

UTILIZAÇÃO DOS CONCEITOS DE REDE NEURAL PARA OTIMIZAÇÃO DA MANUTENÇÃO PREDITIVA DE FILTROS DE AREIA PARA TRATAMENTO DE ÁGUA

Marcella D. R. G. B. Tacconi ¹; Murilo Zanini de Carvalho ²

¹ Aluno de Iniciação Científica da Escola de Engenharia Mauá (EEM/CEUN-IMT);

² Professor da Escola de Engenharia Mauá (EEM/CEUN-IMT).

Resumo Este propõe o uso de rede neural para otimização do cronograma de manutenção preditiva de filtros de areia. O uso dessa tecnologia visa a identificação de forma prática do momento correto de limpeza do elemento filtrante (areia), momento de troca do meio, ocorrência ou não de alteração no perfil da água bruta, dentre outros parâmetros. A variável que caracteriza o status do meio é a vibração do equipamento. Essa foi mensurada através do acelerômetro ADXL 345 posicionado estrategicamente no equipamento, as suas coordenadas nos três eixos cartesianos são os dados de entrada da rede neural que retorna em porcentagem a chance de estar em uma das três situações estudadas (areia limpa, areia que necessita de limpeza e areia suja, sujeita a substituição). Diversas configurações do algoritmo MLPRegressor foram analisadas e a configuração, que durante o treinamento supervisionado, se mostrou satisfatória foi a de três camadas ocultas com cem neurônios cada, duas mil interações, verbose true, função de ativação logisc e solver sgd.

Introdução

Diante da carência de informações sobre o real comportamento do filtro de areia e, muitas vezes, da dificuldade de estipular um cronograma de manutenção, cresce a busca por tecnologias que auxiliem elaboração desse cronograma que até então é realizado pelo método de tentativa e erro.

O filtro de areia (figura 1), equipamento que utiliza a areia como meio filtrante, é largamente aplicado no processo de remoção de contaminantes orgânicos e partículas de matéria em suspensão por apresentarem uma maior superfície de filtração. O equipamento é comprovadamente uma das melhores soluções em filtração de água, tanto para indústria como, principalmente, para irrigação localizada. O funcionamento consiste em duas etapas: filtração e retrolavagem (RAMIREZ, 2010).

Na filtração os sólidos em suspensão ficam retidos no meio poroso durante a passagem da água da água bruta. A eficiência da filtração esta diretamente relacionada com a granulometria dos grãos de areia, quantidade de areia e pelas características hidráulicas do sistema. Vale destacar que a eficiência está inversamente proporcional à vazão, quanto maior a vazão do sistema, menor será a retenção dos sólidos em suspensão (RAMIREZ, 2010).

A retrolavagem por sua vez, é exatamente o oposto da filtração, a água filtrada passa pelo sentido contrário ao sentido da filtração e remove os sólidos em suspensão do meio filtrante que são desprezados, limpando o meio e prolongando sua vida útil. A remoção acontece devido a diferença de densidade entre as partículas e o meio filtrante e deve acontecer sempre que houver perda de carga (MESQUITA, 2010).

A manutenção desse equipamento baseia-se principalmente na limpeza ou troca do elemento filtrante. Durante o primeiro ano de uso o fabricante recomenda que as pressões de entrada e saída sejam monitoradas semanalmente. Isso porque, a frequência de retrolavagem (limpeza do elemento filtrante que consiste na passagem da água filtrada no sentido oposto ao da filtração que deve ser realizada quando a pressão de saída diminui significativamente e a de entrada aumenta) depende exclusivamente das condições da água bruta a ser filtrada. A troca do elemento deve ser realizada quando o mesmo perde totalmente a sua função de filtração, ou seja, quando a pressão de entrada está muito acima da pressão normal e a de saída quase nula.



Figura 1 – Filtro de areia .

A tecnologia escolhida para determinação do comportamento do filtro de areia é a rede neural (figura 2). A técnica nasceu a partir da necessidade de se resolver uma gama de problemas de alta complexidade e recebe o nome de “rede neural” justamente por tentar imitar os neurônios e sua capacidade de reconhecer, associar e gerar padrões. Essa se torna imprescindível em situações onde almeja-se a classificação de padrões ou previsões de dados que mudam constantemente (BARRETO,2018).

