

Nanotubos de carbono: aspectos generales y sus aplicaciones actuales

Carbon nanotubes: general aspects and their current applications

Alma Rosa Torres-Rodríguez¹, Aidé Sáenz-Galindo^{1*}, Rosa Idalia Narro-Céspedes¹, Adalí
Oliva Castañeda-Facio¹, Christian Javier Cabello-Alvarado²

¹ Facultad de Ciencias Químicas, Departamento de Polímeros, Universidad Autónoma de
Coahuila, Blvd. Venustiano Carranza y José Cárdenas Valdés, Código Postal 25280,
Saltillo, Coahuila, México.

² CONAHCYT-Consortio de Investigación Científica, Enrique Reyna H. 140, San José de
los Cerritos, 25294 Saltillo, Coahuila, México.

*Autor de correspondencia: aidesaenz@uadec.edu.mx

Resumen

En este trabajo de revisión se describe brevemente los aspectos generales más importantes de los nanotubos de carbono (NTC), así como sus tipos, estructuras, propiedades eléctricas, térmicas, mecánicas, ópticas y químicas, métodos de síntesis, funcionalización y algunas de las aplicaciones actuales en las que estos se han visto involucrados en estos últimos años en el área de la ciencia y nanotecnología. Sin embargo, se espera que estos puedan ser utilizados en el futuro como parte de la vida cotidiana en su incorporación en materiales compuestos para la fabricación de dispositivos eléctricos y de almacenamiento, en el área de la salud en biosensores, así como marcadores de algunas enfermedades, o sustituyendo a algunos otros materiales en la industria.

Palabras clave: Nanotubos de carbono, estructura, propiedades, síntesis, funcionalización.

Abstract

This review paper describes the most important general aspects of carbon nanotubes (CNT), as well as their types, properties (mechanical, electrical, conductive, etc.), synthesis methods, functionalization and some applications in that these have been involved in recent years in the area of science and nanotechnology. However, it is expecting that these can be used in the future as part of daily life in their incorporation into composite materials for the electronics manufacturing and storage, in the health area in biosensors, as well as markers of some diseases, or change some materials in the industry.

Keywords: Carbon nanotubes, structures, properties, synthesis, functionalization.

Introducción

En los últimos años los nanomateriales a base de grafeno han presentado una amplia variedad de aplicaciones. Dentro de los cuales encontramos a los nanotubos de carbono (NTC), los cuales fueron descubiertos por primera vez por Sumio Iijima en 1991 (Raval y col., 2018). Los NTC son ligeros, insolubles y pueden llegar a formar suspensiones coloides en el medio ambiente (Pandey y Chusuei, 2021). Son una forma alotrópica del carbón, los cuales son

cilindros concéntricos debido al enrollamiento del grafeno. Además, de acuerdo al número de capas que los conforman existen diferentes tipos. Si los NTC están constituidos por una sola capa concéntrica se les conoce como nanotubos de carbono de pared simple (NTCPS), si tienen dos capas como nanotubos de carbono de pared doble (NTCPD) y si están formados por más de dos capas se les denomina como nanotubos de carbono de pared múltiple (NTCPM) (Pandey y Chusuei, 2021; Wang y col., 2009; Wei y col., 2021). Gracias a la estructura que poseen, presentan excelentes propiedades mecánicas, térmicas y eléctricas. Se ha llegado a reportar que poseen una alta resistencia a la tracción de 100 GPa, su conductividad térmica puede alcanzar los $6000 \text{ Wm}^{-1}\text{K}^{-1}$ y su conductividad eléctrica $2 \times 10^7 \text{ Sm}^{-1}$ (Wang y col., 2022).

Sintetizar los NTC es un proceso costoso y difícil, ya que se requieren presión y temperaturas altas (alrededor de 500°C). Sin embargo, hoy en día se han reportado procesos a bajas temperaturas y menos costosos en los cuales no se aplica presión (Thauer y col., 2020). Se ha descubierto que al funcionalizarlos químicamente introduciendo grupos funcionales, como lo son carboxilo y amino aumentan sus aplicaciones, ya que permiten aumentar su solubilidad y se genera el enlace adicional para poder unirlos con otros compuestos, aumentando así sus aplicaciones.

