



RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL

RECOGNIZING BEER STYLES WITH AN ARTIFICIAL NEURAL NETWORK

Diogo Costa Pereira¹

Submetido em: 14/04/2021

e24200

Aprovado em: 26/04/2021

RESUMO

Este trabalho teve como objetivo elaborar uma ferramenta computacional utilizando os conceitos de redes neurais artificiais para reconhecer alguns dos grupos de estilos de cervejas baseado no guia de estilos do BJCP 2015. Para isso, além do desenvolvimento dos padrões de entrada que a rede neural artificial necessita para trabalhar, foi utilizado o *framework* Encog 3.4 para reaproveitamento de códigos. Os resultados dos dois testes realizados neste trabalho foram bastante positivos, uma vez que a rede neural além de reconhecer todos os estilos de cervejas de um grupo do BJCP 2015, em seu primeiro teste, ela também conseguiu distinguir os estilos de quatro grupos simultâneos do guia de estilos.

PALAVRAS-CHAVE: Estilos de Cerveja. Inteligência Artificial. Redes Neurais. Reconhecimento de Padrões.

ABSTRACT

This work aimed to develop a computational tool using the concepts of artificial neural networks to recognize some of the beer style groups based on the BJCP 2015 style guide. For this, in addition to the development of the input patterns that the artificial neural network needs to work, the Encog 3.4 framework was used to reuse codes. The results of the two tests carried out in this work were very positive, since the neural network, in addition to recognizing all the beer styles of a group from BJCP 2015, in its first test, it also managed to distinguish the styles of four simultaneous groups of the guide of styles.

KEYWORDS: Beer Styles. Artificial intelligence. Neural Networks. Pattern Recognition.

1 INTRODUÇÃO

De acordo com as informações do MAPA (2020), o número de cervejarias registradas no Brasil, que no fim do ano de 2015 alcançou em 332, cresceu para 1209 no fim do ano de 2019. Um crescimento um tanto considerável, até porque, de acordo com CERVBRAZIL (2016), o setor cervejeiro é responsável por 1,6% do PIB nacional.

São muitas as características de um estilo de cerveja, possuindo valores e intensidades diferentes entre si. Pensando no guia de estilos BJCP (2015), a identificação dos estilos até mesmo para profissionais é bastante difícil pela grande quantidade de informações que se deve saber. Nesse sentido, uma ferramenta capaz de identificar os padrões dos estilos pode ser considerada proveitosa, tornando assim uma identificação menos complexa.

Na era da tecnologia, as pessoas buscam a facilidade em todos os processos que realizam, como contam com a utilização de calculadoras, análise de dados complexos pelo

¹ Comércio de Bebidas Marra Ltda., Instituto Federal de Educação Ciência e Tecnologia do Triângulo Mineiro



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL
Diogo Costa Pereira

computador entre outros. Falando de cerveja não é diferente, somente o guia BJCP (2015), possui 121 estilos de cerveja com diversos parâmetros para cada um.

Diante disso, o presente trabalho teve como objetivo elaborar uma ferramenta computacional utilizando os conceitos de redes neurais artificiais para reconhecer alguns dos grupos de estilos de cervejas baseado no guia de estilos do BJCP 2015.

Para o desenvolvimento deste projeto de pesquisa, foi levantado inicialmente o referencial teórico importante para o seu desenvolvimento, como trabalhos acadêmicos, revistas científicas, livros, sítios da *Web* os outros meios que se tornem essenciais para o trabalho, desde que possuem cunho científico.

Após a obtenção de todo o conhecimento necessário, foi escolhido um grupo de estilos do BJCP (2015) para a quantificação dos dados a serem inseridos na rede neural artificial. Após esta etapa, um sistema para a plataforma *Desktop* foi desenvolvido com a ajuda de um *framework* para tal finalidade.

Por fim foram demonstrados os testes realizados no *software* para averiguar se o mesmo consegue distinguir os estilos do grupo de cervejas escolhidos.

2 CERVEJA E REDES NEURAIAS ARTIFICIAIS

Para ater-se às possíveis respostas do objetivo do presente artigo, é de suma importância compreender os principais conceitos sobre cerveja e redes neurais artificiais.

2.1 CERVEJA

Tozetto (2017) argumenta que a cerveja é a bebida alcoólica mais consumida no mundo, assumindo a posição de terceira bebida entre todas as bebidas no *ranking*, ficando atrás apenas da água e do chá. Segundo Oliveira (2018) a legislação brasileira define cerveja como uma bebida provinda de uma fermentação alcoólica de um mosto cervejeiro resultante do malte de cevada, água, lúpulo e a ação das leveduras, podendo o malte de cevada e o lúpulo ser trocados pelos seus respectivos extratos. Uma parte do malte de cevada pode ser trocada, até 45%, pelos chamados adjuntos cervejeiros, sendo estes cereais maltados ou não, bem como os açúcares e amidos de origem vegetal aptos para o consumo humano.