O fundamento dessas unidades é bem simples, os neurônios são conectados em canais de comunicação, dados locais de entrada, que estão associados a determinado peso. A classificação de padrões e previsões são resultado das interações entre as unidades de processamento da rede. De forma sucinta o funcionamento ocorre conforme as etapas descritas abaixo (BARRETO,2018):

1. Sinais (dados coletados) são enviados à entrada (camada de entrada);
2. Cada sinal é multiplicado por um peso que indica a sua relevância;
3. A soma ponderada desses sinais, já multiplicados pelos pesos, indica o nível de atividade (camada intermediária);
4. A unidade reage conforme o nível de atividade (camada de saída).

A habilidade de aprender com o ambiente é realizado por meio de um processo iterativo de ajustes de pesos, o treinamento. Cada tipo de algoritmo modifica os pesos de uma forma, mas todos seguem um conjunto de regras bem definido. Os tipos de interação com o ambiente determinam também como a rede se comportará:

- **Aprendizado Supervisionado**, existe um agente externo que indica à rede a resposta desejada para o dado de entrada;
- **Aprendizado Não Supervisionado** (auto-organização), quando não existe um agente externo indicando a resposta desejada para os padrões de entrada;
- **Reforço**, quando um crítico externo avalia a resposta fornecida pela rede.




Figura 2 – Representação de Rede Neural.

Material e Métodos

A vibração do deslocamento da massa da água através do filtro de areia é a variável que caracteriza o estado físico do elemento filtrante, ou seja, quanto mais alta a vibração do equipamento, mais limpa está a areia. Vale destacar que não há dados de referência para situação. Diante disso, a presença de um manômetro na entrada e na saída de água mostra-se imprescindível para validação dos dados coletados. Para coleta dos dados de vibração utilizou-se um acelerômetro ADXL 345 que apresenta valores nas três direções do eixo cartesiano (x, y, z) e foram coletados dados em todas as situações propostas durante o ano todo.

A escolha da posição mais adequada do sensor foi determinada a partir de duas premissas: alta vibração e filtração finalizada em filtro de areia. A determinação do local de maior frequência vibratória só foi possível através de um estudo realizado em software de simulação de elementos finitos, como ilustrado na figura 3. Portanto, o acelerômetro foi posicionado embaixo do elemento filtrante (areia), possibilitando a comparação da aceleração da água entre os diferentes perfis de areia (limpa, suja ou que necessita de retrolavagem), como ilustrado na figura 4.




Figura 3 – Análise vibracional.


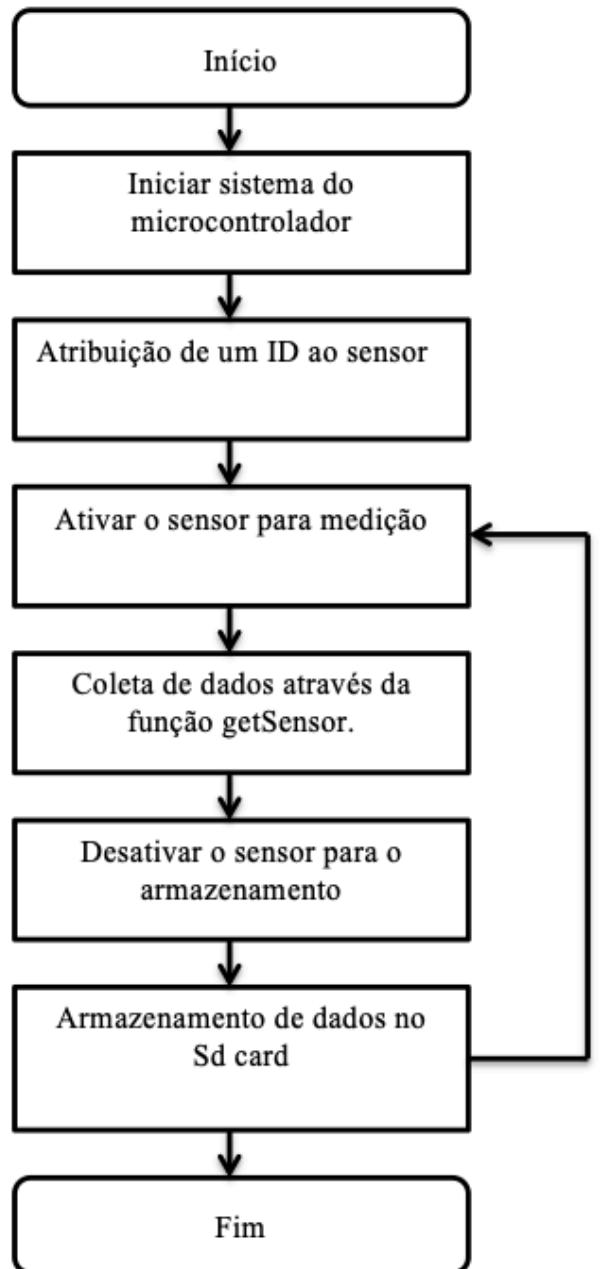


Figura 4 – Posicionamento do sensor.