En el presente artículo de revisión se describen aspectos generales de los NTC, tipos, propiedades, métodos de síntesis y funcionalización, así como aplicaciones que se les han dado actualmente en diferentes áreas.

Tipos de NTC

Desde su descubrimiento en 1991 por Sumio Iijima, los NTC han presentado características importantes que los han destacado de otros materiales. Existen tres tipos, nanotubos de carbono de pared simple (NTCPS), de pared doble (NTCPD) y multicapa (NTCPM). Debido a su estructura y propiedades particulares han sido utilizados en un sinnúmero de aplicaciones desde el área médica y biomédica hasta en aplicaciones en la industria automotriz.

a. Nanotubos de carbono de pared simple (NTCPS).

Los NTCPS están formados por una sola capa o lámina de grafeno envuelta. Tienen un diámetro que oscila entre 0,4 y 2 nm y generalmente se presentan empaquetados hexagonalmente, además de ser estructuras unidimensionales. Estos poseen capacidades eléctricas distintas a los NTCPM por lo que han sido empleados para sistemas microelectromecánicos. Son excelentes conductores, sin embargo, una gran desventaja que presentan es que son muy caros de sintetizar y no existen actualmente técnicas que sean menos costosas para poder producirlos de manera comercial dentro de la industria (Raval y col., 2018; Anzar y col. 2020).




Fig.1 Estructura de los nanotubos de carbono de pared simple (NTCPS).

b. Nanotubos de carbono de pared múltiple (NTCPM).

Los NTCPM están formados por más de dos capas o láminas de grafeno enrolladas de manera coaxial para formar un cilindro o tubo con un diámetro que va de 1-3 nm, además, la distancia entre cada capa es de 0.34 nm. Debido a su forma son bastante sólidos, sin embargo, eso no significa que no tengan imperfecciones o defectos en su estructura. Son resistentes a la tensión (100 veces más que el acero), y de acuerdo a su quiralidad pueden ser conductores o semiconductores (Raval y col., 2018; Anzar y col. 2020).




Fig. 2 Nanotubos de carbono de pared múltiple (NTCPM).

Estructuras de los NTC

Existen tres tipos de morfología de los NTC de acuerdo a su estructura química, las cuales son:

1. Zigzag, en este tipo de estructura pueden comportarse como conductores o semiconductores.
2. Sillón (armchair), se comportan como metales y por tanto permiten conducir la corriente eléctrica.
3. Quirales, con materiales conductores.

La figura 3 presenta los tres tipos de estructuras que pueden llegar a presentar los NTC.




Fig. 3 Morfología de los nanotubos de carbono: a) Quiral, b) Silla y c) Zigzag (elaboración propia).

Propiedades de los NTC

Los NTC presentan diferentes propiedades de acuerdo a la estructura que los constituye.

i. Propiedades eléctricas.

Los NTC pueden actuar como conductores o semiconductores, esto dependerá de los parámetros de Hamada $n-m$, los cuales indican la forma de enrollamiento que está formando al NTC, es decir, zigzag, silla o quiral). Cuando el valor de este parámetro es múltiplo de 3, se considera como un material semiconductor (figura 4). Cuando los NTC se encuentran ante una señal electromagnética, pueden tener un comportamiento resistivo, capacitivo e inductivo. Además, pueden llegar a deformarse en presencia de un campo eléctrico por fuerzas electrostáticas y tienen la capacidad de transformar la luz en electricidad o producir luz al inyectarles un exceso de carga (Raja y Sabha, 2014).




Figura 4. Carácter electrónico de las posibles estructuras de los NTC de acuerdo al parámetro Hamada $n-m$ (elaboración propia).

ii. Propiedades térmicas.

Los NTC son realmente estables a temperaturas elevadas y pueden presentar una alta conductividad térmica en la dirección del eje del nanotubo (aproximadamente de $6000 \text{ W m}^{-1} \text{ K}^{-1}$). Es importante destacar que esta propiedad puede ser transferida a los compuestos o nanocompuestos elaborados con NTC, por lo que se pueden elaborar materiales que sean buenos conductores térmicos por un extremo o dirección, pero con capacidad aislante del otro (Raja y Sabha, 2014).

iii. Propiedades mecánicas.

