máquina” e “indústria” atendem aos critérios supracitados, sendo que para os motores de busca científicos, os termos foram colocados em inglês, sendo “*wheat flour*”, “*machine learning*” e “*industry*”, respectivamente.

Com relação aos motores de busca científicos, foram elencados o *Science Direct* (<https://www.sciencedirect.com/>), base de dados ligada à *Elsevier*, e o *Google Scholar* (<https://scholar.google.com/>), por serem motores de busca gratuitos e que não necessitam de nenhum mecanismo de autenticação para realizar as buscas.

3.1. Critérios de inclusão, exclusão e qualidade adotados

Os critérios adotados para realizar a inclusão de fontes foram:

- a) ser artigo científico de pesquisa;
- b) ter sido publicado no período de 2015 e 2019;
- c) ser relacionado a área de pesquisa do presente artigo.

Em contrapartida, para exclusão de fontes:

- a) artigos que na leitura do resumo não apresentaram uma boa qualidade.

Com relação à qualidade e relevância, as publicações selecionadas foram crivadas de acordo com o Qualis interdisciplinar da revista e fator de impacto pelo SJR, além do assunto abordado, sendo diretamente relacionado à farinha de trigo e inteligência artificial os de maior peso, em alguns momentos os filtros das ferramentas de busca em relação a relevância foram utilizados.

3.2. Busca e seleção de artigos para a RSL

O processo de busca da fonte, inclusão e exclusão de artigos se dá de forma natural, sendo simultânea em alguns momentos. Esse processo pode ser melhor entendido no decorrer desse trabalho.

Em um primeiro momento, a busca na base de dados utilizando o conjunto de palavras-chave definida é utilizado, já aplicando os primeiros filtros para atender os critérios de período de busca (critério b de inclusão) e tipo de arquivo buscado (critério a de inclusão). Dessa forma, o primeiro grande grupo de artigos potenciais para utilização na presente revisão foi encontrado.

A busca no conjunto de palavras-chave na base de dados *Science Direct* retornou 6 resultados, aplicando-se os filtros de busca para o período e tipo de fonte, conforme representado na Figura 1.

Complementarmente, a busca foi realizada no *Google Scholar*, tendo como retorno 7290 resultados, sendo que foram aplicados os filtros exigidos pelas regras de inclusão de artigos. Como, neste caso, os resultados foram massivos, os autores decidiram fazer a busca apenas até a terceira página de resultados, sendo que foi aplicado o filtro de relevância disponível no buscador, conforme a Figura 2.

The screenshot shows the ScienceDirect search interface. At the top, there is a banner for the IX Congresso Brasileiro de Engenharia de Produção, held in Ponta Grossa, PR, Brazil, from December 4 to 6, 2019. Below the banner, the ScienceDirect logo is visible on the left, and navigation links for 'Journals & Books', 'Create account', and 'Sign in' are on the right. The search bar contains the query: "wheat flour" AND "machine learning" AND "industry". Below the search bar, there are options for 'Advanced search' and 'Set search alert'. The search results are displayed in a list format, showing 6 results. The first result is a research article titled 'Multi-target prediction of wheat flour quality parameters with near infrared spectroscopy' by Sylvio Barbon Junior, Saulo Martiello Mastelini, Ana Paula A. C. Barbon, Douglas Fernandes Barbin, and Alessandro Ulrici. The second result is 'A simple and practical control of the authenticity of organic sugarcane samples based on the use of machine-learning algorithms and trace elements determination by inductively coupled plasma mass spectrometry' by Rommel M. Barbosa, Bruno L. Batista, Camila V. Barão, Renan M. Varrigue, and Fernando Barbosa. The interface also includes filters for 'Refine by: Years' (2019, 2018, 2017, 2016, 2015) and 'Article type' (Review articles, Research articles, Encyclopedia, Book chapters). A 'Sign in' button is prominently displayed in the center of the results area.

Fonte: Autoria Própria, (2019).

