

Identificación de uniones de tuberías mediante redes neuronales

Michael Byington¹, Anouk van Pol¹, John van Pol¹

¹Ingu Solutions Inc



**18ª PIPELINE
TECHNOLOGY
CONFERENCE**

8-11 DE MAYO DE 2023, BERLÍN

Organizado por



Actas de la 2023 Pipeline Technology Conference (ISSN 2510-6716).

www.pipeline-conference.com/conferences

Copyright ©2023 de EITEP Institute.

1 RESUMEN

Las herramientas de ILI convencionales utilizan ruedas cuentakilómetros para determinar la ubicación de los defectos identificados. Además, normalmente se utilizan marcadores por encima del nivel del suelo (AGM) para confirmar y posiblemente corregir el deslizamiento de las ruedas cuentakilómetros. Las herramientas de ILI no convencionales de flotación libre utilizan información procedente de diversos sensores para localizar los defectos de forma precisa. La identificación precisa de las uniones es un requisito previo para la localización y la identificación automática es clave para una inspección rentable.

Este trabajo se centra en la automatización del proceso de identificación de uniones con una red neuronal. Presentaremos estrategias de aprendizaje profundo para la identificación de características discretas y la segmentación en datos de series temporales, la forma en que estas estrategias están aumentando la eficiencia del procesamiento de datos, la precisión y las limitaciones actuales, así como las estrategias de normalización para datos de múltiples sensores.

2 INTRODUCCIÓN

El uso de herramientas de inspección en línea (ILI) es esencial para el funcionamiento seguro y eficaz de las tuberías. Sin embargo, las herramientas de ILI convencionales tienen sus limitaciones, como la necesidad de ruedas cuentakilómetros y marcadores por encima del nivel del suelo (AGM) para localizar los defectos de forma precisa. Para superar estas limitaciones, se han desarrollado herramientas de ILI no convencionales de flotación libre que utilizan información de diversos sensores para localizar los defectos de forma precisa. Para que estas herramientas sean rentables, es necesario automatizar el proceso de identificación de uniones. El presente documento analizará cómo se pueden utilizar las estrategias de aprendizaje profundo para la identificación de características discretas y la segmentación en datos de series temporales, la forma en que estas estrategias están aumentando la eficiencia del procesamiento de datos, la precisión y las limitaciones actuales, y las estrategias de normalización para datos de múltiples sensores. En concreto, nos centraremos en el uso de una red neuronal convolucional llamada UNet para este fin.

En 2016, una avería en un oleoducto de Norteamérica provocó la liberación incontrolada de 2,000 toneladas métricas de hidrocarburos (tanto líquidos como gaseosos) [1]. Desde la década de los 80, las fugas por flujo magnético (MFL) y los dispositivos de ultrasonido han sido las principales herramientas utilizadas para la gestión de la integridad de las tuberías. Sin embargo, debido a curvas cerradas, válvulas no circulares, cambios de diámetro o geometría desconocida [1,2], aproximadamente el 70% de las líneas de gas estadounidenses construidas antes de que la moderna inspección en línea (ILI) fuera una tecnología viable se consideran no inspeccionables [3]. Estudios realizados en el sector en 2012 indican que el 40% de los gasoductos de Norteamérica son no inspeccionables [4]. En respuesta a este problema, desde principios de la década de 2000 se han desarrollado tecnologías más recientes para abordar el problema de las líneas no inspeccionables [5,6].