Las propiedades mecánicas de los NTC se destacan por ser excepcionales, ya que presentan alta dureza, resistencia mecánica, flexibilidad, elasticidad y tenacidad, además de ser muy ligeros. Poseen una elongación del 10%, resistencia a la tracción de 1.35 gcm^{-3} y un módulo de Young de 1TPa. Estas propiedades están muy por encima de otros materiales, por lo que, gracias a esto, se ha despertado un gran interés de los NTC tanto para la industria como en la investigación (Raja y Sabha, 2014; Baskaran y col. 2006).

iv. Propiedades ópticas.

Al ser iluminados con luz visible, los NTC pueden producir corrientes eléctricas o viceversa. Además, presentan fotoluminiscencia y absorben radiación visible e infrarroja. Al igual que las propiedades mecánicas y eléctricas, las propiedades ópticas también pueden transferirse al material en que se encuentren los NTC, mejorando sus características finales (Raja y Sabha, 2014; Baskaran y col. 2006).

v. Propiedades químicas.

Al estar formados por carbono, los NTC pueden permitir el acoplamiento de estructuras químicas en sus paredes y los extremos, lo cual ocasionará modificaciones en sus propiedades (Raja y Sabha, 2014; Baskaran y col. 2006).

En la Tabla 1 se muestran algunas propiedades generales de los NTC.

Tabla 1. Propiedades generales de los NTC.

Propiedades	NTC
Diámetro	0.4-5 nm
Estabilidad a la temperatura	Estable a >2800°C en vacío y >750°C en aire.
Densidad	1.33-1.40 g-cm ³
Fuerza de tensión	45x10 ¹² Pa
Conductividad eléctrica	Aproximada a 1x10 ¹² Acm ⁻²

Síntesis de los NTC

a. Método de descarga de arco.

En este método se emplean dos electrodos de grafito de alta pureza de 0.5 a 40 mm, en el cual uno es el ánodo y el otro cátodo, ambos se mantienen a corta distancia bajo una atmósfera de helio, se conectan a una fuente de alimentación con un voltaje de 20-50 V. Bajo estas condiciones se produce una chispa de corriente de 50-120 A entre las barras, en donde parte del carbono se evapora del ánodo y se re condensa como un cilindro duro en la varilla del cátodo. Un parámetro importante en este método es la corriente que se aplica, ya que, si es mayor se produce un material sintetizado con baja cantidad de NTC libres. Las altas temperaturas son necesarias para esta técnica (600-1000°C), por lo que puede haber diferencia de arreglos en la red de los tubos, haciendo difícil el control de la quiralidad y diámetro de los NTC (Kumar y col., 2020).

Usando el método de descarga de arco se puede obtener NTC de cientos de micrones de largo, tanto de pared simple como de pared múltiple con pocos defectos estructurales. Una desventaja que presenta este método es que no es fácil de escalar, además de que en ocasiones

se requiere la adición de catalizadores metálicos para aumentar el rendimiento de los NTC (Raja y Sabha, 2014; Raval y col., 2018).




Figura 5. Representación esquemática del método de descarga de arco (Adaptado (Kumar y col., 2020)).

b. Ablación laser.

El método de ablación por láser es utilizado para la producción de NTCPS en masa. En éste se emplea un láser para vaporizar un objetivo de grafito en un ambiente controlado con atmósfera inerte (argón o helio) con una temperatura del horno a 1200°C. El material condensado contiene una gran cantidad de NTC.

El método más actual de ablación laser emplea catalizadores de cobalto y níquel para dopar el objetivo de grafito, con el fin de poder alinear el crecimiento de los NTC durante el proceso (Raja y Sabha, 2014; Raval y col., 2018).




Figura 6. Representación esquemática del método de ablación láser (adaptado (Kumar y col., 2020)).

c. Deposición de vapor químico.

Un grupo de investigadores de la Universidad de Rice bombardeó un metal con pulsos intensos de láser para producir moléculas más extravagantes, y sin darse cuenta descubrieron que habían producido NTC. Este es el método de síntesis considerado como el mejor para la obtención de NTCPS, ya que son obtenidos con alta pureza y a su vez puede ser escalado para producir grandes cantidades. El proceso se lleva a cabo en un reactor tubular a una temperatura entre 550-950°C, el cual lleva a cabo la descomposición de hidrocarburos asistida empleando un catalizador, que puede ser nanopartículas de Fe, Ni o Co. Este es un proceso que se lleva a cabo en continuo, ya que la fuente de carbono siempre se está alimentando con el gas de interés que fluye.

