
Copyright 2018, ABRACO

Trabalho apresentado durante o INTERCORR 2018, em São Paulo, no mês de maio de 2018.

As informações e opiniões contidas neste trabalho são de exclusiva responsabilidade do(s) autor(es).

Rede Neural Aplicada em Sistemas de Proteção Catódica – Estudo de Caso

Rodrigo M.S. Soares^a, Vitor H. Ferreira^b, Márcio Z. Fortes^c.

Abstract

Cathodic protection is a technique used for the preservation of metallic structures immersed in an electrolyte, whose function is to minimize corrosion to derisory values. The control to verify the good functioning of these systems is given through the field inspection or through monitoring via datalogger. In both cases, there is a periodicity of verification in the field, whose interval between inspections will be done according to the importance that each one has for a given system. The cathodically protected metal structures are usually arranged in the subsoil of large cities, and thus are subject to various events that are likely to hamper their inspection. Having a good database of previous inspections, aligned with a regression-supervised learning algorithm, missing measurements can be estimated, leading to greater system reliability by improving maintenance, safety, and environmental indices. The objective of this work is, from the cathodic protection database of a natural gas distribution pipeline, to create a neural network that, through the regression, can estimate the missing data of one of the measurement points at a given instant.

Keywords: Machine learning, supervised learning, regression, cathodic protection.

Resumo

A proteção catódica é uma técnica utilizada para preservação de estruturas metálicas imersas em um eletrólito, cuja função é minimizar a corrosão a valores irrisórios. O controle para verificação do bom funcionamento deste sistema se dá através da inspeção em campo ou por meio de monitoração via *datalogger*. Em ambos os casos há uma periodicidade de verificação em campo, cujo intervalo entre inspeções será feito de acordo com a importância que cada um tem para um determinado sistema. As estruturas metálicas protegidas catódicamente estão normalmente dispostas nos solos de grandes cidades, sendo assim, estão sujeitas a diversos acontecimentos que possivelmente irão dificultar sua inspeção. Tendo uma boa base de dados de inspeções anteriores, alinhada com um algoritmo de aprendizado supervisionado por regressão, as medições faltantes poderão ser estimadas, levando a uma maior confiabilidade ao sistema melhorando os índices da manutenção, segurança e meio ambiente. O objetivo deste trabalho é, a partir da base de dados da proteção catódica de um gasoduto de

^a Mestrando, Engenheiro Eletricista – GÁS NATURAL FENOSA.

^b Doutor, Engenheiro Eletricista – UFF.

^c Doutor, Engenheiro Eletricista – UFF.

distribuição de gás natural, criar uma rede neural que, através da regressão, possa estimar o dado faltante de um dos pontos de medição em um determinado instante.

Palavras-chave: Aprendizado de máquina, aprendizado supervisionado, regressão, proteção catódica.

Introdução

O aprendizado de Máquina (AM) é uma técnica que gera um modelo computacional da capacidade de aprender a partir da interação com seu ambiente visando melhorar o seu desempenho na execução de uma determinada tarefa (1). Ainda que o AM seja uma ferramenta poderosa para a aquisição automática de conhecimento, deve ser observado que não existe um único algoritmo que apresente o melhor desempenho para todos os problemas. Portanto, é importante compreender o poder e a limitação dos diversos algoritmos de AM utilizando alguma metodologia que permita avaliar os conceitos induzidos por esses algoritmos em determinados problemas (2).

Uma forma de aprendizagem que pode ser aplicada em AM é a aprendizagem indutiva. A indução é a forma de inferência lógica que permite obter conclusões genéricas sobre um conjunto particular de exemplos, ou seja, um conceito é aprendido efetuando-se inferência indutiva sobre os exemplos apresentados, portanto, as hipóteses geradas através da inferência indutiva podem ou não preservar a verdade (2).

O aprendizado indutivo é efetuado a partir do raciocínio sobre exemplos fornecidos por um processo externo ao sistema de aprendizado. O aprendizado indutivo pode ser dividido em supervisionado e não supervisionado. No aprendizado supervisionado é fornecido ao algoritmo de aprendizado, ou indutor, um conjunto de exemplos de treinamento para os quais o rótulo da classe associada é conhecido, ou seja, devem existir dados de entrada com suas respectivas saídas, para serem apresentadas ao algoritmo de aprendizado utilizado durante o processo de treinamento (3). O objetivo do algoritmo de indução é construir um tipo de classificador que possa determinar corretamente a classe de novos exemplos ainda não rotulados. Para rótulos de classe discretos, esse problema é conhecido como classificação e para valores contínuos como regressão.