De acordo com Hughes (2014), produzir cerveja está interlaçado por uma longa jornada histórica, remontada a milhares de anos das antigas planícies da mesopotâmia (7000 a.C.) até a atual tendência mundial de produção de cerveja artesanal.

Segundo CERVBRASIL (2016), o setor cervejeiro no Brasil está presente em todas as cidades do país, interligado uma enorme cadeia produtiva que vai do agronegócio até o pequeno varejo. Ainda segundo o mesmo autor, este setor por sua vez, é bastante importante para a economia brasileira, possui mais de 2,2 milhões de pessoas empregadas ao longo dessa cadeia



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL
Diogo Costa Pereira

de produção, sendo um fator multiplicador, sua atuação é responsável por 1,6% do PIB nacional e 14% da indústria de transformação nacional.

De acordo com o MAPA (2020), no ano de 2019 o número de cervejarias registradas no Brasil atingiu a marca de 1209 cervejarias, sendo um crescimento de quase uma nova cervejaria por dia para o mesmo ano. O crescimento de novas cervejarias segue em uma média quase constante de 19,6% nos últimos vinte anos, subindo para 26,6% comparando os últimos 10 anos e 36,4% nos últimos cinco anos. Na figura 1 pode ser observado essa evolução.

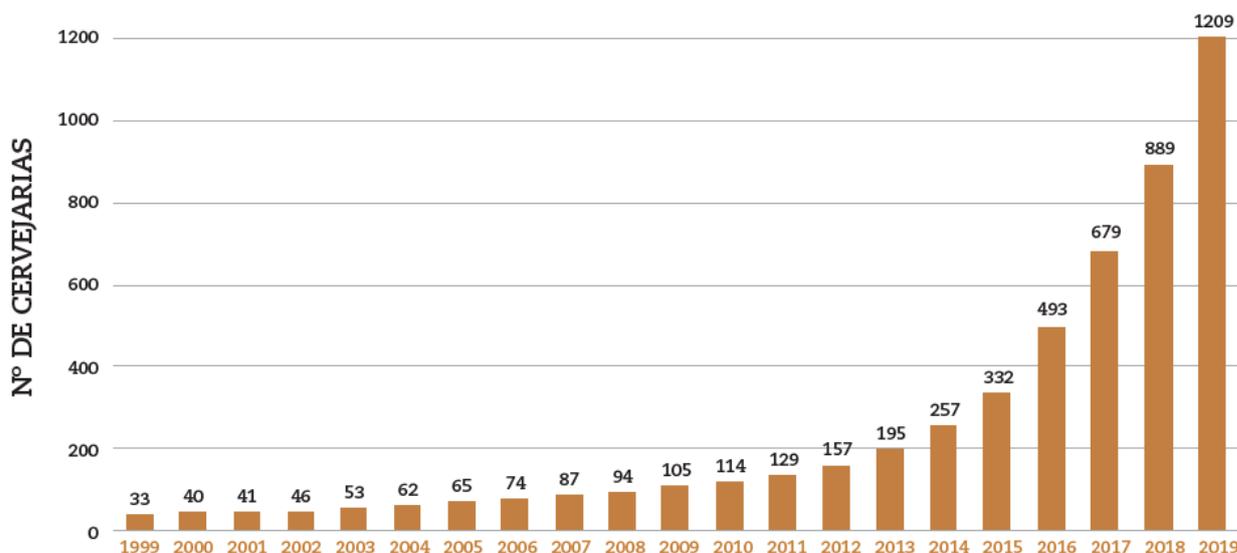


Figura 1: Evolução dos números de cervejarias no Brasil.

Fonte: MAPA (2020).

Segundo Morado (2017), classificar cervejas apenas pelo seu tipo de fermentação (*A/e*, *Lager* ou *Lambic*) tem pouca serventia, pois a classificação de cervejas não é uma tarefa fácil, engloba inúmeros parâmetros que podem direcionar essa classificação, como cor, teor alcoólico, origem do estilo, ingredientes, método de produção e etc. Ainda ressalva que alguns fatores podem dificultar a classificação das cervejas, como: adoção de novas tecnologias, mudanças no paladar dos consumidores, disponibilidade de matérias-primas entre outros.

2.1.1 Beer Judge Certification Program

Um dos guias de estilos mais aceito mundialmente foi criado pela *Beer Judge Certification Program Inc.*, uma instituição sem fins lucrativos criada nos Estados Unidos em 1985, no qual atualmente está em sua versão do ano de 2015. O guia completo do BJCP inclui hidromel, sidra e cerveja. A seção de cervejas, engloba 121 estilos associados em 35 grupos diferentes (MORADO, 2017).



