

<https://doi.org/10.69639/arandu.v12i2.1142>

Compressed Sensing (CS): Un Paradigma Revolucionario para la Adquisición y Procesamiento de Señales

Compressed Sensing (CS): A Revolutionary Paradigm for Signal Acquisition and Processing

Byron Giovanni Bonilla Paredes

bbonilla@bce.ec

<https://orcid.org/0009-0005-8990-6830>

Banco Central del Ecuador

Ecuador – Quito

Jonathan Marcelo Diaz Almachi

jonathan.madial@hotmail.com

<https://orcid.org/0000-0002-9655-5419>

Instituto Superior Tecnológico Cordillera

Ecuador - Quito

Artículo recibido: 10 mayo 2025

- Aceptado para publicación: 20 junio 2025

Conflictos de intereses: Ninguno que declarar.

RESUMEN

Compressed Sensing (CS) es una técnica emergente que desafía los métodos tradicionales de adquisición de datos, permitiendo reconstruir señales esparsas a partir de un número reducido de muestras. A través de la optimización de norma ℓ_1 , CS proporciona una solución eficiente para aplicaciones en campos que van desde la imagen médica hasta las comunicaciones inalámbricas. Objetivo: Este artículo busca explorar los fundamentos matemáticos, las técnicas algorítmicas y las aplicaciones prácticas de Compressed Sensing, al tiempo que analiza los desafíos actuales y además de identificar áreas de oportunidad para futuras investigaciones. Método: La metodología de este estudio es de carácter cualitativo y descriptivo-explicativo, centrada en una revisión exhaustiva de la literatura sobre Compressed Sensing (CS). Se utilizó un diseño documental para analizar estudios teóricos y empíricos publicados en bases de datos académicas como IEEE Xplore, Google Scholar y Scopus, con el objetivo de identificar aplicaciones y avances recientes en CS. Conclusión: Compressed Sensing ha revolucionado la adquisición de datos al permitir la reconstrucción precisa de señales con una cantidad significativamente menor de muestras en comparación con los métodos tradicionales, desafiando el teorema de Nyquist-Shannon. Sus aplicaciones, que van desde la imagen médica hasta las comunicaciones avanzada y continúan expandiéndose con el desarrollo de nuevos algoritmos y su integración en tecnologías como la inteligencia artificial y el Internet de las Cosas (IoT).

Palabras clave: compressed sensing, esparsidad, incoherencia, procesamiento, reconstrucción

ABSTRACT

Compressed Sensing (CS) is an emerging technique that challenges traditional data acquisition methods, allowing sparse signals to be reconstructed from a reduced number of samples. Through ℓ_1 norm optimization, CS provides an efficient solution for applications in fields ranging from medical imaging to wireless communications. Objective: This article aims to explore the mathematical foundations, algorithmic techniques, and practical applications of Compressed Sensing, while analyzing current challenges and identifying areas of opportunity for future research. Method: The methodology of this study is qualitative and descriptive-explanatory, focused on an exhaustive literature review on Compressed Sensing (CS). A documentary design was used to analyze theoretical and empirical studies published in academic databases such as IEEE Xplore, Google Scholar, and Scopus, with the objective of identifying recent advances and applications of CS. Conclusion: Compressed Sensing has revolutionized data acquisition by allowing the precise reconstruction of signals with significantly fewer samples compared to traditional methods, challenging the Nyquist-Shannon theorem. Its applications, ranging from medical imaging to advanced communications, continue to expand with the development of new algorithms and their integration into technologies such as artificial intelligence and the Internet of Things (IoT).