A proteção catódica pode ser definida como abrandamento ou prevenção total de todas as formas de corrosão em estruturas metálicas imersas em um eletrólito (4). A rotina de inspeção dos elementos de proteção catódica segue uma periodicidade de acordo com a importância destes para o sistema. Diversas medições são coletadas pelo inspetor de campo, e, a partir delas, ações são tomadas após a análise dos dados.

Eventualmente, dados faltantes da inspeção de campo ou do sistema de monitoramento tornam a análise de um determinado sistema de proteção catódica incompleta.

Diante deste problema e visando solucioná-lo, o aprendizado de máquina, mais especificamente o aprendizado supervisionado, mostra-se uma ferramenta poderosa para estimativa dos dados faltantes em um determinado período, com base em um sólido banco de dados, aumentando a confiabilidade do sistema e do setor de manutenção.

Metodologia

Para garantir que a proteção catódica esteja sendo aplicada de maneira correta em todas as áreas dos dutos envolvidos, deve ser construído ao longo deste, pontos de monitoração de potencial respeitando os seguintes critérios:

- 1) Para obter uma boa proteção, a taxa de corrosão do metal deverá ser inferior a 0,01 mm por ano.
- 2) É adotado como valor máximo de proteção, o potencial de -0,85 V com relação ao eletrodo de referência de Cu/CuSO₄, ou seja, $E_p = -0,85$ V.
- 3) É adotado como valor mínimo de proteção, o potencial de -1,20 V com relação ao eletrodo de referência de Cu/CuSO₄, ou seja $E_c = -1,2$ V.

O potencial metal-eletrólito (E) deverá ser menor ou igual ao potencial de proteção (E_p) e que por sua vez, deverá ser maior ou igual que o potencial crítico (E_c). Este último se deve ao fenômeno da fragilização por hidrogênio provocado por potenciais muito baixos, tendo como ônus o descolamento do revestimento protetor do metal e/ou um alto pH na superfície do metal (5). Valores entre o potencial de proteção e o potencial crítico são considerados ideais para a proteção das tubulações de gás enterradas (6) e (7).

Foi utilizado como base para este problema um gasoduto de aço carbono API 5L grau B, de aproximadamente 40 km de extensão, 350 mm de diâmetro, 12 kgf/cm² de pressão, de uma companhia de distribuição de gás natural. Esta linha possui 9 pontos de medição de potencial e 4 retificadores de proteção catódica, monitorados via *datalogger* diariamente.

Segue na Figura 1 imagem via satélite dos equipamentos posicionados no *Google Earth*. A linha vermelha representa o gasoduto, os 4 pontos vermelhos representam os retificadores de proteção catódica, os pontos em amarelo representam os pontos de medição de potencial.

Das 12 entradas no programa, 4 são valores de corrente de saída (retificadores) e 8 de potencial tubo-solo (entre o gasoduto e uma semi-célula de cobre/sulfato de cobre - Cu/CuSO₄) e uma saída de potencial tubo-solo. Dentro da configuração deste sistema, o ponto que tem potencial mais próximo ao limite do potencial de proteção (E_p) é o ponto PT06, portanto é o ponto que deverá ter atenção especial e será à saída de dados deste estudo. Desta maneira, a base de dados possui uma tabela com 13 colunas e 773 linhas com medições diárias coletadas entre o período de 21/10/2014 à 01/12/2016. Os valores coletados foram do resumo diário do sistema por elemento. Neste resumo há valores mínimos, médios, máximos e predominantes. O *datalogger* faz medições a cada segundo durante 24 horas, ou seja, são 86.400 medidas que irão gerar o resumo e conseqüente envio do mesmo para o sistema. Para este trabalho foram utilizados os valores da predominância diária por elemento