O microcontrolador utilizado para processar os dados obtidos pelo acelerômetro foi o arduino UNO. O seu código consiste basicamente em coletar os dados do sensor e armazená-los em SD card a cada 1 minuto, o mesmo está representado no fluxograma a seguir.



A implementação da rede neural foi por meio do software *Anaconda*, dentro desse ambiente a biblioteca de aprendizado de máquina utilizada foi a *sklearn*, biblioteca de código aberto para a linguagem de programação Python. A escolha dessa linguagem se justifica pela simplicidade e facilidade de aprendizagem. O algoritmo utilizado para treinamento da rede foi o *MLPRegressor*, empregado com a finalidade de determinar a porcentagem de chance do dado estar em um dos três estados estudados (areia limpa, areia que necessita de retrolavagem e areia que necessita de troca, suja).

Apenas os parâmetros de alto impacto do MLPRegressor foram alterados. As configurações desses parâmetros estão relacionadas na tabela 1, tanto as camadas ocultas como o número de neurônios foram determinados de forma arbitrária como condição inicial do estudo.


Camadas Ocultas	Nº de neurônios em cada camada oculta	Função de ativação	Solver	Verbose	Nº max de interações
3	4	identity	lbfgs	TRUE	2000
	20	logistic	sgd		
	50	relu	adam		
	80				
	100				

Tabela 1 – Configurações testadas para treinamento da rede.

O aprendizado foi supervisionado mediante a função `rede.predict([[coordenadas dos três eixos na situação de areia limpa]])` e está exemplificado na figura 5.

A escolha pela configuração da rede mais adequada para esse conjunto de dados foi baseada em duas exigências:

1. Apresentar a maior porcentagem de chance do dado ser da situação de areia limpa durante o treinamento supervisionado.
2. Resultar nos menores valores de erro médio e desvio padrão durante a validação com a função `sklearn.model_selection import cross_val_score`.

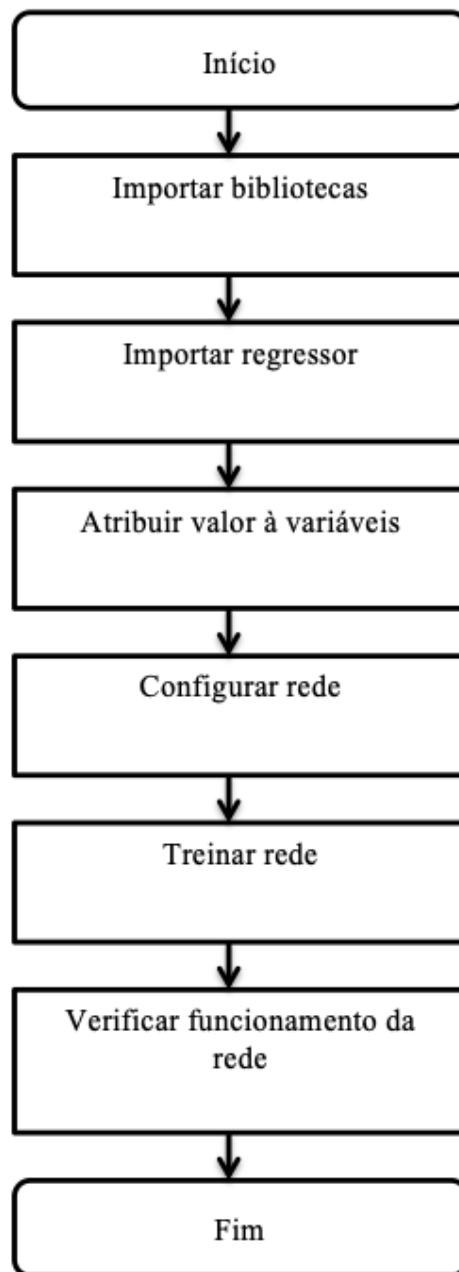


Legenda:

- A: Coordenadas cartesianas dos três eixos mensuradas pelo acelerômetro.
- B: 3 camadas ocultas treinadas pelo algoritmo MLPRegressor.
- C: Porcentagem de chance do dado estar em um dos três estados estudados.