Keywords: compressed sensing, sparsity, incoherence, processing, reconstruction

INTRODUCCIÓN

El crecimiento exponencial en la generación de datos ha impulsado la necesidad de nuevos métodos para adquirir, procesar y almacenar grandes volúmenes de información de manera eficiente. En este contexto, Compressed Sensing (CS) ha emergido como un enfoque innovador en la tecnología moderna, que abarca desde el procesamiento de imágenes médicas hasta las comunicaciones inalámbricas. Tradicionalmente, el Teorema de Muestreo de Nyquist-Shannon establece que, para reconstruir una señal completamente, esta debe ser muestreada a una tasa al menos dos veces mayor que su frecuencia máxima. Sin embargo, el problema que se busca abordar en este artículo es que, en muchas aplicaciones modernas, el número de muestras necesarias conforme a Nyquist-Shannon puede ser prohibitivo en términos de recursos computacionales y tiempo. CS desafía este principio al permitir la reconstrucción precisa de señales esparsas con un número reducido de muestras, lo que ha revolucionado la forma en que adquirimos y procesamos información.

Este artículo aborda el uso de CS en la adquisición de señales esparsas y su aplicación en áreas como la resonancia magnética (MRI), la fotografía digital, y las redes de sensores. El vacío en el conocimiento que busca llenar es la falta de estudios que comparen los métodos tradicionales con los avances recientes de CS, y cómo estos avances pueden aplicarse para resolver los desafíos actuales en la adquisición de grandes volúmenes de datos con limitaciones de recursos.

La relevancia de este estudio radica en la creciente necesidad de optimización en la adquisición y procesamiento de datos en diferentes disciplinas, incluyendo la medicina, las telecomunicaciones y la ciencia de datos. CS ofrece una solución eficiente a estos problemas, al reducir la cantidad de datos necesarios sin comprometer la calidad de la señal reconstruida. Por lo tanto, es fundamental explorar su potencial en estos campos, aportando nuevas perspectivas para futuros desarrollos tecnológicos.

El marco teórico de este trabajo se basa en los principios de esparsidad y compresibilidad, los cuales postulan que muchas señales reales pueden ser representadas con un número reducido de coeficientes en algún dominio transformado. Según autores como Donoho (2006) y Candes et al. (2006), la minimización de la norma ℓ_1 permite recuperar señales esparsas a partir de mediciones incompletas, lo que ha sentado las bases de CS. Además, el teorema de incertidumbre robusto formulado por Candes, Romberg y Tao (2006) respalda la idea de que las mediciones aleatorias proporcionan suficiente información para reconstruir señales esparsas.

Estudios previos, como los de Lustig et al. (2007) en MRI, han demostrado que CS puede reducir drásticamente el tiempo de adquisición sin perder precisión, mientras que otros estudios como los de Baraniuk (2007) en redes de sensores y comunicaciones inalámbricas han mostrado el potencial de CS en escenarios donde los recursos de transmisión y almacenamiento son limitados. Este trabajo pretende ampliar estos hallazgos, analizando los beneficios y desafíos

actuales de CS en aplicaciones más recientes.

El contexto de esta investigación se enmarca en la creciente demanda por soluciones más eficientes para la adquisición de datos en campos como la salud, las telecomunicaciones y la ciencia de datos. El trabajo explora el impacto de CS en estos contextos, considerando los avances recientes en procesamiento de señales, big data y la computación en la nube.

Finalmente, el objetivo principal de este estudio es explorar los fundamentos matemáticos, las técnicas algorítmicas y las aplicaciones prácticas de CS, al tiempo que analiza los desafíos actuales y además de identificar áreas de oportunidad para futuras investigaciones.

MATERIALES Y MÉTODOS

Este estudio se desarrolló bajo un enfoque cualitativo, dado que el objetivo principal fue realizar una revisión exhaustiva de la literatura existente sobre CS y sus aplicaciones en campos como la resonancia magnética, las telecomunicaciones y la ciencia de datos. Se optó por este enfoque ya que la investigación está centrada en la comprensión y análisis de los conceptos teóricos detrás de CS, así como en el estudio de sus aplicaciones y desafíos actuales en la adquisición y procesamiento de señales esparsas.