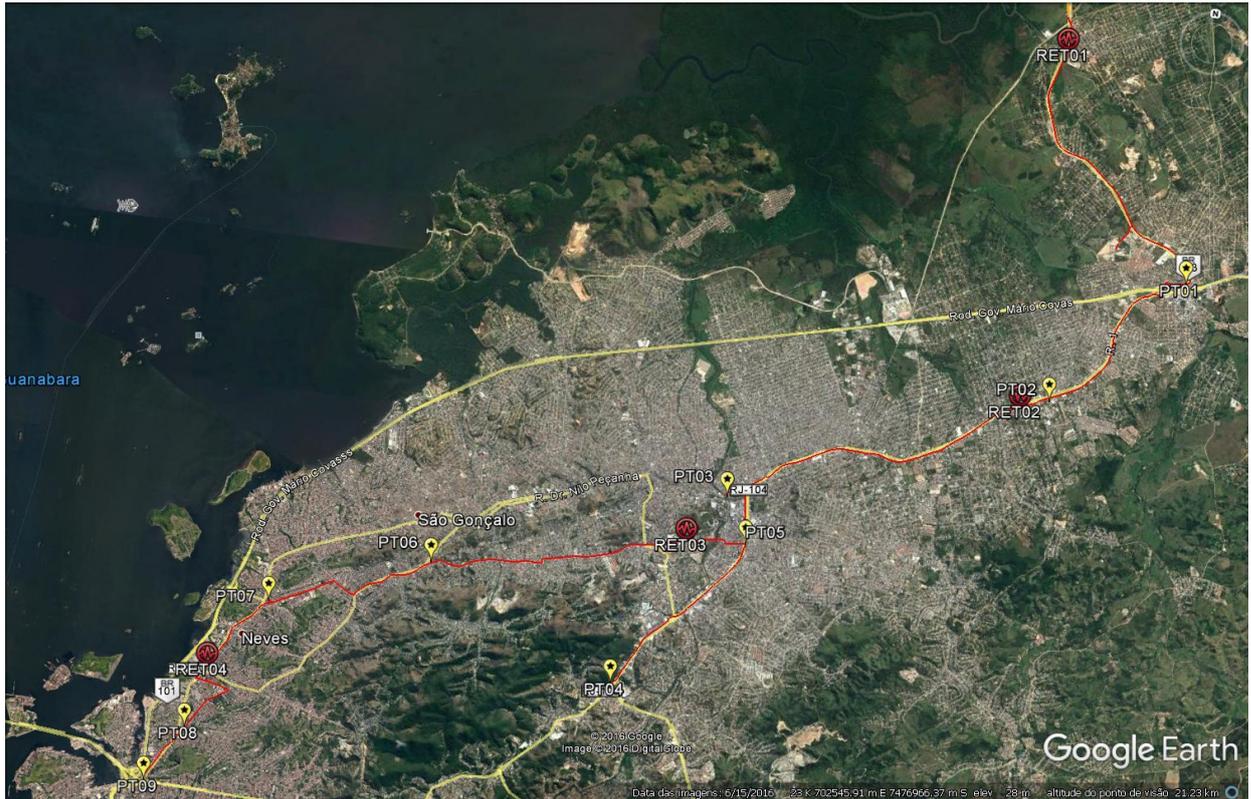


Figura 1 – Equipamentos posicionados no *Google Earth*

Definindo as entradas e a saída esperada, será dado um *input* da base de dados no sistema. A fim de evitar problemas relativos à estagnação do treinamento, as entradas e saída serão normalizadas em uma faixa, neste caso definida entre $[-1 \ 1]$ pois os dados têm valores e características diferentes.

Após normalização dos dados, será definido o número de neurônios que serão utilizados. Segundo o teorema de aproximação universal, uma camada oculta é o suficiente, tendo apenas que definir o número de neurônios que serão utilizados neste sistema, que será definido de acordo com a melhor aproximação ou menor erro da saída. Após testes na faixa entre 30 e 50 neurônios, foi definida a configuração com 36 neurônios, como sendo o melhor modelo para este sistema. Segue na Figura 02 o diagrama de blocos do sistema.