Figura 1 – captura da tela de busca no banco de dados Science Direct

The screenshot shows the Google Acadêmico search interface. The search bar contains the query: "wheat flour + machine learning + industry". Below the search bar, there are filters for 'Artigos' (Articles) and 'Meu perfil' (My profile). The search results are displayed in a list format, showing approximately 7.290 results. The first result is 'Predicting consumer healthy choices regarding type 1 wheat flour' by M. Fiore, C. Gallo, E. Tsoukatos, and P. La Sala, published in British Food Journal, 2017. The second result is '[HTML] Multi-target prediction of wheat flour quality parameters with near infrared spectroscopy' by SB Junior, SM Mastelini, APAC Barbon, et al., published in Information Processing, 2019. The third result is 'Terahertz Spectroscopy Determination of Benzoic Acid Additive in Wheat Flour by Machine Learning' by X Sun, K Zhu, J Liu, J Hu, X Jiang, Y Liu, et al., published in Journal of Infrared, 2019. The fourth result is '[HTML] Discovery of food identity markers by metabolomics and machine learning technology' by A Erban, I Fehrlé, F Martínez-Seidel, F Brigante, et al., published in Scientific reports, 2019. The interface also includes filters for 'A qualquer momento' (Any time), 'Desde 2019' (From 2019), 'Desde 2018' (From 2018), 'Desde 2015' (From 2015), 'Período específico...' (Specific period...), 'Classificar por relevância' (Sort by relevance), 'Classificar por data' (Sort by date), 'Em qualquer idioma' (Any language), 'Pesquisar páginas em Português' (Search pages in Portuguese), 'Incluir patentes' (Include patents), 'Incluir citações' (Include citations), and 'Criar alerta' (Create alert).

Fonte: Autoria Própria, (2019).

Figura 2 - captura de tela da busca no banco de dados Google Scholar

Dentre as buscas supracitadas, foram selecionados 12 artigos para leitura, dado que os mesmos artigos apresentados pela plataforma Science Direct também foram apresentados pelo Google Scholar, sendo que os demais foram eliminados pelo critério de inclusão c, apresentado no item 5 deste trabalho.

Os artigos selecionados que suportam todas as regras de inclusão estão indicados no Quadro 1.

Número	Título do Artigo	Ano	Revista	SJR	Qualis
1	Predicting consumer healthy choices regarding type1 wheat flour	2017	British Food Journal	0,49 H 69	B1
2	Evaluation of spectral imaging for inspection of adulterants in terms of common wheat flour, cassava flour and corn flour in organic Avatar wheat (<i>Triticum</i> spp.) flour	2017	Journal of Food Engineering	1,28 H 156	A1
3	Multi-target prediction of wheat flour quality parameters with near infrared spectroscopy	2019	Information Processing in Agriculture	0,57 H 13	N/A
4	Modern practical convolutional neural networks for multivariate regression: applications to NIR calibration	2018	Chemometrics and Intelligent Laboratory Systems	0,74 H 109	A2
5	A simple and practical controlo f the authenticity of organic sugarcane samples based on the use of machine-learning algorithms and trace elements determination by inductively coupled plasma mass spectrometry	2015	Food Chemistry	1,77 H 221	A1
6	Improving the baking quality of bread wheat using rapid tests and genomics: The prediction of dough rheological parameters by gluten peak índices and genomic selection models	2017	Journal of Cereal Science	1,05 H 101	A2
7	GlutoPeak profile analysis for wheat classification: skipping the refinement process	2017	Journal of Cereal Science	1,05 H 101	A2
8	Discovery of food identity markers by metabolomics and machine learning technology	2019	Scientific Reports	1,41 H 149	A1
9	Prediction of properties of wheat dough using inteligente deep belief networks	2017	Journal of Experimental & Theoretical Artificial Intelligence	0,39 H 36	N/A
10	A rapid classification of wheat flour protein content using artificial neural network model based on bioelectrical properties	2018	Telkomnika	0,28 H 16	N/A
11	Computer vision system for characterization of pasta (noodle) composition	2018	Journal of Electronic Imaging	0,24 H 60	N/A
12	Utilising near-infrared hyperspectral imaging to detect low-level peanut poder contamination of whole wheat flour	2019	Biosystems Engineering	0,83 H 95	A2

Fonte: Autoria Própria, (2019).

Quadro 1 - Artigos selecionados e informações de impacto científico para a Revisão Sistemática da Literatura

A respeito dos dados apresentados no Quadro 1, a Qualis apresentada é referente à área interdisciplinar, dado a natureza da pesquisa que envolve a área da computação, alimentos e produção, sendo que as apresentadas como N/A são as não avaliadas nesta área.