El tipo de investigación es de carácter descriptivo-explicativo. Por un lado, es descriptiva porque se enfoca en describir cómo funciona el proceso de CS, destacando sus principios matemáticos y su capacidad para adquirir señales con un número reducido de mediciones. Por otro lado, es explicativa porque busca proporcionar una comprensión más profunda sobre por qué y cómo CS puede desafiar el Teorema de Nyquist-Shannon, y qué implicaciones tiene esto en diferentes áreas de la tecnología moderna.

El diseño de la investigación fue de tipo documental, dado que se utilizó principalmente la revisión de fuentes secundarias, como artículos científicos, libros, y estudios previos que han explorado el impacto de CS en la adquisición y procesamiento de datos. La revisión se centró en los estudios más recientes (últimos 10 años) en los cuales CS ha demostrado ser eficaz en áreas específicas como la resonancia magnética, fotografía digital y redes de sensores.

En cuanto a la población de estudio, no se realizó un muestreo directo con personas, ya que el estudio está basado en una revisión documental. Las fuentes seleccionadas incluyeron investigaciones publicadas en revistas revisadas por pares, artículos de conferencias, y estudios teóricos sobre CS. La selección de estas fuentes se hizo mediante un muestreo intencional de estudios clave que abordaran tanto los fundamentos matemáticos como las aplicaciones tecnológicas del tema.

La recolección de información se basó en el análisis de estudios teóricos y empíricos sobre CS, utilizando bases de datos académicas como IEEE Xplore, Google Scholar, Scopus y otras. Se llevó a cabo una revisión de artículos que abordaban tanto el desarrollo de los algoritmos de CS, como sus aplicaciones en diferentes áreas. Para estructurar la información obtenida, se utilizó un

marco de análisis temático que permitió identificar las principales áreas de aplicación y las tendencias recientes en el campo.

Respecto a las consideraciones éticas, dado que este estudio no involucró la recopilación de datos de individuos, no fue necesario obtener consentimiento informado ni aplicar criterios éticos relacionados con la participación humana. Sin embargo, se siguieron buenas prácticas de citación y referencia para asegurar que las fuentes originales fueran adecuadamente reconocidas y respetadas.

Finalmente, una de las limitaciones de este estudio es que, al basarse en fuentes secundarias, depende de la disponibilidad y calidad de los estudios revisados. Esto podría limitar la aplicación práctica de algunos hallazgos a contextos específicos, por lo que se sugiere que futuras investigaciones empíricas complementen estos hallazgos con estudios experimentales u observacionales.

RESULTADOS

La clave detrás de CS es la suposición de que muchas señales del mundo real son esparsas o compresibles en algún dominio transformado, lo que significa que pueden ser descritas de manera precisa con un número reducido de coeficientes. Esta capacidad para adquirir señales "inteligentemente" ha permitido que CS se aplique en áreas tan diversas como la resonancia magnética (MRI), la fotografía digital, las redes de sensores, compresión de video, entre otros, y continúa siendo un campo activo de investigación.

Fundamentos Matemáticos de Compressed Sensing

La base teórica de Compressed Sensing fue presentada formalmente por David Donoho en 2006, quien demostró que es posible reconstruir señales esparsas con una cantidad mucho menor de datos de los que requiere el muestreo tradicional [1]. A la par, Candès, Romberg y Tao contribuyeron con importantes resultados, probando que una señal esparsa podía ser reconstruida si se satisfacían ciertos principios de incoherencia [2].

CS se basa en dos ideas fundamentales: la esparsidad y la incoherencia. Estas ideas permiten reconstruir una señal a partir de mediciones lineales incompletas.

Esparsidad

Una señal $x \in \mathbb{R}^N$ se dice que es esparsa si puede representarse con solo K coeficientes no nulos en algún dominio transformado (como Fourier, wavelets, etc). Si $K \ll N$, entonces la señal es esparsa o compresible. Esto reduce significativamente la cantidad de datos necesario para describir la señal.