Una gran ventaja de este método es la obtención de matrices alineadas de NTC con diámetro y longitud controlados. Además, presenta un rendimiento de hasta 70% en peso. Se puede fabricar en un área de sustrato seleccionada, a una temperatura baja si se utiliza la técnica

con plasma, sin embargo, una gran desventaja es el costo elevado del láser que se utiliza (Raja y Sabha, 2014; Raval y col., 2018).




Figura 7. Representación esquemática del método de deposición de vapor químico (adaptado (Kumar y col., 2020)).

d. Deposición de vapor químico catalítico.

A diferencia del método de vapor químico, las nanopartículas de Fe, Ni y/o Co son depositadas de forma directa formando una fina lámina de 1-50 nm de espesor, el sustrato se mantendrá en una solución diluida con HF y agua destilada, la cual se colocará en una cubeta de cuarzo y se pondrá en un horno de atmósfera inerte con gas de helio a baja presión, en donde se formarán las partículas de metal catalítico de tamaño nanométrico, posteriormente se le dará un grabado adicional usando gas de metano, acetileno o benceno a una temperatura de 750-1050°C. Los NTC crecerán en las partículas de metal catalítico. La formación de estas partículas es el proceso más importante por lo que hay que tener sumo cuidado para evitar que se degraden. Los NTC que se obtienen suelen ser de pared múltiple con numerosos defectos y una resistencia a la tracción menor a los obtenidos por el método de descarga de arco (Raja y Sabha, 2014; Raval y col., 2018).

Funcionalización de los NTC

Los NTC presentan excelentes propiedades térmicas, eléctricas, ópticas y químicas, lo cual hace que sean excelentes candidatos para una gran variedad de aplicaciones como en la fabricación de sensores biológicos (Zhou y col., 2017), en celdas fotovoltaicas como material activo de adsorción de luz (Grace y col., 2017), en la elaboración de celdas de litio (Fang y col., 2017), biomedicina (Xue, 2017), por mencionar algunas. Sin embargo, presentan baja estabilidad de dispersión en disolventes polares. Para poder entender claramente cómo actúan los NTC, se debe considerar lo siguiente:

- ✓ Una dispersión es una mezcla que está formada por dos o más componentes, la cual está constituida por una fase dispersa y una fase dispersante. La fase dispersa se encuentra en menor proporción y la fase dispersante se encuentra en mayor cantidad respecto a la cantidad total en la mezcla.
- ✓ Una disolución es una mezcla homogénea de dos o más sustancias, la cual está compuesta por un soluto y un disolvente. El soluto es el de menor cantidad en la mezcla.
- ✓ La solubilidad por su parte es considerada como la máxima de soluto (partículas) que se pueden disolver en cierto volumen de disolvente a una temperatura dada (Guldi y Martin, 2010).

La formación de coloides o suspensiones es debido a la dispersión, también se obtienen disoluciones como resultado de la solubilidad de iones de un soluto o moléculas de un disolvente. Una disolución se considera estable cuando es homogénea y no hay separación de las fases después de un tiempo determinado. Además, contienen al soluto en un tamaño molecular o a nivel iónico por debajo de 1 nm. Por otro lado, los coloides son sustancias opacas, no estables y el tamaño de sus partículas oscila entre 1 nm a 1000 nm, siendo estas dimensiones suficientes para poder dispersar la luz. Sus partículas se pueden encontrar suspendidas, dependiendo del equilibrio coloidal (Guldi y Martin, 2010).

Los NTC presentan una dispersión coloidal y no una disolución, por lo cual se han llevado a cabo diversos estudios de funcionalización, ya que estos son insolubles en agua. La

funcionalización consiste en añadir grupos funcionales, partículas o moléculas que permitan un cambio de polaridad sobre la superficie de los NTC, lo cual ocasionará una modificación a sus propiedades debido a que estas quedarán unidas a los defectos estructurales naturales de los NTC. Al llevar a cabo una funcionalización de forma adecuada, los NTC pueden dispersarse en distintos disolventes, además, se genera una mejor interacción con otras moléculas (partículas metálicas, cerámicas, polímeros, etc.), volviéndose más atractivos para poder llevar a cabo un sinnúmero de aplicaciones en diferentes áreas (González Velázquez, 2015).