De acordo com o próprio BJCP (2015), o guia de estilos é uma orientação destinada a apresentar as características gerais mais comuns das cervejas para um determinado estilo, e não uma lista de especificações e requisitos a serem rigorosamente seguidos. A ideia é servir como direcionamento orientativo para se chegar dentro dos estilos propostos. Para cada estilo de cerveja, o guia possui as características vitais do estilo (*Original Gravity*, *Final Gravity*, cor, IBU e o teor alcoólico) e as características e suas intensidades de aroma, aparência, sabor e sensação de boca.

2.2 REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais são baseadas no mecanismo de comportamento de um cérebro, sendo emulado através de um *hardware* ou/e *software*. Estas por sua vez são capazes de adquirirem conhecimento com a experiência. Elas são organizadas em camadas ou fileiras, propiciando um conglomerado de interconexões, tendo como princípio base de aprendizado os pesos, unidades de processamento que são o ponto de calibração da rede (LIMA e MINUSSI, 2011). De acordo com Miguez, Maculan e Xavier (2012), uma rede neural artificial é uma ligação entre unidades de processamento matemático, conhecido como neurônio artificial.

Haykin (2001) diz que o neurônio é a unidade base de processamento de informações para que uma rede neural possa funcionar, diante disso, ele cita os seguintes elementos básicos de um neurônio, sendo: conjunto de sinapses ou elos de conexão onde os valores de entrada na rede são multiplicados pelo valor do peso da conexão, um somador para os sinais de entradas que soma todo o resultado do conjunto de sinapses para o neurônio específico, bias que serve para aumentar ou diminuir a entrada líquida da função de ativação e uma função de ativação para restringir a amplitude de saída. Um modelo de neurônio pode ser observado na figura 2.

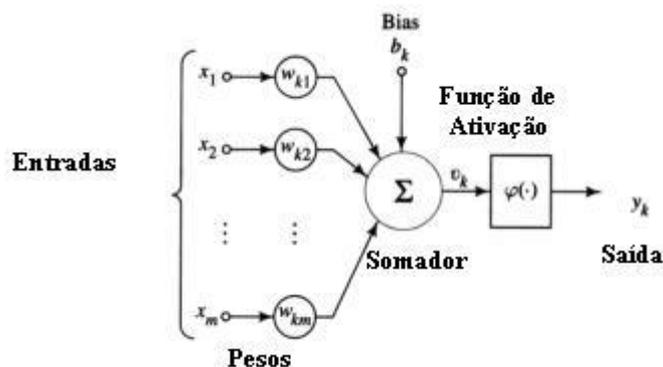


Figura 2: Modelo de um neurônio artificial.

Fonte: HAYKIN (2001).

Lima e Minussi (2011) falam que o processo de calibração da rede é conhecido como aprendizado ou treinamento. Uma vez que a rede passar pelo processo de ajustamento dos



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL
Diogo Costa Pereira

pesos, a rede está apta para análises, até mesmo para entradas que não passaram antes pelo processo de treinamento.

Heaton (2011) enfatiza que não se deve alimentar diretamente uma rede neural antes de tratar os dados, é preciso normalizá-los antes para máxima eficiência da rede. A normalização basicamente consiste em trazer os dados a serem inseridos na rede neural para o intervalo em que as funções de ativação trabalham, por exemplo, a função sigmoide opera entre 0 e +1, já a função tangente hiperbólica trabalha entre -1 e +1. Na equação 1 pode-se observar uma equação para normalizar os dados de entrada de uma rede neural, onde x representa o valor a ser normalizado, d o valor máximo (H) e mínimo (L) da amostra de dados do valor a ser normalizado e n representa a faixa de valor máxima (H) e mínima (L) desejada.

(1)

$$f(x) = \frac{(x - dL)(nH - nL)}{(dH - dL)} + nL$$

Fonte: HEATON (2011).

De forma geral são identificados três tipos de arquiteturas distintas de redes neurais artificiais. A primeira estrutura é a rede de camada única, onde as entradas da rede com o cálculo dos seus respectivos pesos formam a camada de saída (neurônios). A segunda estrutura é a de múltiplas camadas, após os resultados da primeira camada, estes resultados se tornam agora entradas para uma outra camada (unidades ocultas) que podem também ser utilizados para uma outra e assim sucessivamente. A terceira estrutura são as redes recorrentes, distinguindo se por conter pelo menos um laço de realimentação, na qual a saída da rede se torna sua própria entrada (HAYKIN, 2001). As arquiteturas podem ser observadas na figura 3.

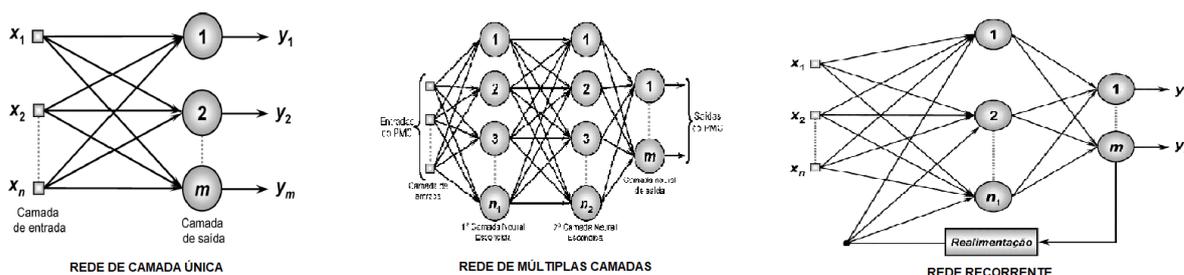


Figura 3: Modelos de arquiteturas de redes neurais artificiais.