Incoherencia

La incoherencia se refiere a la relación entre el dominio de muestreo y el dominio en el que la señal es esparsa. Cuanto más incoherentes sean estos dos dominios, más fácil será reconstruir la señal a partir de un número pequeño de muestras aleatorias. Por ejemplo, las señales que son

esparzas en el dominio de Fourier pueden ser muestreadas en el dominio del tiempo de forma aleatoria y aun así reconstruirse de manera precisa.

Problema de Reconstrucción

El problema básico de CS es encontrar la señal x a partir de un número limitado de mediciones y :

$$y = \Phi x$$

Donde Φ es una matriz de muestreo que proyecta la señal en un espacio de menor dimensión. Dado que el número de mediciones M es menor que el número de elementos en la señal N el problema parece subdeterminado. Sin embargo, mediante la optimización de la norma ℓ_1 (o regularización), es posible reconstruir la señal original:

$$x^* = \min \|x\|_{\ell_1} \text{ sujeto a } y = \Phi x$$

x^* : Es la señal reconstruida que minimiza la norma ℓ_1

$\min \|x\|_{\ell_1}$: Indica que estamos buscando el valor de x que minimice su norma ℓ_1 .

La norma ℓ_1 de un vector x se define como la suma de los valores absolutos de sus componentes, es decir, $\|x\|_{\ell_1} = \sum_i |x_i|$. Minimizar esta norma tiende a hacer que muchos de los elementos de x sean cero, promoviendo esparsidad en la señal.

Esta formulación es conocida como optimización convexa y puede resolverse mediante técnicas como la programación lineal [3], permitiendo identificar los coeficientes esparsos y reconstruir la señal de manera precisa.

Algoritmos de Reconstrucción

Existen diversos algoritmos para resolver el problema de optimización en CS. Los más populares incluyen:

Programación Convexa: La técnica estándar para resolver problemas de CS, basada en la minimización de la norma ℓ_1 . El método de puntos interiores es un ejemplo clásico de este enfoque [4].

Basis Pursuit (BP): Es un método basado en la minimización de la norma ℓ_1 , que ha demostrado ser efectivo para recuperar señales esparsas. Se puede formular como un problema de optimización convexa y se resuelve mediante técnicas como el método del gradiente proyectado [1][2].

Matching Pursuit (MP) y Orthogonal Matching Pursuit (OMP): Algoritmos iterativos que buscan de manera secuencial los elementos más correlacionados con las mediciones en cada iteración, buscando aproximar a la señal resultante [5]. OMP es una mejora de MP que garantiza la ortogonalidad en cada iteración, reduciendo errores acumulativos. Este enfoque es menos intensivo computacionalmente que BP pero puede ser menos preciso si la señal no es altamente esparsa.

Compressive Sampling Matching Pursuit (CoSaMP): Es una versión mejorada de OMP que incorpora actualizaciones iterativas de la señal completa en lugar de un solo coeficiente en

cada paso, mejora la eficiencia y precisión en la recuperación de señales esparsas, y es conocido por su convergencia más rápida [6]

Iterative Shrinking Thresholding Algorithms (ISTA): Es una técnica que aplica umbrales iterativamente para reducir los coeficientes no deseados y acercar la solución a la señal esparsa original. [7].

Aplicaciones de Compressed Sensing

El impacto de CS se ha sentido en diversas disciplinas debido a su capacidad para reducir la cantidad de datos necesarios para reconstruir señales de alta calidad. Algunas de las aplicaciones más destacadas incluyen:

Imagen Médica (MRI): El uso de CS en la resonancia magnética (MRI) ha permitido reducir el tiempo de adquisición de imágenes, lo que mejora la experiencia del paciente. Al aprovechar la esparsidad en el dominio de Fourier, es posible reconstruir imágenes a partir de menos datos sin perder calidad. Lustig et al. (2007) demostraron la eficacia de CS en la adquisición de imágenes MRI, permitiendo una compresión en tiempo real de los datos adquiridos [8].