Figura 5 – Exemplificação do funcionamento da rede neural estudada.

O código completo da rede neural está demonstrado no fluxograma a seguir de forma sucinta, com intuito de esclarecer o processo de determinação do status da areia.



Resultados e Discussão

Os dados apresentados nesse trabalho representam apenas as condições desse estudo (água da chuva coletada em calhas, com pequenas folhas e pedras, além das impurezas não visíveis a olho nu), é interessante continuar alimentando a rede com mais dados para que o treinamento seja contínuo. É necessário salientar que durante o estudo a rede foi alimentada constantemente, resultando em um banco de dados de milhares de leituras (apenas 3.500 leituras foram apresentadas afim de promover melhor visualização dos gráficos). As leituras estão expostas nas figuras 6 (leitura no eixo x), 7 (leitura no eixo y), 8 (leitura no eixo z).

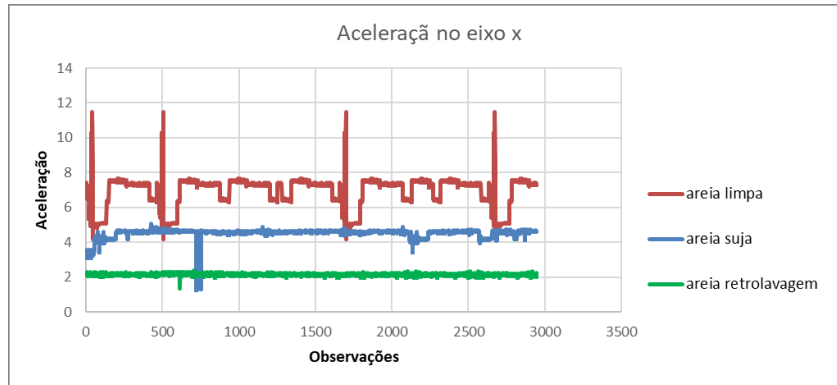


Figura 6 – Apresentação dos valores de vibração na direção x do eixo cartesiano nos três graus de saturação da areia para o perfil de água utilizado no estudo.

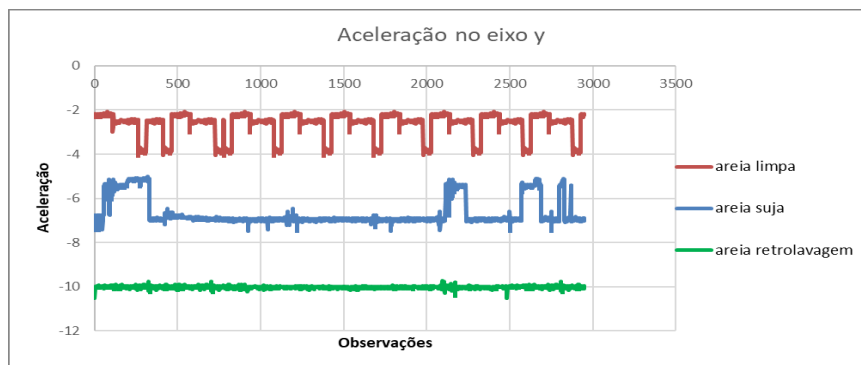


Figura 7 – Apresentação dos valores de vibração na direção y do eixo cartesiano nos três graus de saturação da areia para o perfil de água utilizado no estudo.