Con independencia de la tecnología, determinar con precisión la ubicación dentro de la tubería siempre ha sido todo un reto. Las herramientas de ILI tradicionales utilizan ruedas cuentakilómetros, pero el deslizamiento sigue siendo un problema, especialmente en líneas con depósitos pesados o superficies rugosas [7]. Para minimizar las imprecisiones en la distancia, se pueden utilizar marcadores externos por encima del nivel del suelo (AGM). Los AGM están disponibles en matrices magnéticas, acústicas o geófonas [8,9,10]; sin embargo, son costosos y muchas veces no pueden utilizarse en zonas urbanas muy pobladas debido a su precisión limitada según la profundidad de la tubería. Los dispositivos multisensor de flotación libre ofrecen un método alternativo para resolver el problema de la localización, con sus propios inconvenientes y fortalezas. Las soldaduras identificadas a partir de datos magnetométricos son un componente primario de la conversión de tiempo de medición a distancia de medición [11]. Una red neuronal (NN) puede automatizar satisfactoriamente la detección de soldaduras en tuberías de acero a partir de datos magnetométricos residuales con un rendimiento cercano al nivel humano. La automatización de este obstáculo crítico mejora considerablemente la escalabilidad de los dispositivos de flotación libre multisensor.

3 SEGMENTACIÓN UNIDIMENSIONAL CON RED TIPO UNET

La morfología de las uniones, detectada por magnetometría residual, es muy variada. Algunas uniones de tuberías pueden encontrarse con una simple búsqueda de picos, mientras que otras

aparecen como sutiles aumentos de la frecuencia de oscilación. Otras son tan sutiles que sólo pueden determinarse teniendo en cuenta la separación promedio de las uniones en el área circundante. Como la identificación de uniones carece de atributos articulables precisos que puedan permitir una programación imperativa, la solución más prometedora es una red neuronal (NN). Para desarrollar un sistema automatizado de detección de uniones, éste se conceptualiza como un problema de segmentación 1D. Se aplican etiquetas a cada punto de datos (unión o no unión) y se diseña una red neuronal para clasificar cada punto. La red toma cuatro vectores magnéticos como entradas (m_x, m_y, m_z y m_t donde $m_t = (m_x^2 + m_y^2 + m_z^2)^{0.5}$) y devuelve dos valores y_1, y_2 . La función de probabilidad de unión vs. posición es determinada por un softmax $p = -\log \log \left(\frac{e^{y_2}}{e^{y_1} + e^{y_2}} \right)$. Véase la figura 1.




Figura 1 (a) Las entradas a la red neuronal no están normalizadas debido a la magnitud de los valores y a la ausencia de una referencia de normalización natural. (b) La salida en bruto de la red neuronal se muestra en unidades arbitrarias. (c) El softmax de los vectores de salida de la red neuronal de (b) proporciona una medida de certeza para cada

unión, y la búsqueda de picos produce una lista de uniones (mostrada en cian).

Desde que se publicó el artículo de referencia sobre UNet en 2015 [13], las redes neuronales totalmente convolucionales se han convertido en la norma de facto para las tareas de segmentación. Se han documentado miles de variaciones y aplicaciones de UNet desde entonces, con 54,960 citas del artículo original a fecha de 2023-01-11. Nuestra aplicación de UNet requiere varias modificaciones; en primer lugar, debido a que nuestros datos son 1D en lugar de 2D, los campos receptivos deben aumentarse para tener en cuenta la mayor distancia entre los puntos de datos. En segundo lugar, la precisión requerida para la identificación de uniones es menor que la de la segmentación de imágenes médicas, de modo que no necesitamos que las matrices de salida sean tan grandes como las de entrada. Por último, como nuestros datos son magnéticos de tuberías y no micrografías de células, los aumentos de datos apropiados para el entrenamiento no son idénticos.

