

Identificação de conexões hidráulicas utilizando redes neurais

Michael Byington¹, Anouk van Pol¹, John van Pol¹

¹Ingu Solutions Inc



**18ª PIPELINE
TECHNOLOGY
CONFERENCE**

8 a 11 de MAIO DE 2023, BERLIM

Organizado por



Instituto Europeu para Transferência de
Informações e Tecnologia

Processo da Pipeline Technology Conference 2023 (ISSN 2510-6716).

www.pipeline-conference.com/conferences

Copyright ©2023 por EITEP Institute.

1 RESUMO

Ferramentas de ILI convencionais utilizam odômetros de roda para determinar a localização dos defeitos identificados. Além disso, marcadores de superfície (AGMs) tipicamente são utilizados para confirmar e possivelmente corrigir deslizamentos dos odômetros de roda. As ferramentas de ILI não convencionais de livre flutuação utilizam informações de uma variedade de sensores para localizar com precisão os defeitos. Identificar as conexões com precisão é um pressuposto para a localização e identificação automáticas e fundamental para uma inspeção economicamente viável.

Esse trabalho se concentra na automação da processo de identificação de conexões com uma rede neural. Vamos apresentar estratégias de aprendizagem aprofundada (*deep learning*) identificação e segmentação de recursos discretos em dados de séries temporais, como essas estratégias estão aprimorando a eficiência do processamento de dados, os níveis atuais de precisão e as limitações, bem como estratégias de normalização para dados de múltiplos sensores.

2 INTRODUÇÃO

O uso de ferramentas de inspeção em linha (ILI) é essencial para a operação segura e eficiente das tubulações. Entretanto, as ferramentas de ILI convencionais têm suas limitações, como a necessidade de utilizar odômetros de roda ou marcadores de superfície (AGMs) para localizar com precisão os defeitos. Para superar essas limitações, ferramentas de ILI não convencionais de livre flutuação foram desenvolvidas e utilizam informações de uma variedade de sensores para localizar com precisão os defeitos. Para tornar essas ferramentas economicamente viáveis, é preciso automatizar o processo de identificação de conexões. Este documento discute como as estratégias de deep learning podem ser utilizadas para identificação e segmentação de recursos discretos entre dados de séries temporais, uma vez que essas estratégias estão aumentando a eficiência do processamento de dados, a precisão e as limitações atuais e estratégias de normalização para dados de múltiplos sensores. Especificamente, vamos nos concentrar no uso de uma rede neural convolucional, conhecida como UNet, para esse fim.

Em 2016, uma falha de tubulação na América do Norte resultou na liberação descontrolada de 2.000 toneladas métricas de hidrocarboneto (nas formas líquida e gasosa) [1]. Ensaios de fuga do fluxo magnético (FFM) e dispositivos de ultrassom foram as principais ferramentas utilizadas para a gestão da integridade da tubulação desde os anos 1980. Entretanto, devido curvas fechadas, válvulas não circulares, alterações nos diâmetros ou geometrias desconhecidas [1,2], cerca de 70% dos gasodutos nos EUA, construídos antes que a inspeção em linha (ILI) moderna fosse considerada uma tecnologia viável, são consideradas não pigáveis [3]. Pesquisas do setor em 2012 indicam que 40% dos gasodutos na América do Norte não são pigáveis [4]. Em resposta a esse problema, tecnologias foram desenvolvidas mais recentemente, desde o início dos anos 2000, para lidar com a questão das linhas não pigáveis [5,6].