7. Resultados e Discussão

Os artigos selecionados foram suficientes para demonstrar a diversidade da pesquisa relacionada à área deste trabalho. Em busca da resposta da primeira pergunta, podemos verificar que de uma certa forma, o enfoque nas pesquisas com farinha de trigo é relacionado ao ambiente laboratorial, tomando medidas desde segurança alimentar, qualidade do produto até otimização de cozimento com a farinha.

Conforme abordado por Su e Sun (2016), que tomaram uma abordagem pela área da segurança alimentar, o mercado busca por um método eficiente que garanta a autenticidade do alimento consumido, sendo que os mesmos utilizaram-se da imagem espectral, obtida pela análise de espectrofotometria (método de análise que se utiliza da medição da absorção da luz por soluções, neste caso, farinha e água), para identificar adulteração de farinha, complementada com farinhas diferentes e de custo menor, mas que geram diferenças significativas quanto à segurança alimentar. Para tratar as imagens espectrais, os mesmos utilizaram modelos matemáticos para realizar regressão parcial dos mínimos quadrados, além de análise dos componentes principais e análise multivariada. O sucesso do trabalho foi de autenticar as amostras com 75% de certeza.

Um dos motivos da assertividade possuir um percentual baixo é o grande número de fatores de influência, sendo que fica impossível realizar o reconhecimento da origem das diferenças entre as adulterações possíveis. Para corrigir este problema, os pesquisadores sugeriram realizar uma abordagem diferente para descobrir as adulterações, buscando controlar mais variáveis que as controladas no estudo, mas utilizando-se de classificadores robustos, gerados com inteligência artificial (SU; SUN, 2016).

Ainda na linha de segurança alimentar, mas agora com um enfoque pelo consumidor, Fiore et al. (2017) investigou os atributos comumente observados às características da farinha de trigo em uma compra (tipo de farinha, embalagem, preço, quantidade em um pacote), implementando um modelo preditivo para a compra, mas que tome decisões corretas sem a necessidade da intervenção de um especialista humano. Os pesquisadores utilizaram-se de mineração de dados para obterem resultados sobre o comportamento de compra da população italiana, informação retirada de um formulário online que os autores elaboraram. O modelo estatístico de comportamento de compra foi realizado utilizando técnicas de aprendizado de máquina. Os resultados obtidos foram basicamente relacionados ao marketing, sendo que descobriram a preferência pela utilização da farinha “tipo 1” dos consumidores, mesmo esses não sabendo quais os benefícios que este tipo de farinha traz em comparação com os demais.

Um trabalho realizado também com segurança alimentar e na área de autenticidade de alimentos, mas com cana-de-açúcar ao invés de farinha de trigo, utilizou algoritmos de aprendizado de máquina para determinar traços de elementos por espectrofotometria. Os resultados obtidos podem ser utilizados em outros alimentos também, sendo que a precisão encontrada foi de 95,4% para a rede neural (BARBOSA et al., 2015).

O sistema de visão computacional também é utilizado como método em pesquisas com farinha de trigo, principalmente quando trata-se de produtos, como no trabalho elaborado por Mastelini et al. (2018), que com este método realizou predições de três componentes diferentes em macarrão (massas), sendo a quantidade de proteína de soja hidrolisada, frutoligossacarídeo e farinha de trigo. As imagens utilizadas foram microscópicas, de cada tipo de massa preparada pelos pesquisadores, sendo que estas foram pré-processadas e

segmentadas, permitindo assim extrair os recursos da imagem para colocar como entrada em quatro algoritmos de aprendizado de máquina, sendo eles a rede neural artificial perceptron multicamada, máquina de aumento de gradiente, máquina de vetor de suporte e floresta aleatória. Os resultados foram satisfatórios para quantidade de farinha e proteína de soja hidrolisada. Como trabalhos futuros, os autores sugeriram a adoção de outras estratégias para a seleção de características, para poder encontrar um equilíbrio entre custos computacionais e desempenho na previsão.

Já o trabalho de Malegori et al. (2017) utilizou o teste GlutoPeak para prever a qualidade da farinha de trigo medindo as propriedades da agregação de glúten em pouco tempo, usando uma amostra em pequena quantidade, focando em farinhas de grãos integrais. O tratamento e exploração de dados foi realizado pela Análise de Componentes Principais. O resultado foi de um acerto na previsão de 81,8% para farinhas de grãos integrais, sendo que realizando o teste GlutoPeak diretamente nesta farinha, não há necessidade de realizar o processo de refinamento para realizar a previsão da qualidade. Porém, os pesquisadores reconhecem a necessidade de realizar mais estudos na área, com tipos de farinha de grãos diferentes, inclusive mais repetições do estudo apresentado.