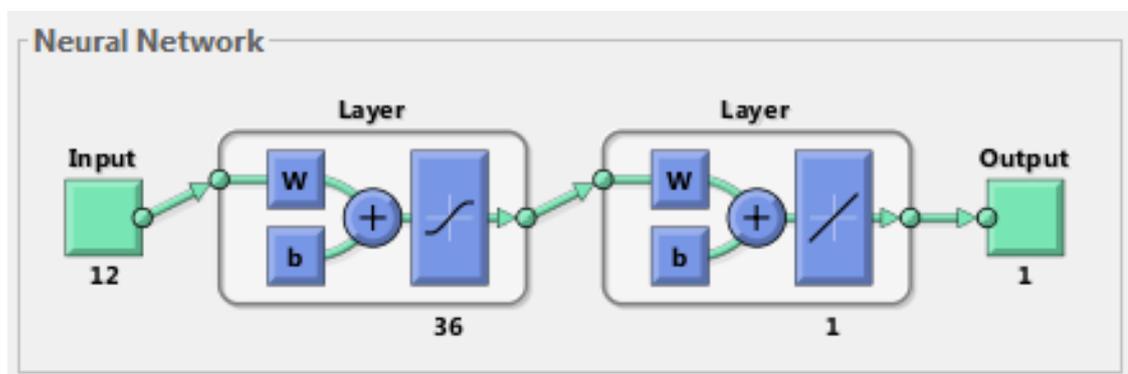


Figura 2 – Diagrama de blocos da rede neural (MATLAB)

Foram utilizados 20% dos dados para validação e escolha do modelo. A medida do número de vezes que todos os vetores de treinamento são usados para atualizar os pesos é chamada de *epoch*. Nesta rede neural foram utilizados 1000 *epochs*. Todas as amostras de treinamento passam pelo algoritmo de aprendizado simultaneamente em uma época antes que os pesos sejam atualizados. Neste primeiro momento, a saída do sistema é conhecida para definição do modelo.

Após definição dos parâmetros de funcionamento da rede neural, o usuário poderá imputar ao sistema 12 novas entradas, que serão normalizadas e verificadas pela rede. Após as iterações, uma saída será dada pelo sistema. Os dados imputados para obtenção desta nova saída não foram utilizados no treinamento do sistema, sendo assim, possível verificar a confiabilidade deste resultado.

Resultados e discussão

Na aprendizagem supervisionada a saída desejável é conhecida, portanto, é possível mensurar o erro cometido pelo modelo. O sinal de erro aciona um mecanismo de controle responsável pelo ajuste dos parâmetros visando otimizar uma determinada medida de desempenho (8). Segue na Figura 3 o diagrama de funcionamento do aprendizado supervisionado.

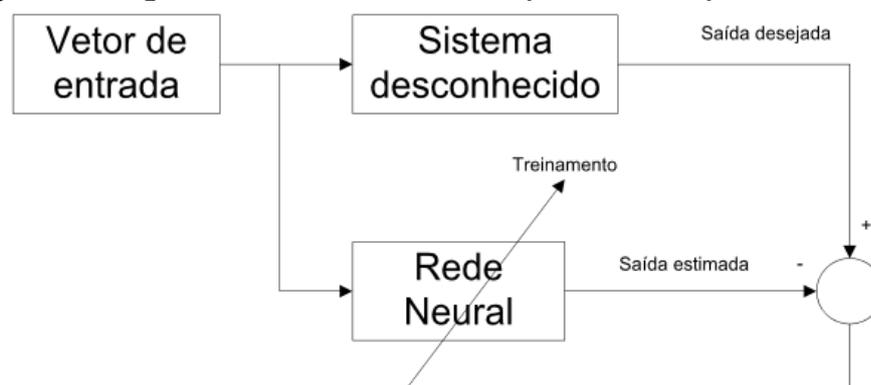


Figura 3 – Sistema aprendido supervisionado

A fim de validar a rede neural criada, serão imputados ao sistema 5 conjuntos de entradas com as respectivas saídas conhecidas que serão comparadas com a saída da rede. Para melhor visualização do problema, segue na Figura 4 as variáveis alocadas em um modelo linear.