Fonte: Imagens do Google¹.

Haykin (2001) diz que não há um algoritmo único de aprendizagem se tratando de redes neurais, o que se tem é um conjunto diversificado na qual cada um possui vantagens específicas. De forma geral, o que difere os algoritmos de aprendizagem de uma rede neural é o tipo de

¹ Imagens disponíveis em: <<https://medium.com/@avinicius.adorno/redes-neurais-artificiais-418a34ea1a39>>, <<https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9>> e <<https://www.embarcados.com.br/redes-neurais-artificiais/>>. Acessado em 15 de abril de 2021.



formulação do ajuste dos pesos sinápticos de um neurônio. Diante disso, o mesmo autor cita alguns tipos de aprendizagem para uma rede neural artificial, sendo: aprendizagem por correção de erro, aprendizagem baseada em memória; aprendizagem *hebbiana*, aprendizagem competitiva e aprendizagem de *Boltzman*.

A maneira onde uma rede neural artificial se relaciona com o seu meio para o processo de aprendizado, de acordo com Braga (2006), é dada de três maneiras:

1. Aprendizado supervisionado: um conjunto de exemplos de entradas juntamente com suas respectivas saídas são fornecidas a rede para o ajustamento dos pesos (treinamento), contudo, a rede não conhece esse ambiente. Neste processo uma medida de erro é utilizada para incorporar conhecimento a rede neural, sendo a diferença entre a respostas apresentada e a resposta desejada.
2. Aprendizado não-supervisionado: a rede aprende diretamente com os dados de entradas inseridos, sem uma resposta pré-determinada. São utilizados padrões redundantes com regularidade estatística para o processo de aprendizado, caso essa redundância inexistir, é impossível o aprendizado da rede.
3. Aprendizado por reforço: este baseia-se em toda medida que seja capaz de ser dada ao sistema onde a informação de realimentação disposta é se uma determinada saída está correta ou não, diferente do aprendizado supervisionado onde a medida é baseada no erro.

2.2.1 Encog

Encog é um *framework* com sua primeira versão desenvolvida em 2008 por Jeff Heaton para o aprendizado de máquina para as linguagens de programação Java e .NET. Inicialmente foi elaborada apenas com suporte as redes neurais artificiais, porém no decorrer dos anos foi se expandindo, abordando outros conceitos de inteligência artificial (HEATON, 2011).

3 RESULTADOS E DISCUSSÃO

Para a apuração dos resultados propostos pelo trabalho, foi desenvolvido um *software* para a plataforma *Desktop* na linguagem de programação Java através da IDE NetBeans. Como o intuito do trabalho não é o desenvolvimento detalhado de uma rede neural artificial, foi utilizado a biblioteca Encog 3.4 no acervo de bibliotecas para que seja possível a utilização de redes neurais sem a necessidade de programá-las do início.

Foi necessário quantificar alguns termos qualitativos descritos para cada estilo de cerveja no BJCP (2015), como intensidades do sabor, aroma, corpo e aparência, sendo possível de ser observado nas tabelas 1 e 2.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL
Diogo Costa Pereira

Tabela 1: Intensidade da aparência da cerveja.

DESCRIÇÃO	ESCALA
TURVA	7 - 10
TRASLUCIDA	4 - 6
CRISTALINA	2 - 3
LÍMPIDA	1

Fonte: Elaborada pelo autor.

Tabela 2: Intensidade de sabor e aroma do malte e lúpulo, e intensidade de corpo.

DESCRIÇÃO	ESCALA
MUITO INTENSO	9 - 10
INTENSO	7 - 8
MODERADO	6
FRACO	4 - 5
MUITO FRACO	2 - 3
NENHUM PERCEBIDO	1

Fonte: Elaborada pelo autor.

Os valores de entrada para a rede neural artificial foram gerados de forma aleatória, respeitando os valores limites do guia de estilos BJCP (2015), totalizando 12 entradas, sendo: *original gravity*, *final gravity*, SRM, IBU, ABV, tipo de fermentação, intensidade do aroma de malte, intensidade do aroma de lúpulo, intensidade do sabor do malte, intensidade do sabor de lúpulo, aparência e corpo. Um exemplo dos valores gerados, antes de passar pelo processo de normalização de dados, pode ser observado na tabela 3.

Tabela 3: Exemplo de valores de entrada para a rede neural artificial.