Para mejorar las propiedades de los NTC se puede llevar a cabo las siguientes uniones:

- ↳ Reacción química con los NTC.
- ↳ Sustitución de los átomos de carbono por átomos de otros elementos o grupos funcionales.
- ↳ Anclaje de grupos funcionales en la apertura final de los NTC.
- ↳ Anclaje de grupos funcionales en las paredes de los NTC.
- ↳ Decoración de las paredes exteriores de los NTC.
- ↳ Relleno de las cavidades interiores de los NTC mediante la inserción de átomos o moléculas en el espacio intertubular (González Velázquez, 2015).


De acuerdo al tipo de unión, la funcionalización puede ser:

- a. Funcionalización endoédrica. Se lleva a cabo por la inserción de moléculas o partículas en las paredes internas de los NTC. Para este tipo de funcionalización se utilizan dos diferentes métodos, el primero consiste en la penetración espontánea mediante suspensión de nanopartículas coloidales, las cuales se introducirán en el interior de los NTC mediante la evaporación del disolvente portador. El segundo consiste en introducir el precursor en el interior de los NTC para posteriormente transformarse mediante medios químicos o térmicos.
- b. Funcionalización exoédrica. Es aquella en la que se lleva a cabo el anclaje de grupos funcionales o moléculas en la superficie de los NTC. Puede ser de dos tipos:


- **Funcionalización covalente.** Es aquella en la cual se lleva a cabo la creación de grupos funcionales en las paredes de los NTC mediante una reacción química. Las más comunes son las llevadas a cabo con grupos amino y carboxilo. Este tipo de funcionalización permite un cambio en la hibridación del carbono de sp^2 a sp^3 , sin embargo, presenta una gran desventaja, ya que se puede comprometer la integridad de las paredes de los NTC dañándolas de manera irreversible (Andrade y col., 2012).
- **Funcionalización no covalente.** Se lleva a cabo mediante la adsorción de moléculas no covalentes, mediante las fuerzas de van der Waals y fuerzas electrostáticas sin necesidad de crear defectos estructurales permitiendo así, conservar las propiedades mecánicas y de transporte de los NTC. Este tipo de funcionalización se puede llevar a cabo empleando tecnologías alternas como lo es el ultrasonido y el microondas, con las cuales se puede obtener una mejor dispersión de los NTC, lo cual ayudará a tener una mejor interacción entre los grupos funcionales y los carbonos en hibridación sp^2 (Guldi y Martin, 2010).



a) Funcionalización endoédrica



b) Funcionalización exoédrica no covalente



c) Funcionalización exoédrica covalente

Figura 8. Tipos de funcionalización de NTC (elaboración propia).

Aplicaciones actuales

Como ya se ha mencionado, gracias a las propiedades que presentan los NTC pueden ser empleados en una gran variedad de aplicaciones. En la Tabla 2 se muestran los diferentes trabajos y/o aplicaciones en las que se han empleado los NTC recientemente, desde su uso en sensores táctiles a base de nanoplaquetas de grafeno, hasta como sustitutos de aleaciones permitiendo a estas aumentar sus propiedades eléctricas. Además, se ha podido mejorar las propiedades de diferentes materiales como el acrílico al adicionar NTCPM aumentando sus propiedades de tracción y resistencia al impacto.

Tabla 2. Aplicaciones de los NTC en los últimos 10 años en diferentes áreas.

Título	Aplicación	Referencia
Aplicación de nanotubos de carbono preparados a partir de residuos plásticos a materiales de cambio de fase: el potencial para la gestión térmica de baterías	Se produjeron NTC a partir de desechos plásticos como nanorrelleno en material de cambio de fase (PCM). El compuesto preparado tiene un potencial similar al NTCc y muestra un rendimiento destacado como relleno conductor fluido para sistemas de gestión térmica de baterías.	(Wang y col., 2022)