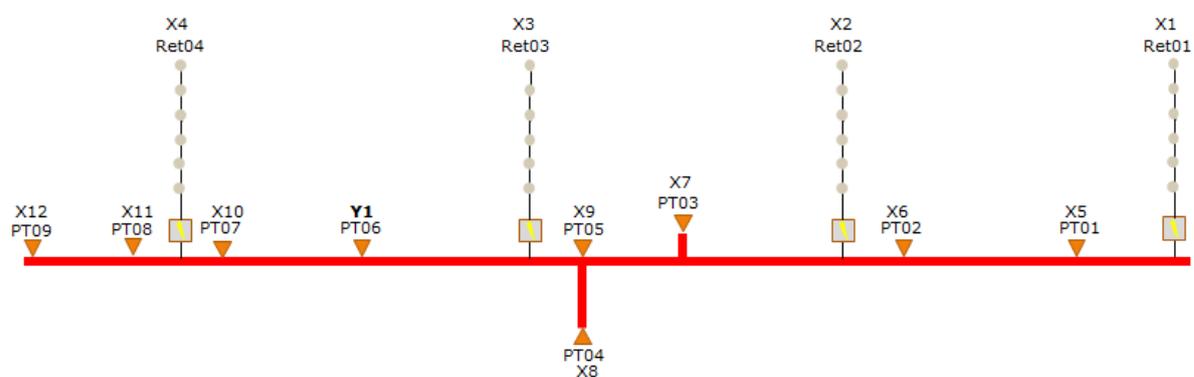


Figura 4 – Variáveis alocadas em um modelo linear

Na Tabela 1 verifica-se o conjunto X1 a X12 de entrada, a saída esperada Y1, a saída da rede neural e o erro da rede para cada conjunto.

Tabela 1 – Conjunto de entradas e saídas da rede neural

X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	Saída Esperada	Saída Rede	Erro (%)
7,3	4,9	9,1	11,1	-2,4	-3,3	-1,9	-1,8	-1,6	-1,6	-1,8	-1,8	-1,8	-1,798	0,094
7,4	5,1	9,2	11,1	-2,2	-2,9	-1,7	-1,8	-1,5	-1,6	-1,6	-1,5	-1,9	-1,889	0,558
5,8	5,1	9,1	11,1	-1,8	-2,2	-1,5	-1,6	-1,4	-1,3	-1,5	-1,4	-1,3	-1,300	0,000
6,0	4,3	3,9	10,2	-1,9	-2,4	-1,5	-2,0	-1,4	-1,4	-1,5	-1,6	-0,9	-0,911	1,178
6,0	4,3	2,7	10,2	-1,8	-2,3	-1,5	-1,9	-1,4	-1,4	-1,5	-1,6	-0,8	-0,803	0,375
													Erro Médio	0,441

Segue na Figura 04 o gráfico representando o erro quadrático médio pela *epoch*, cujo melhor desempenho de treinamento foi na *epoch* 1000, com um valor de 0,00041437.

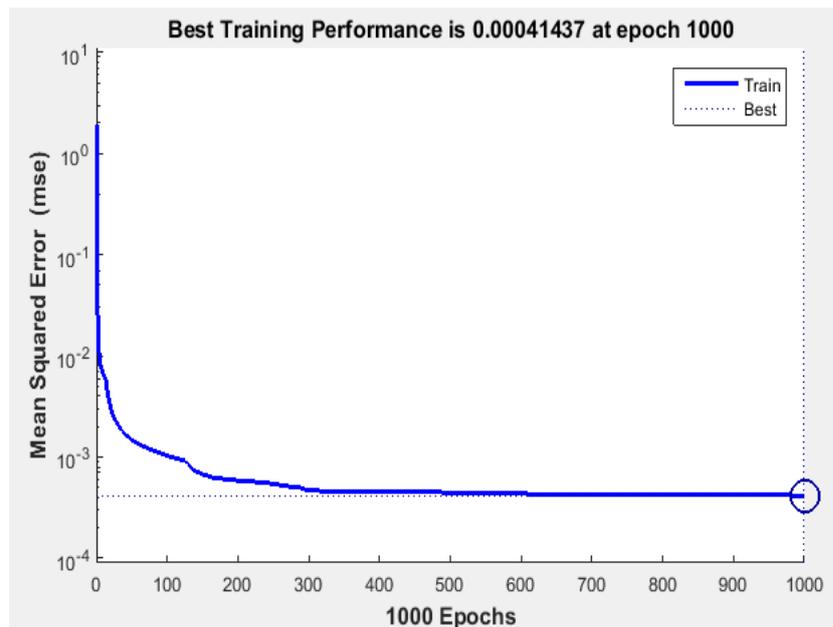


Figura 4 – Gráfico erro quadrático médio x *epoch*

O valor R na Figura 5 é uma indicação da relação entre as saídas do sistema e a saída esperada. Se $R = 1$, isso indica que há uma relação linear exata entre elas, no entanto, se R é próximo de zero, não há relação linear. No treinamento R atingiu o valor de $R=0,99844$, próximo de 1, indicando relação linear entre a saída do sistema e a saída esperada.