	ORIGINAL GRAVITY	FINAL GRAVITY	SRM	IBU	ABV	TIPO DE FERMENTAÇÃO	INTENSIDADE DO AROMA DE MALTE	INTENSIDADE DO AROMA DE LUPULO	INTENSIDADE DO SABOR DE MALTE	INTENSIDADE DO SABOR DE LUPULO	APARENCIA	CORPO
1036	1007	2	12	3,81	2	3	2	4	1	1	1	
1034	1008	3	11	3,41	2	3	2	5	2	1	1	
1041	1007	3	17	4,46	2	1	1	3	2	1	4	
1043	1007	2	16	4,73	2	1	2	5	2	1	4	
1044	1011	2	10	4,33	1	6	3	6	4	3	4	
1050	1012	4	17	4,99	1	5	4	4	5	3	5	
1052	1012	3	23	5,25	3	6	6	5	4	10	5	
1049	1008	5	18	5,38	3	5	4	5	5	10	6	

Fonte: Elaborada pelo autor.



3.1 TESTE 1: *Standard American Beer*

A ideia nesta etapa é verificar se a rede neural consegue distinguir os estilos entre si pelas suas características, para isso, neste teste foram geradas 1000 receitas aleatórias para cada um dos estilos de cerveja da categoria 1 do BJCP (2015), sendo a *American Light Lager*, *American Lager*, *Cream Ale* e *American Wheat Beer*, formando uma base de 4000 receitas para o treinamento da rede neural artificial.

Foram diversas tentativas com mudanças na estrutura da rede e também na escolha da função de ativação, em uma delas a rede neural artificial conseguiu aprender a diferenciar os estilos, foram necessárias 112.811 iterações para este processo, executado em 2 minutos e 33 segundos com uma taxa de erro de 0.001 sobre o valor de saída desejado. Após o treinamento da rede neural os dados dela foram salvos em um arquivo para que não seja preciso treiná-la toda vez para os testes, pois as vezes esse processo pode demorar bastante. A função de ativação escolhida foi a tangente hiperbólica e a estrutura da rede foi uma estrutura de múltiplas camadas compostas por uma camada de entrada com 12 entradas, uma camada escondida formada por 7 neurônios e uma camada de saída com 4 neurônios. Uma parte da evolução do treinamento pode ser observada na figura 4.

Figura 4: Evolução do treinamento da rede neural artificial.

```

run:
Epoch #10000 Error:0.8071732767108178
Epoch #20000 Error:0.4791141079591721
Epoch #30000 Error:0.2734872099070666
Epoch #40000 Error:0.15135843229578208
Epoch #50000 Error:0.08255248467331254
Epoch #60000 Error:0.04047348156180606
Epoch #70000 Error:0.019098798400519004
Epoch #80000 Error:0.009382288613002762
Epoch #90000 Error:0.004701007511376253
Epoch #100000 Error:0.0023902799732365538
Epoch #110000 Error:0.0012105500766102222
Epoch: 112811
Treinamento finalizado!
Network trained to error: 9.998751537064977E-4
Saving network
Writing on Excel file Finished ...

CONSTRUIDO COM SUCESSO (tempo total: 2 minutos 33 segundos)

```

Fonte: Elaborada pelo autor.

Foram geradas novas 4 receitas para cada estilo da categoria 1 do BJCP (2015) para testar a rede neural artificial desenvolvida. A rede neural conseguiu distinguir em 100% de exatidão os estilos entre si em apenas 2 segundos, pois uma vez que a rede neural artificial esteja treinada, a execução do processo é bastante eficiente. O resultado bem como os valores de entrada para a rede, antes da normalização dos dados, pode ser observado na tabela 4.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL
Diogo Costa Pereira

Tabela 4: Valores de entrada gerados para testar a rede neural artificial para o teste 1.