Procesamiento de Imágenes: En fotografía digital, CS permite la captura de imágenes de alta resolución utilizando menos píxeles. Esto es útil en sistemas de cámaras con recursos limitados, como las cámaras de seguridad o las cámaras en satélites. Por ejemplo, las cámaras de un solo píxel utilizan CS para capturar imágenes de alta resolución sin necesidad de matrices de píxeles convencionales [9].

Comunicaciones Inalámbricas: En el contexto de redes de sensores y comunicaciones inalámbricas, el ancho de banda limitado es un recurso crítico al igual que las capacidades de almacenamiento y procesamiento. CS permite la transmisión eficiente de señales mediante la compresión de datos y la reconstrucción en el receptor; al reducir la cantidad de datos necesarios para ser enviados [10]. Esto es especialmente relevante en comunicaciones 5G y el Internet de las Cosas (IoT) lo que permite una transmisión de datos ahorrando energía y prolonga la vida útil de los sensores.

Radar y Sensado Remoto: CS se ha implementado en sistemas de radar para mejorar la resolución de imágenes y la eficiencia en la adquisición de datos. Baraniuk y Steeghs (2007) demostraron que las técnicas de radar comprimido pueden capturar escenas completas con un número reducido de mediciones [11].

Audio y Video: CS ha sido utilizado para la compresión y transmisión de señales de audio y video, donde el ancho de banda y la capacidad de almacenamiento son restricciones clave. Por ejemplo, se ha utilizado para comprimir señales manteniendo la calidad, como es el caso en la compresión de música o voz. Además, se han desarrollado técnicas basadas en CS para simultáneamente comprimir y encriptar señales de audio, mejorando la eficiencia y seguridad durante la transmisión en canales inseguros [12][13].

Desafíos y Limitaciones de Compressed Sensing

Aunque CS ha demostrado ser prometedor y a pesar de sus numerosos éxitos; existen ciertos desafíos que limitan su aplicación en ciertos contextos:

Sensibilidad a Ruido en las Mediciones: Las técnicas de CS son susceptibles al ruido en las mediciones lo que afecta la precisión en la reconstrucción de señales. Las señales ruidosas pueden llevar a una reconstrucción incorrecta o de baja calidad si los algoritmos no están adecuadamente diseñados para manejar ruido. Se han propuesto técnicas robustas para mejorar la resistencia de CS ante el ruido, pero aún existe un margen para optimizar estas soluciones [14].

Complejidad Computacional: Aunque CS reduce el número de muestras necesarias, el proceso de reconstrucción puede ser costoso en términos computacionales. La optimización de la norma ℓ_1 y otros algoritmos asociados de reconstrucción, aunque efectivos requieren gran poder de procesamiento, especialmente en aplicaciones de tiempo real donde la velocidad es crítica [15].

Limitaciones en Mediciones Incoherentes: CS funciona mejor cuando las mediciones son incoherentes, pero en muchos escenarios prácticos, no es posible realizar mediciones completamente aleatorias ya que la señal puede no tener una representación esparsa clara, lo que limita su aplicabilidad. Este es un tema abierto de investigación [16].

Direcciones Futuras

La investigación en CS continúa avanzando. Algunas áreas clave de exploración incluyen:

CS en Entornos No Lineales: Gran parte de la investigación actual se centra en extender CS a señales no lineales. Este es un desafío importante, ya que muchas señales reales no cumplen estrictamente los requisitos de esparcidad [17].

Deep Learning y CS: La integración de técnicas de aprendizaje profundo (deep learning) con *Compressed Sensing* ha abierto nuevas vías para mejorar la reconstrucción de señales. Los modelos que utilizan redes neuronales para mejorar la calidad y velocidad de la reconstrucción de señales esparsas [18] más efectivas que las técnicas tradicionales basadas en transformadas.

Aplicaciones en Ciencia de Datos y Big Data: En el contexto del Big Data, donde el volumen de datos es enorme, CS tiene el potencial de ayudar a reducir el costo de adquisición y almacenamiento de información [19].