Não obstante a tecnologia, a determinando precisa da localização na tubulação sempre foi um desafio. Ferramentas tradicionais de ILI utilizam odômetros de roda, mas o deslizamento continua sendo um problema, particularmente em dutos com grandes depósitos ou superfícies ásperas [7]. Para minimizar a imprecisão na distância, marcadores de superfície (AGMs) externos podem ser utilizados. Os AGMs são fabricados nas variantes magnética, acústica ou geofone eletrônico [8, 9, 10]; entretanto, são dispendiosos e muitas vezes não podem ser utilizados em áreas urbanas tumultuadas, devido à sua precisão limitada conforme a profundidade da tubulação. Dispositivos multissensoriais de livre flutuação são um método alternativo para solucionar o problema da localização, e têm seus próprios pontos fortes e fracos. Soldas identificadas com base em dados de magnetômetros são um dos principais componentes da conversão entre o tempo de medição e a distância de medição [11]. A rede neural (RN) pode automatizar a detecção de soldas em tubos de aço a partir de dados residuais dos magnetômetros, com desempenho semelhante ao humano. A automação desse gargalo crítico melhora significativamente a escalabilidade dos dispositivos multissensoriais de livre flutuação.

3 UMA SEGMENTAÇÃO DIMENSIONAL COM REDES NO ESTILO UNET

A morfologia das conexões, conforme detectadas por magnetometria residual, é altamente variável. Algumas conexões em tubulações podem ser localizadas com a simples identificação dos picos, embora outras se manifestam como aumentos sutis na frequência de oscilação. Outras são tão sutis que só podem ser determinadas se for considerado o espaçamento médio entre as conexões nas proximidades. Como a identificação de conexões não conta com atributos articuláveis precisos que permitam seu uso na programação obrigatória, uma rede neural (RN) é a solução mais promissora. Para desenvolver um sistema automatizado de conexões detecção sistema, este é conceitual como um 1D segmentação problema. Identificadores são utilizado em cada ponto de dados (com ou sem conexão) e uma RN foi projetada para classificar cada ponto. A rede usa quatro vetores magnéticos como entradas (m_x, m_y, m_z e m_t onde $m_t = (m_x^2 + m_y^2 + m_z^2)^{0,5}$) e retorna dois valores y_1, y_2 . A probabilidade de uma conexão vs função de posição é dada pela função softmax $p = \text{registro} \left(\frac{e^{y_2}}{e^{y_1} + e^{y_2}} \right)$. Ver Figura 1.




Figura 1 (a) As entradas para a rede neural não estão normalizadas devido à magnitude dos valores e à ausência de uma referência natural à normalização. (b) O resultado bruto da rede neural é exibido em unidades arbitrárias. (c) O valor softmax dos vetores de saída da rede neural de (b) fornecem uma medida de certeza para cada conexão, com identificação dos picos produzindo uma lista de conexões (exibida na cor ciano).

Desde que o artigo de referência da UNet foi publicado em 2015 [13], as redes neurais inteiramente convolucionais têm se tornado a regra de fato para tarefas de segmentação. Milhares de variações e aplicações na UNet foram documentadas desde então, com 54.960 citações ao artigo original desde 11/01/2023. Nossa aplicação da UNet torna obrigatórias diversas modificações; primeiramente, como utilizamos dados 1D em vez de dados 2D, os campos receptivos devem ser aumentados para refletir a expressiva distância entre os pontos de dados. Em segundo lugar, a precisão necessária para identificar as conexões é inferior à requerida pra a segmentação por imagem, portanto, não é necessário que os vetores de saída tenham as mesmas dimensões dos vetores de entrada. Finalmente, como os dados da tubulação são de natureza magnética e não micrográficos de células, os aumentos adequados dos dados para fins de treinamento não são idênticos.