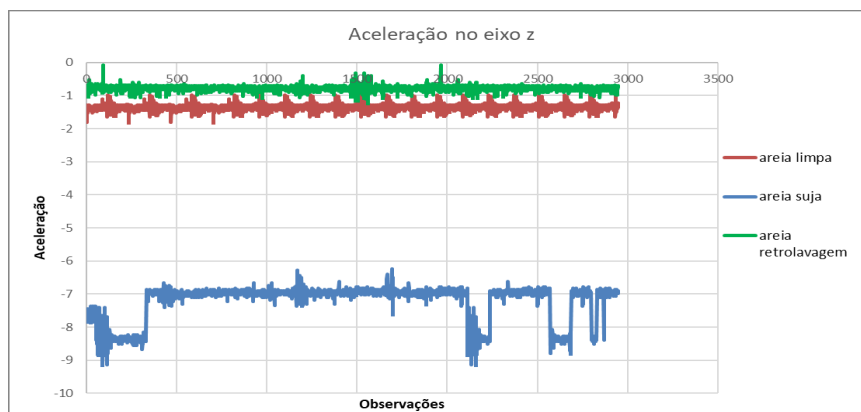


Figura 8 – Apresentação dos valores de vibração na direção z do eixo cartesiano nos três graus de saturação da areia para o perfil de água utilizado no estudo.

Na tabela 2 estão as porcentagens resultantes de cada configuração testada com os dados inseridos de areia limpa. O resultados grifados são da configuração escolhida.

Neurônios	Verbose	Interações	Camadas Ocultas	Função de ativação	Solver	% areia limpa	% areia suja	% retrorlavagem
4	TRUE	2000	3	identity	lbfgs	69.2	0.23	0.14
					sgd	79.7	24.7	37.5
					adam	73.4	21.5	16.1
				logistic	lbfgs	47.6	0.5	8.5
					sgd	50.25	50.23	0.15
					adam	68.3	12.88	3.5
				relu	lbfgs	43.1	56.9	0.06
					sgd	48.94	49.61	22.17
					adam	91.63	15.12	0.92
20	TRUE	2000	3	identity	lbfgs	89.7	0.1	0.7
					sgd	49.4	5.14	6.2
					adam	65.5	6.3	5.9
				logistic	lbfgs	69.4	5.14	0.3
					sgd	50.3	49.5	0.23
					adam	75.4	1.44	0.2
				relu	lbfgs	96	1.8	0.18
					sgd	76.6	4.14	19.4
					adam	95	3.1	0.6
50	TRUE	2000	3	identity	lbfgs	78.4	0.4	0.7
					sgd	68.8	5.6	3.3
					adam	79.5	0.16	4.2
				logistic	lbfgs	78.5	1.5	0.13
					sgd	49.8	50	0.1
					adam	69.5	11.6	0.8
				relu	lbfgs	87.3	0.44	0.41
					sgd	98.4	15.22	9.1
					adam	97.6	1.1	1.4
80	TRUE	2000	3	identity	lbfgs	97.5	0.37	0.33
					sgd	96.2	3.5	2.5
					adam	94.5	6.2	4.4
				logistic	lbfgs	95.4	3.5	0.17
					sgd	51.6	49.1	0.15
					adam	95.4	12.4	0.34
				relu	lbfgs	98.2	0.14	0.58
					sgd	97.5	1.7	0.82
					adam	96.8	1.15	1.2
100	TRUE	2000	3	identity	lbfgs	94.8	0.19	0.1
					sgd	91.8	4.8	2.4
					adam	94.3	11.25	0.7
				logistic	lbfgs	96.17	3.6	0.63
					sgd	99.98	0.91	0.11
					adam	94.74	5.6	0.21
				relu	lbfgs	98.99	0.93	1.5
					sgd	89.87	8.9	6.5
					adam	95.78	1.82	0.9

Tabela 2 – Resultados do treinamento da rede em todas as configurações propostas.

Na tabela 3 estão os resultados da análise de precisão da rede, porcentagens de erro médio e desvio padrão, realizada através da função *cross_val_score*. O resultados grifados são da configuração escolhida.