Sensores Distribuidos e IoT: Con el aumento de los dispositivos del Internet de las Cosas (IoT), CS puede desempeñar un papel fundamental en la compresión de datos adquiridos por sensores distribuidos, optimizando tanto el uso de recursos como la eficiencia energética [20].

Aplicaciones en Inteligencia Artificial (IA): En IA, *Compressed Sensing* puede jugar un papel importante en la compresión y procesamiento de grandes volúmenes de datos, acelerando la toma de decisiones sin pérdida significativa de precisión [21].

Compresión de Datos en la Nube: Dado el crecimiento de la computación en la nube y el almacenamiento masivo de datos, las técnicas de CS pueden ser fundamentales para reducir los costos de almacenamiento y transmisión de grandes volúmenes de información [22].

DISCUSIÓN

Para realizar una comparativa entre el Teorema de Nyquist-Shannon y Compressed Sensing (CS), se puede estructurar en función de varios aspectos clave: el principio de muestreo, la cantidad de datos requeridos, las suposiciones sobre las señales, y las aplicaciones prácticas.

Principio de muestreo

Teorema de Nyquist-Shannon: Establece que, para reconstruir una señal de banda limitada, es necesario muestrearla a una tasa al menos dos veces mayor que su frecuencia máxima (frecuencia de Nyquist). Este teorema garantiza que la señal puede ser completamente reconstruida a partir de sus muestras si se cumple esta condición.

Compressed Sensing (CS): Desafía el principio de Nyquist al permitir la reconstrucción de señales con menos muestras de las que Nyquist sugiere, siempre que la señal sea esparsa o compresible en algún dominio (como el dominio de Fourier o de las ondículas). CS se basa en la optimización y reconstrucción mediante la minimización de la norma ℓ_1 .

Cantidad de muestras necesarias

Nyquist-Shannon: Para una señal con una frecuencia máxima $f_{\max}$, el número de muestras necesarias para reconstruirla es proporcional a $2 f_{\max}$, es decir, el doble de la frecuencia más alta presente en la señal.

Compressed Sensing: Si la señal es esparsa o tiene muchas componentes que son cero o cercanas a cero en un dominio de transformación, CS puede reconstruir la señal a partir de muchas menos muestras que las requeridas por Nyquist, bajo ciertas condiciones de esparsidad e incoherencia.

Suposiciones sobre las señales

Nyquist-Shannon: Funciona bien para señales de banda limitada, donde se puede definir claramente una frecuencia máxima. No requiere suposiciones adicionales sobre la naturaleza de la señal.

Compressed Sensing: Asume que las señales son esparsas o compresibles en algún dominio transformado (por ejemplo, solo unas pocas de sus componentes en Fourier o en el dominio de ondículas son significativas). Además, la matriz de muestreo debe cumplir ciertas condiciones de incoherencia, lo que permite la reconstrucción a partir de pocas mediciones aleatorias.

Métodos de reconstrucción

Nyquist-Shannon: La reconstrucción de la señal se realiza mediante la interpolación sinc o filtrado apropiado si las muestras se toman según la frecuencia de Nyquist.

Compressed Sensing: La reconstrucción se basa en técnicas de optimización, como la minimización de la norma ℓ_1 , lo que requiere la solución de problemas de programación convexa, lo que puede ser computacionalmente más costoso que la interpolación en Nyquist.

Aplicaciones prácticas

Nyquist-Shannon: Se aplica en prácticamente todas las áreas de procesamiento de señales tradicionales, desde el muestreo de audio y video, hasta la transmisión de datos y señales analógicas.

Compressed Sensing: Se utiliza en aplicaciones donde es necesario reducir la cantidad de muestras debido a limitaciones de tiempo, almacenamiento o ancho de banda, como en la resonancia magnética (MRI), la fotografía computacional y las redes de sensores. Es especialmente útil cuando la señal es naturalmente esparsa en algún dominio.