3.1.1 Arquitetura e campos receptivos para dados 1D

A expansão do campo receptivo para abranger múltiplas conexões permite que a rede neural replique a compreensão contextual que a identificação manual de conexões emprega. É possível que aquilo que se pode interpretar como uma conexão na assinatura magnética de uma tubulação pode ser simplesmente uma flutuação normal em um segmento da tubo em outra linha. Quando as conexões são identificadas manualmente, procuramos padrões de assinatura com distâncias semelhantes entre si. Para a rede neural limitar com precisão esse processo, o campo receptivo de seus neurônios mais profundos deve abranger múltiplas conexões. Esta perspectiva é essencial para a adaptação da UNet a uma segmentação 1D. As imagens quadradas de 572x572 pixel originárias da UNet contêm 327.184 pontos de dados por imagem, nenhum dos quais a mais de 571 passos de outra. Com uma frequência de amostragem de 200 Hz no magnetômetro e 250 segundas capturas de imagem, nossos dados de entrada tem 51.840 pontos de dados. Entretanto, a distância máxima entre esses pontos é de 51.839 em vez de 571. Com a transição de 2D para 1D, podemos reduzir nossa entrada total de dados em 85%, ao mesmo tempo aumentando a distância máxima entre os pontos por um fator de 90. À medida

que as informações fluem do lado do codificador da UNet, um campo receptivo mais amplo se faz necessário para capturar o contexto de uma área mais ampla e gera classificações precisas para cada ponto.

O campo receptivo de um neurônio em uma RN com camadas convolucional e de agrupamento [14] é dada pela fórmula:

$$r_0 = \sum_{l=1}^L \left((k_l - 1) \prod_{i=1}^{l-1} s_i \right) + 1$$

onde k_l é o núcleo da camada l e s_i é o avanço da camada i . A UNet original continha um campo receptivo de 140x140 pixels para as primeiras 14 camadas do codificador. Ao aumentarmos o avanço da convolução inicial em cada par para 2 e o núcleo e o avanço das camadas de agrupamento máximo para 3, podemos ampliar esse campo receptivo de 140 para 10.367. Esta expansão permite que o codificador contextualize com precisão os dados do magnetômetro no âmbito da respectiva linha.

Utilizamos convoluções de transposição para reverter as compressões do agrupamento máximo e as camadas convolucionais com avanço de 2. Ao selecionarmos um comprimento para o vetor de entrada uniformemente divisível pelo avanço de todas as camadas do codificador, foi possível traçar uma rede que não exigia recortes antes de acrescentarmos as camadas do codificador no lado da rede do decodificador. Isto gerou uma ligeira otimização no desempenho do treinamento e conferiu qualidade estética ao projeto da rede.




Figura 2: Arquitetura da UNet inteiramente convolucional para segmentação 1D. As dimensões retangulares não são proporcionais ao comprimento, uma vez que o comprimento dos tensores muda por um fator de 2.600 à medida que ele se desloca através da rede. Todas as camadas convolucionais têm um núcleo de 3. No lado do codificador na rede, o avanço é de 2 ou 1 para a primeira ou a segunda em cada par, respectivamente. No lado do decodificador, o avanço é de 1 para todas as camadas convolucionais. Todas as camadas convolucionais de transposição têm um núcleo de 3; o avanço é de 2 ou 3 para a primeira ou a segunda em cada par, respectivamente. As camadas de agrupamento máximo têm um núcleo e um avanço de 3. As funções de ativação de ReLU seguem o padrão de cada camada convolucional ou convolucional de transposição.

3.2 CONJUNTO DE DADOS E AUMENTOS

Apesar de toda a atenção, a dúvida quanto ao volume de dados necessário para que uma RN efetue o treinamento ainda é uma área de pesquisas ativas [15,16]. Geralmente, as estimativas se mantêm entre 10 e 1000 vezes o número de parâmetros do modelo. No nosso caso, temos uma RN com 12,6 milhões de parâmetros e apenas $\sim 100,000$ exemplos de conexões. Essas amostras não são de fato amostras independentes para fins de treinamento, uma vez que várias conexões são necessárias por amostra para esse fim. Felizmente, temos acesso a muitos

aumentos de dados que nos permitiram gerar 3 milhões de amostras para treinamento. Além disso, mesmo com esses aumentos, essas RNs são capazes de convergir e generalizar em duas ordens de magnitude menos dados do que tipicamente seriam esperados em modelos desse porte. Conseqüentemente, prevemos melhorias significativas à medida que mais dados forem incorporados à biblioteca de treinamento.