Neurônios	Verbose	Interações	Camadas Ocultas	Função de ativação	Solver	Erro Médio %	Desvio Padrão %
4	TRUE	2000	3	identity	lbfgs	6,6	20,3
					sgd	7,8	14,5
					adam	6,9	15,8
				logistic	lbfgs	6,3	19,6
					sgd	6	17,8
					adam	6,3	19,9
				relu	lbfgs	6,6	19,3
					sgd	6	17,4
					adam	6	18,7
20	TRUE	2000	3	identity	lbfgs	6,6	19,6
					sgd	6,5	19,6
					adam	6,2	18,4
				logistic	lbfgs	6,3	19,3
					sgd	6	18,5
					adam	6,3	19,9
				relu	lbfgs	6,6	20,2
					sgd	6,3	19,1
					adam	6,4	19,4
50	TRUE	2000	3	identity	lbfgs	6,6	20,6
					sgd	6,5	19,5
					adam	6,5	19,5
				logistic	lbfgs	6,6	19,9
					sgd	5,9	17,8
					adam	5,9	17,8
				relu	lbfgs	6,6	19,9
					sgd	6,4	19
					adam	6,4	19,2
80	TRUE	2000	3	identity	lbfgs	6,6	19,9
					sgd	6,5	19,7
					adam	6,5	19,7
				logistic	lbfgs	6,4	19,2
					sgd	6	18
					adam	6	18
				relu	lbfgs	6,4	19,3
					sgd	6,3	18,8
					adam	6,5	19,7
100	TRUE	2000	3	identity	lbfgs	6,7	19,9
					sgd	6,6	19,7
					adam	6,5	19,6
				logistic	lbfgs	6,7	19,9
					sgd	5,8	17,7
					adam	6,5	19,7
				relu	lbfgs	6,6	19,9
					sgd	6,3	19
					adam	6,6	19,9

Tabela 3 – Resultados da validação de todas as configurações propostas.

Conclusões

Durante a análise dos resultados o uso da rede neural se fez ainda mais necessário. Percebeu-se que os dados apresentados representavam apenas e exclusivamente a aquela condição de filtração, pois as impurezas encontradas na água a ser filtrada se alteram de uma fonte para outra, ou até mesmo, com o tempo, na mesma fonte. É inviável mensurar ou até mesmo determinar um comportamento de referência uma vez que não existe um caso geral que possibilite estabelecer uma relação entre impurezas e vibração do equipamento. Além disso, a potência da bomba utilizada no sistema de filtração também influencia no comportamento vibracional do estudo.

Diante disso, era esperado que a rede identificasse a relação entre as variáveis e então determina-se o grau de saturação da areia, identificando retrolavagem ou troca do meio sem que o usuário se preocupe com a quantidade e tipo de impurezas (antes da escolha do equipamento realiza-se um teste físico-químico para verificação de ferro e manganês, e também uma análise visual dos sólidos em suspensão. Dentro do grupo de sólidos em suspensão existem vários tipos de impurezas que tornam o filtro de areia adequado para o tratamento). A configuração que apresentou melhor desempenho durante o treinamento com os dados conhecidos de areia limpa (99,98 % de chance de ser esse estado), foi a apresentada na tabela 4. Além disso, na validação resultou nos menores erro médio (5,8%) e desvio padrão (17,7%).

CAMADAS OCULTAS	Nº DE NEURÔNIOS EM CADA CAMADA OCULTA	FUNÇÃO DE ATIVAÇÃO	SOLVER	VERBOSE	Nº MAX DE INTERAÇÕES
3	4	Identity	lbfgs	TRUE	2000
	20	Logistic	sgd		
	50	Relu	adam		
	80				
	100				

Tabela 4 – Configuração da rede que apresentou melhor desempenho.

Referências Bibliográficas

BANAFÁ, Ahmed. **WHAT IS NEXT FOR IOT & IIOT?** San Jose, California: College Of Engineering San Jose State University, 2015. Color.

BARRETO, Jorge M. **Introdução às redes neurais.** Disponível em: <<http://www.inf.ufsc.br/~j.barreto/tutoriais/Survey.pdf>>. Acesso em: 26 mar. 2018.

EVANS, Dave. **The Internet of Things: How the Next Evolution of the Internet Is Changing Everything.** Cisco Internet Business Solutions Group (ibsg), San Jose, California, v. 01, n. 01, p.01-11, abr. 2011.

MESQUITA, Márcio. **Avaliação dos componentes hidráulicos e do material filtrante em filtros de areia utilizados na irrigação.** 2010. 119 f. Dissertação (Mestrado) - Curso de Engenharia Agrícola, Unicamp, Campinas, 2010.

RAMIREZ, Juan Camilo Salcedo. **Efeito das características granulométricas e da altura da camada filtrante no processo de retrolavagem em filtros de areia.** 2010. 158 f. Dissertação (Mestrado) - Curso de Engenharia Agrícola, Unicamp, Campinas, 2010.

VELLASCO, Marley Maria Bernardes Rebuszi. **Redes neurais artificiais.** Disponível em: <<https://drive.google.com/drive/folders/1OZDxtJT6BXE6Oxcchyr5XD-sU9C7BT1g?ogsrc=32>>. Acesso em: 15 abr. 2018.