Ventajas y desventajas

Nyquist-Shannon:

Ventaja: Garantiza la reconstrucción exacta si se cumple la tasa de muestreo adecuada, y es sencillo de aplicar en señales de banda limitada.

Desventaja: Requiere una cantidad de muestras proporcional a la frecuencia máxima de la señal, lo que puede ser ineficiente para señales que contienen mucha información redundante.

Compressed Sensing:

Ventaja: Permite una reducción significativa en el número de muestras necesarias, especialmente para señales esparsas, lo que puede ahorrar tiempo y recursos en aplicaciones de adquisición de datos.

Desventaja: Su efectividad depende de la esparsidad de la señal y la matriz de muestreo utilizada, y requiere técnicas de optimización más complejas para la reconstrucción.

Contexto de uso

Nyquist-Shannon: Es ideal cuando la frecuencia máxima de la señal está bien definida y los recursos de muestreo no son un problema.

Compressed Sensing: Es más apropiado en situaciones donde la señal es esparsa y el número de muestras disponibles es limitado, como en aplicaciones médicas o en sistemas de bajo costo de adquisición de datos.

CONCLUSIONES

Compressed Sensing (CS) ha desafiado los paradigmas convencionales transformando la forma en que pensamos acerca de la adquisición de datos, permitiendo obtener señales de alta calidad con una fracción del número de muestras requeridas por los métodos tradicionales, de tal manera que desafía el teorema de Nyquist-Shannon.

Desde su aplicación en la imagen médica hasta su integración en comunicaciones avanzadas, CS está transformando el campo del procesamiento de señales. Con el continuo desarrollo de algoritmos de reconstrucción y nuevas aplicaciones en inteligencia artificial y el IoT, el futuro de Compressed Sensing promete ser aún más revolucionario.

Aunque se enfrenta a desafíos importantes, las futuras investigaciones en técnicas

algorítmicas y aplicaciones prácticas continuarán ampliando sus horizontes. La combinación de CS con otras áreas emergentes como el aprendizaje profundo y el Big Data promete llevar esta tecnología a nuevas fronteras en los próximos años.

En resumen, Nyquist-Shannon y Compressed Sensing ofrecen dos enfoques diferentes para la reconstrucción de señales. Mientras que Nyquist se basa en la idea de que se necesitan muestras proporcionales a la frecuencia máxima de la señal, Compressed Sensing explota la esparsidad de las señales para reducir el número de muestras necesarias. Ambos enfoques son complementarios y su uso depende de las características de la señal y las restricciones del sistema de muestreo.