ESTILO GERADO	ORIGINAL GRAVITY	FINAL GRAVITY	SRM	IBU	ABV	TIPO DE FERMENTAÇÃO	INTENSIDADE DO AROMA DE MALTE	INTENSIDADE DO AROMA DE LUPULO	INTENSIDADE DO SABOR DE MALTE	INTENSIDADE DO SABOR DE LUPULO	APARENCIA	CORPO	RESULTADO DA REDE NEURAL
AMERICAN LIGHT LAGER	1029	1002	2	12	3,54	2	2	3	5	2	1	1	AMERICAN LIGHT LAGER
AMERICAN LIGHT LAGER	1037	1008	2	10	3,81	2	1	2	5	2	1	1	AMERICAN LIGHT LAGER
AMERICAN LIGHT LAGER	1035	1006	2	8	3,81	2	2	2	2	3	1	1	AMERICAN LIGHT LAGER
AMERICAN LIGHT LAGER	1038	1008	3	12	3,94	2	2	1	3	1	1	1	AMERICAN LIGHT LAGER
AMERICAN LAGER	1047	1009	4	14	4,99	2	4	3	2	5	1	5	AMERICAN LAGER
AMERICAN LAGER	1048	1009	2	18	5,12	2	1	2	2	5	1	2	AMERICAN LAGER
AMERICAN LAGER	1046	1007	4	11	5,12	2	4	2	4	3	1	2	AMERICAN LAGER
AMERICAN LAGER	1047	1008	4	15	5,12	2	2	2	4	2	1	4	AMERICAN LAGER
CREAM ALE	1045	1012	2	19	4,33	1	5	3	5	5	3	4	CREAM ALE
CREAM ALE	1045	1006	4	8	5,12	1	6	4	5	5	2	5	CREAM ALE
CREAM ALE	1044	1012	5	10	4,2	1	5	2	6	4	3	4	CREAM ALE
CREAM ALE	1044	1007	4	19	4,86	1	6	5	5	4	2	6	CREAM ALE
AMERICAN WHEAT BEER	1050	1013	3	28	4,86	3	5	6	4	6	8	4	AMERICAN WHEAT BEER
AMERICAN WHEAT BEER	1041	1008	6	24	4,33	3	5	6	4	4	4	4	AMERICAN WHEAT BEER
AMERICAN WHEAT BEER	1043	1011	6	15	4,2	3	4	4	4	6	5	6	AMERICAN WHEAT BEER
AMERICAN WHEAT BEER	1047	1012	6	16	4,59	3	6	4	5	6	7	4	AMERICAN WHEAT BEER

Fonte: Elaborada pelo autor.

3.2 TESTE 2: Testando 4 categorias do BJCP 2015

Para este segundo teste foram selecionados os 4 primeiros grupos de estilos de cervejas do BJCP (2015), totalizando 13 estilos, sendo eles: *American Light Lager*, *American Lager*, *Cream Ale*, *American Wheat Beer*, *International Pale Lager*, *International Amber Lager*, *Czech Pale Lager*, *Czech Premium Pale Lager*, *Czech Amber Lager*, *Czech Dark Lager*, *Munich Helles*, *Festbier* e *Helles Bock*.

Foram geradas aleatoriamente 100 receitas para cada um dos estilos citados, totalizando em uma base de 1300 estilos de cervejas. Sendo necessárias 858.239 iterações do *software* num total de 24 minutos e 31 segundos para que a rede neural aprenda os padrões entre os estilos. A estrutura da rede e suas configurações foram basicamente as mesmas elaborada no teste 1, havendo apenas uma alteração na camada de saída da rede para 13 neurônios, sendo um para cada estilo.

Para testar a rede neural, foram geradas 3 receitas para cada estilo para verificar o aprendizado da rede, apesar de não reconhecer um padrão entre as receitas, no geral ela obteve um bom desempenho acertando os demais estilos. Para melhorar ainda mais o treinamento da



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL
Diogo Costa Pereira

rede neural, pode-se inserir um número ainda maior de estilos para o treiná-la e diminuir a taxa de erro da rede. Na tabela 5 pode ser observado os resultados deste teste.

Tabela 5: Valores de entrada gerados para testar a rede neural artificial para o teste 2.