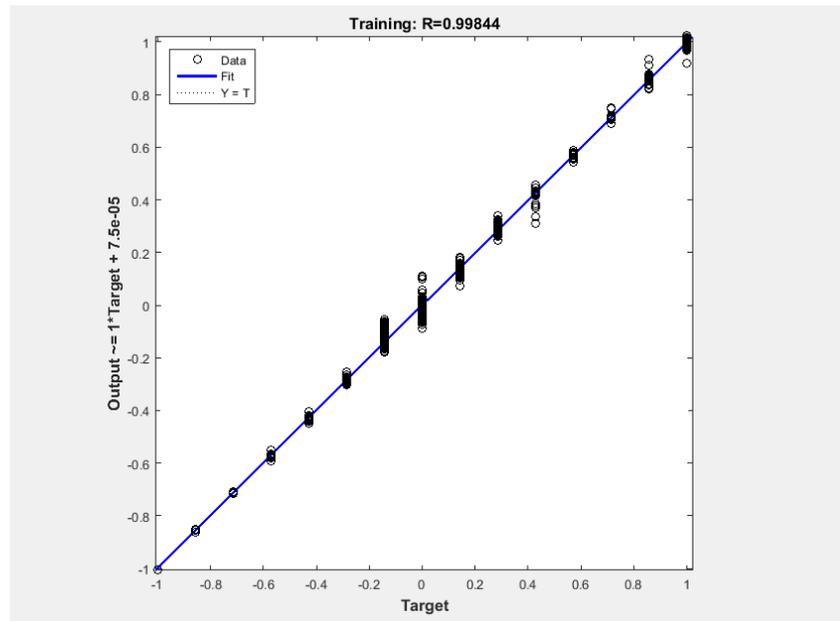


Figura 5 – Relação entre a saída e a saída esperada

Conclusões

A rede neural criada para este sistema de proteção catódica, com base no histórico que possuía, mostrou-se efetiva nos testes realizados, com erros consideráveis dentro de uma margem aceitável para este problema, aumentando a confiabilidade do sistema, dando uma maior segurança na tomada de decisões do setor de manutenção.

O sistema analisado possui pouca variação histórica de potenciais e não possui problemas de interferência elétrica, o que facilita na hora do treinamento, pois não há variáveis desconhecidas ou fora de um padrão normal. Caso fosse uma linha com interferência elétrica, poderia inviabilizar esta análise ou aumentar o erro de forma considerável.

Referências bibliográficas

- (1) R.S.SUTTON E A.G. BARTO, “Reinforcement Learning: An Introduction”. 2012
- (2) M.C.MONART E J.A.BARANAUSKAS, “Conceitos sobre Aprendizado de Máquina” Capítulo 4.
- (3) F.BORSATO E M.FIGUEIREDO, “Aprendizagem por Reforço em Redes Neurais Multicamadas Aplicadas em Controle Autônomo”.
- (4) L. LAZZARI, P.PEDEFERRI, “Cathodic Protection,” 1st edition, Polipress Milano, 2006.
- (5) A.C.DUTRA E L.P. NUNES, “Proteção Catódica – Técnica de Combate à corrosão” 5ª Edição – 2011.
- (6) ABNT NBR ISSO 15589-1:2016 – Indústria do Petróleo e Gás Natural – Proteção Catódica para Sistemas de Transporte de Dutos Parte1: Dutos Terrestres.
- (7) ISO 15589-1:2015 - Petroleum, petrochemical and natural gas industries - Cathodic protection of pipeline systems - Part 1: On-land pipelines
- (8) GEDSON FARIA E ROSELI F. ROMERO, “Explorando o Potencial de Algoritmos de Aprendizado com Reforço em Robôs”. 1999