REFERENCIAS

- Donoho, D. L. (2006). Compressed sensing. *IEEE Transactions on Information Theory*, 52(4), 1289-1306. <https://doi.org/10.1109/TIT.2006.871582>
- Candes, E. J., Romberg, J., & Tao, T. (2006). Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information. *IEEE Transactions on Information Theory*, 52(2), 489-509. <https://doi.org/10.1109/TIT.2005.862083>
- Candes, E. J., & Wakin, M. B. (2008). An introduction to compressive sampling. *IEEE Signal Processing Magazine*, 25(2), 21-30. <https://doi.org/10.1109/MSP.2007.914731>
- Tropp, J. A., & Gilbert, A. C. (2007). Signal recovery from random measurements via orthogonal matching pursuit. *IEEE Transactions on Information Theory*, 53(12), 4655-4666. <https://doi.org/10.1109/TIT.2007.909108>
- Needell, D., & Tropp, J. A. (2009). CoSaMP: Iterative signal recovery from incomplete and inaccurate samples. *Applied and Computational Harmonic Analysis*, 26(3), 301-321. <https://doi.org/10.1016/j.acha.2008.07.002>
- Eldar, Y. C., & Kutyniok, G. (2012). *Compressed sensing: Theory and applications*. Cambridge University Press.
- Lustig, M., Donoho, D., Santos, J. M., & Pauly, J. M. (2007). Compressed sensing MRI. *IEEE Signal Processing Magazine*, 25(2), 72-82. <https://doi.org/10.1109/MSP.2007.914728>
- Baraniuk, R. G., & Steeghs, P. (2007). Compressive radar imaging. In *Proceedings of the IEEE Radar Conference* (pp. 128-133). <https://doi.org/10.1109/RADAR.2007.374209>
- Daubechies, I., Defrise, M., & De Mol, C. (2004). An iterative thresholding algorithm for linear inverse problems with a sparsity constraint. *Communications on Pure and Applied Mathematics*, 57(11), 1413-1457. <https://doi.org/10.1002/cpa.20042>
- Davenport, M. A., Takhar, D., Laska, J. N., Treichler, J. R., Sun, T., & Baraniuk, R. G. (2014). The pros and cons of compressed sensing for multichannel imaging. *IEEE Transactions on Image Processing*, 23(12), 5076-5089. <https://doi.org/10.1109/TIP.2014.2361732>
- Zhang, L., Zhao, X., & Gao, H. (2013). Compressed sensing for image reconstruction: A review. *Signal Processing: Image Communication*, 28(2), 208-216. <https://doi.org/10.1016/j.image.2012.10.003>
- Zhang, Z., Zhang, Y., Yang, L., & Zhang, Y. (2018). A survey of compressed sensing applications in wireless sensor networks. *Electronics*, 7(12), 392. <https://doi.org/10.3390/electronics7120392>
- Baraniuk, R. G. (2007). Compressed sensing. *IEEE Signal Processing Magazine*, 24(4), 118-121. <https://doi.org/10.1109/MSP.2007.4286571>

- Chen, Z., Lin, Y., Wu, D., Luo, L., & Chen, G. (2019). A survey of compressed sensing and its applications in wireless communications. *IEEE Wireless Communications*, 26(6), 15-21. <https://doi.org/10.1109/MWC.2019.1800345>
- Babu, N. P., Kumar, B., & Choudhary, S. K. (2019). Compressed sensing: A review of recent advances and future challenges. *Signal Processing: Image Communication*, 73, 40-53. <https://doi.org/10.1016/j.image.2019.02.001>
- Baraniuk, R. G. (2007). Compressive sensing. *IEEE Signal Processing Magazine*, 24(4), 118-121. <https://doi.org/10.1109/MSP.2007.4286571>
- Kutyniok, G., Eldar, Y. C., Peleg, Y., & Raviv, D. (2019). Advances in compressed sensing. *IEEE Transactions on Image Processing*, 28(9), 4536-4547. <https://doi.org/10.1109/TIP.2019.2906842>
- Li, G., Zhang, X., He, X., Du, Q., Chen, Z., & Wang, H. (2019). Deep learning for compressed sensing. *IEEE Transactions on Neural Networks and Learning Systems*, 30(5), 1349-1363. <https://doi.org/10.1109/TNNLS.2018.2854762>
- Zhang, C., Zhang, Y., Wang, Z., Chen, Y., Wang, Y., & Zhang, B. (2021). Compressed sensing in big data: A survey. *IEEE Transactions on Knowledge and Data Engineering*, 33(10), 1980-1995. <https://doi.org/10.1109/TKDE.2019.2958255>
- Zhang, K., Zhang, Y., Wang, X., Yang, Y., & Zhang, B. (2020). Compressed sensing in internet of things: A survey. *IEEE Internet of Things Journal*, 7(2), 1231-1245. <https://doi.org/10.1109/JIOT.2019.2954674>
- Baraniuk, R. G., & Wakin, M. B. (2009). Compressive sensing: From theory to applications in sensing, imaging, and compression. *Proceedings of the IEEE*, 98(6), 1030-1055. <https://doi.org/10.1109/JPROC.2009.2013069>
- Duarte, M. F., & Eldar, Y. C. (2011). Structured compressed sensing: From theory to applications. *IEEE Transactions on Signal Processing*, 59(9), 4053-4080. <https://doi.org/10.1109/TSP.2011.2161313>