3.1.1 Arquitectura y campos receptivos para datos 1D

La ampliación del campo receptivo para abarcar múltiples uniones permite a la red neuronal replicar la comprensión contextual que emplea la identificación manual de uniones. Es posible que lo que puede interpretarse como una unión en la firma magnética de una tubería sea simplemente una fluctuación normal dentro de un segmento de tubería en otra línea. En la identificación manual de uniones, buscamos patrones de firmas con distancias similares entre las mismas. Para que la red neuronal imite este proceso de forma precisa, el campo receptivo de sus neuronas más profundas debe abarcar múltiples uniones. Esta idea es esencial para adaptar UNet a la segmentación de 1D. Las imágenes de 572x572 píxeles cuadrados de la UNet original contienen 327,184 puntos de datos por imagen, ninguno de los cuales está a más de 571 pasos de distancia de otro. Con una frecuencia de muestreo del magnetómetro de 200 Hz e instantáneas de 250 segundos, nuestros datos de entrada tienen 51,840 puntos de datos; sin embargo, la distancia máxima entre estos puntos es de 51,839 en lugar de 571. Al pasar de 2D a 1D, podemos reducir la entrada total de datos en un 85% y, simultáneamente, multiplicar por 90 la distancia máxima entre puntos. Cuando la información desciende por el lado del codificador de la red UNet, se necesita un campo receptivo más amplio para captar el contexto de un área más extensa y realizar clasificaciones precisas de cada punto.

El campo receptivo de una neurona en una NN de capas convolucionales y de agrupación [14] es determinado por:

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

donde k_l es el kernel de la capa l y s_i es el stride de la capa i . El UNet original presentaba un campo receptivo de 140x140 píxeles para las 14 primeras capas del codificador. Aumentando el stride de la convolución inicial en cada par a 2 e incrementando el kernel y el stride de las capas de agrupación máxima a 3, podemos ampliar este campo receptivo de 140 a 10.367. Esta ampliación permite al codificador contextualizar los datos del magnetómetro de forma precisa dentro de su línea respectiva.

Utilizamos convoluciones de transposición para invertir las compresiones de las capas de agrupación máxima y convolucionales con stride 2. Al seleccionar una longitud de matriz de entrada divisible uniformemente por los strides de todas las capas del codificador, pudimos diseñar una red que no requería recorte antes de añadir capas del codificador en el lado del decodificador de la red. Esto supuso una ligera mejora en el rendimiento del entrenamiento y aportó una calidad estética al diseño de la red.




Figura 2: arquitectura de la red UNet totalmente convolucional para la segmentación de 1D. Las dimensiones rectangulares no son

proporcionales a la longitud porque la longitud de los tensores cambia en un factor de 2,600 al desplazarse por la red. Todas las capas convolucionales tienen un kernel de 3. En el lado del codificador de la red, el stride es 2 o 1 para el primero o el segundo de cada par, respectivamente. En el lado del decodificador, el intervalo es 1 para todas las capas convolucionales. Todas las capas convolucionales de transposición tienen un kernel de 3; el stride es 2 o 3 para la primera o la segunda de cada par, respectivamente. Las capas de agrupación máxima tienen un kernel y un stride de 3. Las funciones de activación ReLU siguen a cada capa convolucional o convolucional de transposición.

3.2 CONJUNTO DE DATOS Y AUMENTO

Aunque se le ha prestado mucha atención, la pregunta de cuántos datos necesita una NN para entrenarse sigue siendo un área de investigación activa [15,16]. Por lo general, las estimaciones oscilan entre 10 y 1,000 veces el número de parámetros del modelo. En nuestro caso, tenemos una NN con 12.6 millones de parámetros y sólo ~100,000 ejemplos de uniones. Ni siquiera se trata de muestras de entrenamiento independientes, ya que se necesitan varias uniones por muestra para el entrenamiento. Afortunadamente, tenemos acceso a muchos aumentos de datos que nos han permitido crear 3 millones de muestras de entrenamiento. Además, incluso con estos aumentos, estas NN lograron converger y generalizar con dos órdenes de magnitud de datos menos de lo que se esperaría normalmente para modelos de este tamaño. En consecuencia, prevemos mejoras importantes conforme se incorporen más datos a la biblioteca de entrenamiento.

Para generar una muestra de datos aumentada:

- Seleccione una inspección aleatoria
- Seleccione un subconjunto aleatorio de la inspección de 37.5k a 70k puntos de datos
- Realice un remuestreo por interpolación lineal a 50k puntos de datos (extienda o comprima en x)
- Multiplique cada componente por un valor aleatorio de 0.7 a 1.33 (extienda o comprima en y)
- Con un 50% de probabilidad, invierta la muestra (espejo en x)

- Reordene aleatoriamente los componentes x , y , z . Dado que las mediciones se toman en flotación libre, la orientación del sensor es aleatoria, por lo que la reordenación aleatoria de los componentes es una estrategia de aumento válida.