Realizar testes rápidos ou utilizar-se de modelos de seleção genômica baseando-se em marcadores moleculares ao invés de realizar testes visco-elásticos para medir a qualidade do cozimento de massas foi o objetivo de um dos estudos elencados para essa revisão. A ideia foi de realizar esses testes e comparar uns com os outros por meio de validação cruzada em uma rede neural perceptron multicamadas, uma das muitas técnicas de inteligência artificial. As previsões que se basearam nos índices de pico de glúten (resultado obtido pela análise laboratorial de glúten de amostras de farinha, sendo que das amostras de um mesmo trigo, é considerado aquele que resultou o maior valor) superaram todos os outros testes realizados na pesquisa, resultando uma precisão de 82% de assertividade (MICHEL et al., 2017).

Voltando a tratar sobre segurança alimentar, Erban et al. (2019) utilizou a técnica de aprendizagem de máquina da floresta aleatória para descobrir marcadores metabólicos não direcionados de biscoitos, modo de rastrear os marcadores genéticos e proteicos de alimentos. A tecnologia de floresta randômica obteve excelentes resultados, com um erro geral de 6,7%, muito inferior ao tradicional utilizado no mercado. Um dos pontos que os pesquisadores indicaram é sobre a supervisão humana, pois embora o erro seja baixo, deve-se sempre tratar os dados antes da sua utilização no modelo gerado. Como trabalhos futuros, os autores recomendaram a combinação do modelo de floresta randômica com tecnologias de análise de dados e testes adicionais, inclusive com outros alimentos.

Técnicas de Deep Learning também são utilizadas para determinar propriedades reológicas e químicas de massas de trigo, sendo que para realizar esta predição, gordura, carboidratos, cinzas, umidade e temperatura de cozimento foram consideradas entradas, enquanto viscosidade da massa e percentuais de proteínas foram as saídas. A técnica de inteligência artificial em questão é a de rede neural profunda sendo que cada camada é ajustada por uma rede restrita de máquinas de Boltzmann (RBM), onde o ajuste fino da rede neural profunda é realizado por backpropagation (em tradução livre, retropropagação). Este artigo gerou um novo algoritmo, sendo que os erros entre saídas preditas e reais são menores quando comparados aos do modelo convencional (GUHA et al., 2017).

Técnicas convencionais de análise proteica são, de modo geral, trabalhosas e dispendiosas. Uma forma mais rápida para se fazer isso é utilizando a espectroscopia de infravermelho

próximo (NIR), que de acordo com Barbon Junior et al. (2019), é uma tecnologia analítica utilizada para a caracterização não destrutiva de diversas amostras orgânicas, que considera atributos tanto qualitativos quanto quantitativos.

Cui e Fearn (2018) investigaram a utilização de redes neurais convolucionais (CNN) em comparação com os modelos tradicionais de regressão multivariada para realizar as previsões dos resultados por infravermelho próximo (NIR). O resultado foi que as CNN obtiveram resultados com maior precisão e menos ruído, pois justamente a camada convolucional do modelo encontra automaticamente o filtro de pré-processamento espectral adequado em todo o conjunto de dados, economizando esforços no treinamento do modelo.

Em um segundo estudo, Barbon Junior et al. (2019) utilizaram da previsão Multialvo (MT) e algoritmos de aprendizado de máquina como estratégia para melhorar o desempenho das previsões realizadas pela técnica NIR de farinha de trigo. Support Vector Machine (SVM), Floresta Aleatória (RF) e Regressão Linear (LR) foram as técnicas de aprendizado de máquina utilizadas em um conjunto de dados composto por espectros NIR de farinhas de trigo para a previsão de parâmetros relacionados à qualidade. A combinação de todas as técnicas e preditores de MT resultou em uma melhoria no desempenho preditivo de 7% quando comparadas com abordagens de alvo único.