Para gerar uma amostra com dados aumentados

- Selecione pesquisa aleatória
- Selecione subconjunto de pesquisa aleatório com amplitude de 37.500 a 70.000 pontos de dados
- Faça uma nova amostragem por interpolação linear com 50.000 pontos de dados (ampliada ou compactada em x)
- Multiplique cada componente por um valor aleatório na escala de 0,7 a 1,33 (ampliado ou compactado em y)
- Com probabilidade de 50%, inverta a amostra (espelhada em x)
- Reorganize aleatoriamente os componentes x, y, z. Como as medições são feitas com livre flutuação, a orientação do sensor é aleatória, de forma que a reorganização aleatória dos componentes é uma estratégia válida de ampliação.

3.3 FUNÇÕES DE PERDA E DADOS IRREFUTÁVEIS (*GROUND TRUTH*)

Os valores y nos dados de treinamento são representados como um conjunto discreto de pontos, embora o resultado seja uma segmentação. Para gerar um tensor *ground truth* adequado para um algoritmo de segmentação, definimos o *ground truth* como uma "conexão" em uma janela de 50 pontos de dados e "sem conexão" nos demais casos. Essa aproximação inicial atingiu um nível de precisão próximo ao humano, sem tentar ajustar os valores conforme a variabilidade da largura das conexões nos nossos dados de treinamento.

Essa rede foi treinada utilizando uma função de perda com entropia cruzada padrão, sem aplicar qualquer peso diferente aos pontos de dados. A UNet de origem concentrava-se nas bordas das células e, ponderando-se uma função de perda mais alta nesses limites, foi possível gerar previsões de localização precisas. Nessa aplicação, entretanto, é mais importante aprender as classes dos pontos de dados no centro da região das conexões em vez de identificar com

precisão a borda da segmentação pretendida. Portanto, ponderamos uniformemente a função de perda em todos os pontos de dados.

4 ABORDAGEM MULTISSENSORIAL AOS DADOS




Figura 3: Quando instaladas sobre um pig, as conexões são exibidas entre os dados de magnetômetros, giroscópios e acelerômetros. A rede aceita 12 canais de entrada (x, y, z e total para cada um dos três sensores; x: vermelho, y: verde, z: laranja e total: azul). Os quatro canais de aceleração ou do giroscópio são normalizados pelo valor máximo da aceleração total ou pelo sinal do giroscópio, respectivamente.

A combinação entre dados do acelerômetro, do giroscópio e da magnetometria quando instalados sobre um pig de limpeza é mais eficaz para a detecção de conexões do que os dados de um único sensor, uma vez que as conexões podem ser indiscerníveis para um ou mais desses sensores. Por exemplo, se o pig não se encaixar firmemente no tubo ou se a solda não cobrir a parede do tubo por completo, as conexões podem não constar nos dados de aceleração/giroscópicos. As assinatura das conexões estão presentes nos dados magnéticos cerca de 95% das vezes; é difícil saber por que, uma vez que são inúmeros fatores que influencia a assinatura da conexão na magnetometria residual. Para assegurar que esses dados sejam

corretamente incorporados à rede neural, normalizamos os dados de aceleração e os giroscópicos conforme o comprimento máximo dos vetores a cada janela de 200 segundos.

No caso das redes neurais somente com pigs, podemos alternar aleatoriamente entre os eixos x e z, mas o eixo y é fixo nos dados de campo (paralelos à direção do fluxo no tubo). Outros aumento de dados são válidos, mas devem se aplicar igualmente a todos os sensores (e nele espelhados, expandidos sobre x, etc.).