3.3 FUNCIONES DE PÉRDIDA Y VERDAD TERRENO

Los valores y de los datos de entrenamiento se representan como un conjunto discreto de puntos, mientras que nuestro resultado es un resultado de segmentación. Para generar un tensor de verdad terreno adecuado para un algoritmo de segmentación, definimos la verdad terreno como "unión" dentro de una ventana de 50 puntos de datos y "no unión" en el resto. Esta aproximación inicial logró una precisión casi humana sin intentar ajustar la variabilidad del ancho de las uniones en nuestros datos de entrenamiento.

Esta red se entrenó utilizando una función de pérdida de entropía cruzada estándar sin aplicar ningún peso diferente a los puntos de datos. La UNet original se centró en los bordes de las celdas, y al ponderar la función de pérdida más alta en estos límites, pudo localizar las predicciones de forma precisa. En esta aplicación, sin embargo, es más importante aprender las clases de los puntos de datos en el centro de la región de la unión que identificar con precisión los bordes de la segmentación objetivo. Por lo tanto, ponderamos uniformemente la función de pérdida en todos los puntos de datos.

4 ENFOQUE DE DATOS MULTISENSOR




Figura 3: cuando se ejecuta sobre el dorso de un pig, aparecen uniones en los datos del magnetómetro, el giroscopio y el acelerómetro. La red acepta 12 canales de entrada (x, y, z y total para cada uno de los tres sensores; x: rojo, y: verde, z: naranja y total: azul). Los cuatro canales de aceleración o giroscopio se normalizan por el máximo de la señal total de aceleración o giroscopio, respectivamente.

La combinación de datos de acelerómetro, giroscopio y magnetometría cuando se fijan al dorso de un pig de limpieza es más eficaz para detectar uniones que los datos de un solo sensor, ya que las uniones pueden ser indiscernibles en uno o más de estos sensores. Por ejemplo, si el pig no encaja perfectamente en la tubería o si las soldaduras no atraviesan completamente la pared de la tubería, las uniones pueden estar ausentes de los datos de aceleración/giroscópicos. Las firmas de las uniones están presentes en los datos magnéticos aproximadamente el 95% de las veces; es difícil determinar por qué, ya que hay numerosos factores que influyen en la firma de las uniones en la magnetometría residual. Para garantizar que estos datos se incorporen correctamente a nuestra red neuronal, normalizamos los datos giroscópicos y de aceleración por la longitud máxima del vector en cada ventana de 200 segundos.

En el caso de las redes neuronales sólo con pigs, podemos cambiar aleatoriamente los ejes x y z , pero el eje y es fijo en los datos de campo (paralelo a la dirección de desplazamiento dentro de la tubería). Otros aumentos de datos son válidos pero deben aplicarse por igual en todos los sensores (reflejados igual, extendidos en x igual, etc.).

5 RESULTADOS Y TRABAJO FUTURO

Para este fin, hemos empleado una serie de redes neuronales con 50-150,000 ciclos de entrenamiento, tasas de aprendizaje de 0.01 a 0.3 y minilotes de 20-50 muestras. En conjuntos de datos de validación, estas redes han obtenido tasas de falsos positivos del 1-2% y de falsos negativos del 3-5%, con un rendimiento de nivel humano medido por la discrepancia entre etiquetadores manuales del 0.1 al 2%. A pesar de haber entrenado redes con 10 millones de parámetros en menos de 100,000 ejemplos (antes del aumento), nuestras redes se acercan al nivel de rendimiento humano. Prevemos que, conforme aumente nuestra biblioteca de datos, las redes neuronales superarán el nivel de rendimiento humano.