ESTILO GERADO	ORIGINAL GRAVITY	FINAL GRAVITY	SRM	IBU	ABV	TIPO DE FERMENTAÇÃO	INTENSIDADE DO AROMA DE MALTE	INTENSIDADE DO AROMA DE LÚPULO	INTENSIDADE DO SABOR DE MALTE	INTENSIDADE DO SABOR DE LÚPULO	APARENCIA	CORPO	RESULTADO DA REDE NEURAL
AMERICAN LIGHT LAGER	1033	1008	3	9	3,28	2	2	2	3	1	1	1	AMERICAN LIGHT LAGER
AMERICAN LIGHT LAGER	1040	1008	3	10	4,20	2	3	2	2	2	1	1	AMERICAN LIGHT LAGER
AMERICAN LIGHT LAGER	1030	1003	3	9	3,54	2	1	2	2	1	1	1	AMERICAN LIGHT LAGER
AMERICAN LAGER	1042	1010	2	18	4,20	2	3	1	5	5	1	4	AMERICAN LAGER
AMERICAN LAGER	1040	1006	3	8	4,46	2	3	3	4	3	1	4	AMERICAN LAGER
AMERICAN LAGER	1044	1006	4	15	4,99	2	1	2	3	3	1	4	AMERICAN LAGER
CREAM ALE	1045	1006	5	17	5,12	1	6	2	5	4	3	2	CREAM ALE
CREAM ALE	1047	1006	4	15	5,38	1	5	5	5	5	3	3	CREAM ALE
CREAM ALE	1048	1011	4	16	4,86	1	6	3	4	5	2	3	CREAM ALE
AMERICAN WHEAT BEER	1048	1010	6	29	4,99	3	5	4	4	6	5	4	AMERICAN WHEAT BEER
AMERICAN WHEAT BEER	1045	1010	6	25	4,6	3	5	4	5	5	10	6	AMERICAN WHEAT BEER
AMERICAN WHEAT BEER	1052	1012	6	15	5,25	3	6	4	6	6	8	5	AMERICAN WHEAT BEER
INTERNATIONAL PALE LAGER	1046	1010	5	22	4,73	2	5	4	5	4	1	3	INTERNATIONAL PALE LAGER
INTERNATIONAL PALE LAGER	1050	1009	6	18	5,38	2	6	4	6	4	1	6	NÃO RECONHECU
INTERNATIONAL PALE LAGER	1044	1008	5	21	4,7	2	4	5	5	3	1	5	INTERNATIONAL PALE LAGER
INTERNATIONAL AMBER LAGER	1054	1011	14	24	5,64	2	5	1	6	5	3	5	INTERNATIONAL AMBER LAGER
INTERNATIONAL AMBER LAGER	1055	1011	8	13	5,78	2	6	4	4	6	2	5	INTERNATIONAL AMBER LAGER
INTERNATIONAL AMBER LAGER	1051	1014	7	18	4,86	2	5	2	4	4	2	4	INTERNATIONAL AMBER LAGER
CZECH PALE LAGER	1032	1009	5	30	3,02	2	6	4	4	6	1	6	CZECH PALE LAGER
CZECH PALE LAGER	1042	1012	5	21	3,94	2	5	4	4	7	1	5	CZECH PALE LAGER
CZECH PALE LAGER	1033	1008	6	28	3,28	2	4	6	5	4	1	5	CZECH PALE LAGER
CZECH PREMIUM PALE LAGER	1057	1015	3	35	5,51	2	8	7	6	8	2	6	CZECH PREMIUM PALE LAGER
CZECH PREMIUM PALE LAGER	1051	1013	6	38	4,99	2	8	6	8	7	3	6	CZECH PREMIUM PALE LAGER
CZECH PREMIUM PALE LAGER	1057	1015	3	39	5,51	2	6	6	7	6	2	6	CZECH PREMIUM PALE LAGER
CZECH AMBER LAGER	1053	1016	14	35	4,86	2	6	6	8	5	2	7	CZECH AMBER LAGER
CZECH AMBER LAGER	1048	1014	11	20	4,46	2	6	6	8	5	3	8	CZECH AMBER LAGER
CZECH AMBER LAGER	1051	1015	14	29	4,73	2	6	6	6	6	1	8	CZECH AMBER LAGER
CZECH DARK LAGER	1052	1013	35	24	5,12	2	8	3	6	2	1	7	CZECH DARK LAGER
CZECH DARK LAGER	1057	1013	33	22	5,78	2	8	2	8	2	2	8	CZECH DARK LAGER
CZECH DARK LAGER	1055	1013	25	24	5,51	2	6	2	6	3	3	8	CZECH DARK LAGER
MUNICH HELLES	1046	1006	3	19	5,25	2	6	5	6	3	1	6	MUNICH HELLES
MUNICH HELLES	1047	1006	3	21	5,38	2	6	5	6	2	1	6	MUNICH HELLES
MUNICH HELLES	1045	1008	3	21	4,86	2	6	5	6	3	1	6	MUNICH HELLES
FESTBIER	1056	1011	6	19	5,91	2	6	2	7	5	3	6	FESTBIER
FESTBIER	1057	1010	6	18	6,17	2	6	5	6	4	2	6	FESTBIER
FESTBIER	1057	1012	4	21	5,91	2	6	4	7	4	3	6	FESTBIER
HELLES BOCK	1066	1016	11	35	6,56	2	8	1	8	1	1	6	HELLES BOCK
HELLES BOCK	1071	1015	6	48	7,35	2	9	2	6	2	2	6	HELLES BOCK
HELLES BOCK	1067	1018	10	23	6,43	2	10	1	7	4	3	6	HELLES BOCK

Fonte: Elaborada pelo autor.

4 CONSIDERAÇÕES FINAIS

É fato de que o consumo de cerveja é bastante apreciado por muitas pessoas, podemos observar pelo crescente aumento de cervejarias registradas ao longo dos anos no Brasil. Outro ponto de extrema importância é que vimos o quão importante a cerveja é para o comércio brasileiro, empregando um número bastante significativo de pessoas em toda a sua cadeia.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR ISSN 2675-6218

RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL
Diogo Costa Pereira

Pôde ser observado também que existem diversos tipos de cervejas e diversos fatores que as diferenciam. Para isso vimos sobre o guia de estilos BJCP 2015, no qual diversifica 121 estilos diferentes da bebida.

Redes neurais artificiais trata-se de um tema bastante difundido na comunidade científica, com um grande potencial de aprendizado de padrões e, falando em cerveja, é uma combinação que pode trazer resultados positivos.