5 RESULTADOS E FUTURAS OBRAS

Empregamos uma série de redes neurais para este fim, utilizando 50.000 a 150.000 ciclos de treinamento, taxas de aprendizagem de 0,01 a 0,3 e minilotes de 20 a 50 amostras cada. Nos conjuntos de dados para validação, essas redes apresentam taxas de rendimento positivas falsas 1 a 2% e taxas negativas falsas de 3 a 5%, com o nível de desempenho humano conforme medido pela discrepância entre rotuladores manuais entre 0,1 e 2%. Apesar das redes de treinamento com 10 milhões de parâmetros em menos de 100.000 exemplos (antes dos aumentos), nossas redes estão se aproximando do nível de desempenho humano. Prevemos sem hesitação que, à medida que a nossa biblioteca de dados cresce, as redes neurais tendem a exceder o nível de desempenho humano.

6 REFERÊNCIAS

[1] M. Xie, and Z. Tian, "A review on pipeline integrity management utilizing in-line inspection data," *Engineering Failure Analysis*, vol. 92, pp. 222—239, 2018.

[2] F. Varela, M. Yongjun Tan, and M. Forsyth, "An overview of major methods for inspecting and monitoring external corrosion of on-shore transportation pipelines," *Corrosion Engineering, Science and Technology*, vol. 50, pp. 226—235, 2015.

[3] Interstate Natural Gas Association of America, "Report to the National Transportation Safety Board on Historical and Future Development of Advanced In-Line Inspection Platforms for Use in Gas Transmission Pipelines," 2012.

[4] J. Tiratsoo, "Ultimate Guide to Unpiggable Pipelines," 2013.

- [5] R. Fletcher, and M. Chandrasekaran, "SmartBall: a new approach in pipeline leak detection," *International Pipeline Conference*, vol. 48586, pp. 117—133, 2008.
- [6] J. Smith, A. Van Pol, D. Ham, and J. Van Pol, "Leak detection and prevention using free-floating in-line sensors," *Pipeline Pigging and Integrity Management*, 2019.
- [7] R. Bickerstaff, M. Vaughn, G. Stoker, M. Hassard, and M. Garrett, "Review of sensor technologies for in-line inspection of natural gas pipelines," *Sandia National Laboratories*, 2002.
- [8] X. Wu, A. Xu, Y. Xiao, B. Zhou, G. Wang, and R. Zeng, "Research on Above Ground Marker System of pipeline Internal Inspection Instrument Based on geophone array," *2010 6th International Conference On Wireless Communications Networking and Mobile Computing*, pp. 1—4, 2010.
- [9] Y. Li, D. Wang, and L. Sun, "A novel algorithm for acoustic above ground marking based on function fitting," *Measurement*, vol. 46, pp. 2341—2347, 2013.
- [10] L. Sun, Y. Li, Y. Wu, J. Guo, and Z. Li, "Establishment of theoretical model of magnetic dipole for ground marking system," *2017 29th Chinese Control And Decision Conference (CCDC)*, pp. 6134—6138, 2017.
- [11] M. Kindree, S. Campbell, A. Van Pol, and J. Van Pol, "Defect localization using free-floating unconventional ILI tools without AGMs," *Pipeline Pigging and Integrity Management*, 2022.
- [12] Z. Shand, A. Van Pol, and J. Van Pol, "Pipers; an inline screening tool for unpiggable pipelines," *Unpiggable Pipeline Solutions Forum*, 2019.
- [13] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, vol. 9351, pp. 234—241, 2015.
- [14] A. Araujo, W. Norris, and J. Sim, "Computing receptive fields of convolutional neural networks," *Distill*, vol. 4, pp. e21, 2019.

[15] A. Alwosheel, S. Van Cranenburgh, and C. G. Chorus, "Is your dataset big enough? Sample size requirements when using artificial neural networks for discrete choice analysis," *Journal of Choice Modelling*, vol. 28, pp. 167—182, 2018.

[16] T. Oyedare, and J. J. Park, "Estimating the required training dataset size for transmitter classification using deep learning," 2019 IEEE International Symposium On Dynamic Spectrum Access Networks, pp. 1—10, 2019.