6 REFERENCIAS

- [1] M. Xie y Z. Tian, "Una revisión de la gestión de la integridad de las tuberías utilizando datos de inspección en línea", *Análisis de fallos en ingeniería*, vol. 92, pp. 222—239, 2018.
- [2] F. Varela, M. Yongjun Tan y M. Forsyth, "Descripción general de los principales métodos de inspección y monitoreo de la corrosión externa de las tuberías de transporte terrestre", *Ingeniería, ciencia y tecnología de la corrosión*, vol. 50, pp. 226—235, 2015.
- [3] Interstate Natural Gas Association of America, "Informe a la Junta Nacional de Seguridad en el Transporte sobre el desarrollo histórico y futuro de plataformas avanzadas de inspección en línea para su uso en gasoductos de transporte", 2012.
- [4] J. Tiratsoo, "Guía definitiva de tuberías no inspeccionables", 2013.
- [5] R. Fletcher y M. Chandrasekaran, "SmartBall: un nuevo enfoque en la detección de fugas en tuberías", *International Pipeline Conference*, vol. 48586, pp. 117—133, 2008.

- [6] J. Smith, A. Van Pol, D. Ham y J. Van Pol, "Detección y prevención de fugas mediante sensores de flotación libre en línea", *Raspado de tuberías y gestión de integridad*, 2019.
- [7] R. Bickerstaff, M. Vaughn, G. Stoker, M. Hassard y M. Garrett, "Revisión de las tecnologías de sensores para la inspección en línea de gasoductos de gas natural", *Sandia National Laboratories*, 2002.
- [8] X. Wu, A. Xu, Y. Xiao, B. Zhou, G. Wang y R. Zeng, "Investigación sobre el sistema de marcadores por encima del nivel del suelo del instrumento de inspección interna de tuberías basado en una matriz geofónica", *6ª Conferencia internacional sobre redes de comunicaciones inalámbricas e informática móvil de 2010*, pp. 1—4, 2010.
- [9] Y. Li, D. Wang y L. Sun, "Un nuevo algoritmo de marcado acústico por encima del nivel del suelo basado en el ajuste de funciones" *Measurement*, vol. 46, pp. 2341—2347, 2013.
- [10] L. Sun, Y. Li, Y. Wu, J. Guo y Z. Li, "Establecimiento del modelo teórico del dipolo magnético para el sistema de marcado del suelo", *29ª Conferencia de control y decisión de China (CCDC) de 2017*, pp. 6134—6138, 2017.
- [11] M. Kindree, S. Campbell, A. Van Pol y J. Van Pol, "Localización de defectos mediante herramientas de ILI no convencionales de flotación libre sin AGM", *Raspado de tuberías y gestión de integridad*, 2022.
- [12] Z. Shand, A. Van Pol y J. Van Pol, "Pipers: una herramienta de detección en línea para tuberías no inspeccionables", *Foro de soluciones para tuberías no inspeccionables*, 2019.
- [13] O. Ronneberger, P. Fischer y T. Brox, "U-Net: Redes convolucionales para la segmentación de imágenes biomédicas", *Informática de Imágenes Médicas e Intervención Asistida por Computadora (MICCAI)*, vol. 9351, pp. 234—241, 2015.
- [14] A. Araujo, W. Norris y J. Sim, "Informática de campos receptivos de redes neuronales convolucionales", *Distill*, vol. 4, pp. e21, 2019.
- [15] A. Alwosheel, S. Van Cranenburgh y C. G. Chorus, "¿Su conjunto de datos es lo suficientemente grande? Requisitos del tamaño de la muestra cuando se utilizan redes

neuronales artificiales para el análisis de la elección discreta", *Journal of Choice Modelling*, vol. 28, pp. 167—182, 2018.

[16] T. Oyedare y J. J. Park, "Estimación del tamaño del conjunto de datos de entrenamiento requerido para la clasificación de transmisores utilizando aprendizaje profundo", *Simposio internacional 2019 del IEEE sobre redes de acceso al espectro dinámico*, pp. 1—10, 2019.