O presente trabalho teve como objetivo elaborar uma ferramenta computacional utilizando os conceitos de redes neurais artificiais para reconhecer alguns dos grupos de estilos de cervejas baseado no guia de estilos do BJCP 2015. Diante disso, foi aplicado ao primeiro grupo do guia de estilos, o *American Lager*, no qual apesar da grande semelhança entre os estilos, a rede neural desenvolvida conseguiu distinguir os quatro estilos presentes nesse grupo. Na tentativa de averiguar outros estilos, foi realizado o teste com treze estilos do guia, onde o *software* desenvolvido também conseguiu reconhecer os padrões dos estilos e retornar o estilo correto de acordo com os dados de entrada.

Como proposta para trabalhos futuros, deixo a ideia de dois projetos envolvendo redes neurais artificiais, um para o desenvolvimento de um *software* capaz de informar quais estilos uma pessoa deveria experimentar de acordo com os estilos que ela bebe, ajudaria a evoluir o paladar para que, não ocorra a frustração de experimentar um estilo oposto ao que a pessoa é acostumada, para esse projeto talvez seria interessante o uso da rede neural de Kohonen. A outra sugestão é criar um *software*, muito parecido com este trabalho, para obter as informações de cervejas participantes de concursos cervejeiros e, distinguir as cervejas ganhadoras de não ganhadoras do concurso, para que através do aprendizado da rede neural artificial, uma pessoa que gostaria de participar de um concurso, possa passar por um teste para saber se sua cerveja possui ou não características das cervejas que já ganharam concursos antes.

REFERÊNCIAS

BRAGA, Petrônio de Luna. **Reconhecimento de voz dependente de locutor utilizando redes neurais artificiais**. 2006. Trabalho de conclusão (Curso Engenharia da Computação) - Universidade Federal De Pernambuco, Recife, 2006.

BJCP - BEER JUDGE CERTIFICATION PROGRAM. **Beer style guidelines**. Style Guidelines, 2015. Disponível em: https://www.bjcp.org/docs/2015_Guidelines_Beer.pdf. Acesso em: 15 abr. 2021.

CERVBRASIL. **Anuário 2016**. Disponível em: http://www.cervbrasil.org.br/novo_site/anuarios/CervBrasil-Anuario2016_WEB.pdf. Acesso em: 15 abr. 2021.

HAYKIN, Simon. **Redes Neurais: princípios e prática**. Tradução de Paulo Martins Engel. 2. ed. Porto Alegre: Bookmam, 2001. ISBN 978-85-7307-718-6.



RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINAR
ISSN 2675-6218

RECONHECENDO ESTILOS DE CERVEJA COM UMA REDE NEURAL ARTIFICIAL
 Diogo Costa Pereira

HEATON, Jeff. **Programming neural networks with Encog3 in Java**. Heaton Research, Inc. WordsRU.com, 2011. Disponível em: <https://s3.amazonaws.com/heatonresearch-books/free/Encog3Java-User.pdf>. Acesso em: 17 out. 2020.

HUGHES, Greg. **Cerveja feita em casa**: tudo sobre os ingredientes, os equipamentos e as técnicas para produzir a bebida em vários estilos. Tradução de Rosane Albert. São Paulo: Publifolha, 2014.

LIMA, Fernando Parra dos Anjos; MINUSSI, Carlos Roberto. Usando uma rede neural de Kohonen para reconhecimento de padrões de som. **Omnia Exatas**, v. 4, n. 2, p.19-30, jul./dez. 2011.

MAPA – Ministério da Agricultura, Pecuária e Abastecimento. **Anuário da cerveja**: 2019. Secretaria de Defesa Agropecuária. Brasília: MAPA/DAS, 2020. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/inspecao/produtos-vegetal/publicacoes/anuario-da-cerveja-2019>. Acesso em: 17 set. 2020.

MIGUEZ, Geraldo; MACULAN, Nelson; XAVIER, Adilson Elias. **Desempenho do algoritmo de backpropagation com a função de ativação bi-hiperbólica**. Congresso Latino-Iberoamericano de Investigación Operativa. Rio de Janeiro: Simpósio Brasileiro de Pesquisa Operacional, 2012.

MORADO, Ronaldo. **Larousse da cerveja**: a história e as curiosidades de uma das bebidas mais populares do mundo. São Paulo: Alaúde Editorial, 2017.

OLIVEIRA, Jefferson dos Santos. **Panorama da indústria cervejeira**. 2018. 49 f. Trabalho de conclusão de curso (Graduação em Ciência e Tecnologia de Alimentos) – Instituto Federal de Educação, Ciência e Tecnologia do Sudeste de Minas Gerais, Rio Pomba - MG, 2018.

TOZETTO, Luciano Moro. **Produção e caracterização de cerveja artesanal adicionada de gengibre (*Zingiber officinale*)**. 2017. 82 f. Dissertação (Mestrado em Engenharia de produção) – Programa de Pós-Graduação em Engenharia de Produção, Universidade Tecnológica Federal do Paraná, Ponta Grossa - PR, 2017.