Como a NIR é uma tecnologia amplamente utilizada no mercado, também existem estudos na área de segurança alimentar que fazem uso dela, como no caso da utilização da NIR de imagem hiperespectral para detectar baixos níveis de contaminação por pó de amendoim, principalmente em farinhas de trigo integrais. O modelo de inteligência artificial aplicado foi o de regressão de mínimos quadrados parciais, obtendo coeficientes de 99,3% e 25,1% de erro quadrático médio de predição. Em resumo, o trabalho confirmou que a metodologia de NIR pode ser aplicada para identificar contaminações de baixo nível de pó de amendoim, sendo que como continuação do trabalho, os autores recomendaram testar a detecção de contaminação por outros ingredientes com este mesmo método (ZHAO et al., 2019).

Em contrapartida, pesquisas mais recentes buscam uma forma alternativa de se obter os resultados que a técnica de NIR oferece, dado que a última possui um custo elevado. Uma das alternativas é trazida por Sucipto et al. (2018), a de realizar as medições das propriedades bioelétricas (ao aplicar tensão através de eletrodos na massa, ela retorna uma curva de corrente elétrica específica, permitindo correlacionar atributos qualitativos e quantitativos de alimentos). Os autores apresentaram um estudo preliminar deste novo método, que é rápido tanto quanto a técnica de NIR para modelagem classificada de teor de proteína, sendo no estudo em questão feita com farinha de trigo, com base nas propriedades bioelétricas.

Uma Rede Neural Artificial (RNA) com ajuste por backpropagation foi desenvolvida para realizar a classificação do teor de proteínas da farinha. As entradas da RNA eram diversas propriedades bioelétricas, como a resistência e a capacitância e a saída era um dos tipos de farinha de trigo usadas no trabalho, sendo farinha dura, média ou macia. Os resultados mostraram que o modelo da RNA é capaz de realizar esta classificação com sucesso, apresentando uma correlação de regressão (valor de R) de 97,74%. Sendo assim, mesmo preliminar, esta nova técnica se mostrou assertiva, com o bônus de ser mais econômica, tendo o potencial de ser utilizada como instrumento básico para estimar o teor de proteínas em farinha de trigo. Como trabalhos futuros, os autores apontaram a utilização desta técnica com outros insumos, sem esquecer de aprofundar ainda mais o estudo realizado (SUCIPTO et al., 2018).

Em resposta às questões norteadoras da pesquisa, os estudos envolvendo farinha de trigo são basicamente realizadas para processos de laboratório, sendo que das pesquisas encontradas, apenas uma foi sobre perfil consumidor. Dentre os artigos apresentados, todos se utilizaram de técnicas de inteligência artificial, sendo 83,33% de aprendizado de máquina e 16,67% apenas de mineração de dados.

Quanto aos trabalhos futuros, nem todos os autores deixaram de forma explícita a continuidade ou possibilidade de novas pesquisas para complementar a desenvolvida por cada um, porém, dos que apresentaram, deixaram claro a importância do aprofundamento na área principalmente de aprendizado de máquina, relacionando-a com mineração de dados, para obter melhores resultados e informações mais densas.

8. Considerações finais

De uma forma geral, os artigos selecionados na presente pesquisa são suficientes para uma interpretação do quadro geral das pesquisas na área industrial de farinha de trigo, com enfoque na área de inteligência artificial.

Com relação aos demais assuntos de interesse da presente pesquisa, crê-se que os resultados da busca foram relevantes, pois permitiram entender que existe uma carência em pesquisas da aplicação da farinha diretamente na produção de alimentos, pois apenas dois artigos, 16,67% do amostrado, foram relacionados à um produto oriundo da farinha de trigo.

O fato da palavra-chave de busca e da aplicação de filtros ter retornado trabalhos com diferentes enfoques a respeito do tema mostra a diversidade da área de pesquisa em questão, sendo que se pode perceber uma evolução gradual nas pesquisas, tanto nas técnicas de aprendizado de máquina quanto na evolução dos experimentos realizados em laboratório.

Como continuidade do presente trabalho, indica-se a pesquisa com farinha de trigo na área industrial, que gere impacto direto na produção de determinados produtos, pois assim a área de aplicação de inteligência artificial extrapola os limites dos laboratórios.

Referências

BARBON JUNIOR, Sylvio et al. Multi-target prediction of wheat flour quality parameters with near infrared spectroscopy. **Information Processing In Agriculture**, [s.l.], p.1-13, jul. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.inpa.2019.07.001>.

BARBOSA, Rommel M. et al. A simple and practical control of the authenticity of organic sugarcane samples based on the use of machine-learning algorithms and trace elements determination by inductively coupled plasma mass spectrometry. **Food Chemistry**, [s.l.], v. 184, p.154-159, out. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.foodchem.2015.02.146>.

BRASIL. Portaria nº 354, de 18 de julho de 1996. Ministério da Saúde: Secretaria de Vigilância Sanitária. Brasília, DF. **Diário Oficial da União** de 22/07/1996, Seção 1.

CUI, Chenhao; FEARN, Tom. Modern practical convolutional neural networks for multivariate regression: Applications to NIR calibration. **Chemometrics And Intelligent Laboratory**

Systems, [s.l.], v. 182, p.9-20, 15 jul. 2018. Elsevier BV.

<http://dx.doi.org/10.1016/j.chemolab.2018.07.008>.

DRESCH, A.; LACERDA, D. P.; JÚNIOR, J. A. V. A. **Design Science Research: Método de Pesquisa para Avanço da Ciência e Tecnologia**. Porto Alegre: Bookman Editora, 2015.

ERBAN, Alexander et al. Discovery of food identity markers by metabolomics and machine learning technology. **Scientific Reports**, [s.l.], v. 9, n. 1, p.1-19, 4 jul. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-019-46113-y>.

FIORE, Mariantonietta et al. Predicting consumer healthy choices regarding type 1 wheat flour. **British Food Journal**, [s.l.], v. 119, n. 11, p.2388-2405, 6 nov. 2017. Emerald. <http://dx.doi.org/10.1108/bfj-04-2017-0200>.

GUHA, Paramita et al. Prediction of properties of wheat dough using intelligent deep belief networks. **Journal Of Experimental & Theoretical Artificial Intelligence**, [s.l.], v. 29, n. 6, p.1283-1296, 21 jun. 2017. Informa UK Limited. <http://dx.doi.org/10.1080/0952813x.2017.1340976>.

MALEGORI, Cristina et al. GlutoPeak profile analysis for wheat classification: Skipping the refinement process. **Journal Of Cereal Science**, [s.l.], v. 79, p.73-79, 9 set. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.jcs.2017.09.005>.

MASTELINI, Saulo Martiello et al. Computer vision system for characterization of pasta (noodle) composition. **Journal Of Electronic Imaging**, [s.l.], v. 27, n. 05, p.1-14, 26 set. 2018. SPIE-Intl Soc Optical Eng. <http://dx.doi.org/10.1117/1.jei.27.5.053021>.

MATTAR, J. **Metodologia científica na era digital**. [s. l.], 2017. Disponível em: <<http://search.ebscohost.com/login.aspx?direct=true&db=edsmib&AN=edsmib.000012236&lang=pt-br&site=eds-live&scope=site>>. Acesso em: 24 set. 2019.

MICHEL, Sebastian et al. Improving the baking quality of bread wheat using rapid tests and genomics: The prediction of dough rheological parameters by gluten peak indices and genomic selection models. **Journal Of Cereal Science**, [s.l.], v. 77, p.24-34, set. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.jcs.2017.07.012>.

SOUZA, Susane Maciel de et al. Influência físico-química da farinha de soja no processamento de biscoito. Desafios - **Revista Interdisciplinar da Universidade Federal do Tocantins**, [s.l.], v. 6, p. 42-47, 16 jun. 2019. Universidade Federal do Tocantins. <http://dx.doi.org/10.20873/uft.2359365220196especialp42>.

SU, Wen-hao; SUN, Da-wen. Evaluation of spectral imaging for inspection of adulterants in terms of common wheat flour, cassava flour and corn flour in organic Avatar wheat (*Triticum* spp.) flour. **Journal Of Food Engineering**, [s.l.], v. 200, p.59-69, maio 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.jfoodeng.2016.12.014>.

SUCIPTO, Sucipto et al. A rapid classification of wheat flour protein content using artificial neural network model based on bioelectrical properties. **Telkomnika (telecommunication Computing Electronics And Control)**, [s.l.], v. 17, n. 2, p.920-927, 20 ago. 2018. Universitas Ahmad Dahlan. <http://dx.doi.org/10.12928/telkomnika.v17i2.9450>.

ZHAO, Xin et al. Utilising near-infrared hyperspectral imaging to detect low-level peanut powder contamination of whole wheat flour. **Biosystems Engineering**, [s.l.], v. 184, p.55-68, ago. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.biosystemseng.2019.06.010>.