<p>Efecto del dodecilsulfato de sodio en la mejora de la absorción de CO₂ y H₂S de nanotubos de carbono de pared múltiple funcionalizados en agua: estudio experimental y modelo empírico</p>	<p>Se investigó el efecto de la hidrodinámica de adsorción de CO₂ y H₂S utilizando una columna de absorción de una sola burbuja en agua pura y nanofluidos a base de agua dispersos con NTCPM funcionalizados con OH y NH₂ puros. Se encontró que la absorción máxima de CO₂ y H₂S fue de 0,0038 mol · m⁻² s y 0,056 mmol m⁻²s utilizando NH₂-NTCPM /nanofluido con un contenido de 0,5 % en peso.</p>	<p>(Jafari y Ameri, 2022)</p>
<p>Sensores táctiles capacitivos estirables de grafeno y nanofibras de carbono para aplicaciones de piel robótica.</p>	<p>Fabricación de sensores táctiles electrónicos estirables mediante recubrimiento por pulverización de nanoplaquetas de grafeno conductoras o nanofibras de carbono.</p>	<p>(Yaragalla y col., 2021)</p>
<p>Tabla 2. Aplicaciones de los NTC en los últimos 10 años en diferentes áreas. Continuación.</p>		
<p>Nanocompuestos funcionalizados con NTCPM/NPs de plata como biosensores electroquímicos no enzimáticos para la</p>	<p>Se sintetizaron nanocompuestos funcionalizados de nanotubos de NTCPM/nanopartículas de plata (f-MWCNT/AgNP) como material de biodetección para detectar DA. Mediante pruebas de caracterización de SEM, TEM y EDS se determinó que el nanocompuesto NTCPM/AgNP es un material biosensores prometedor para la detección de DA.</p>	<p>(Anshori y col., 2021)</p>

detección de dopamina (DA)		
Resistividad eléctrica de la unión de soldadura Sn–3.0Ag–0.05Cu con la incorporación de nanotubos de carbono	Se adicionan NTC a una soldadura de Sn–3.0Ag–0.5Cu, esto para evitar el uso de soldadura pura a granel. Se demostró que la adición de los nanotubos no modifica la microestructura de la soldadura, ni modifica sus propiedades, sino que se observó un aumento en electricidad de la soldadura modificada.	(Ismail y col., 2021)
Rendimiento de compuestos a base de epoxi con nanotubos de carbono de paredes múltiples y copolímero acrílico de tres bloques	Se reforzó la red epoxi-amina al adicionar el compuesto BMG-NTCPM funcionalizados (7.1 % BMG y 0.4% NTCPM). Con esto se pudo aumentar las propiedades de tracción y resistencia al impacto de los compuestos aumentando de 11.25 y 36.4% respectivamente.	(Li y col., 2019)
Rendimiento y durabilidad a largo plazo de los nanocompuestos de policarbonato/NTC.	Se realizó una investigación para predecir el tiempo hasta la falla a largo plazo de los nanocompuestos de policarbonato/NTC basado en la experimentación a corto plazo con una aplicación tanto para la fluencia como para la fatiga.	(Pastukh ov y col., 2018)

Tabla 2. Aplicaciones de los NTC en los últimos 10 años en diferentes áreas. Continuación.

<p>Un nanosistema modificado inmunológicamente basado en la unión no covalente entre NTCPS y quitosano glicosilado</p>	<p>Se investigó las características de unión de NTCPS y quitosano glicosilado mediante simulaciones de dinámica molecular. Los resultados de las simulaciones demostraron que el quitosano glicosilado se unía a los NTCPS mediante una fuerte interacción no covalente.</p>	<p>(Saha y col., 2018)</p>
<p>Compuestos inteligentes reforzados con nanotubos de carbono para detectar la temperatura de congelación y descongelar por autocalentamiento.</p>	<p>Se fabricaron compuestos poliméricos reforzados con NTC mediante una mezcla con polidimetilsiloxano. Concluyeron que que a una concentración de 7% de NTC y a al aumentar el grosor el material adquiriría alta conductividad eléctrica. Además, se observó que los NTC son sensibles a la temperatura por lo que se pueden utilizar como revestimiento inteligente para descongelar por autocalentamiento.</p>	<p>(Jang y Park, 2018)</p>
<p>Observaciones de un nuevo mecanismo de fortalecimiento en nanocompuestos de HDPE.</p>	<p>Se desarrolló un nuevo mecanismo de fortalecimiento a nivel molecular de nanocompuestos NTC/HDPE producido por intercalación de fusión. Las propiedades mecánicas del nanocompuesto mostraron una mejora en el módulo de tracción y la resistencia máxima del material de HDPE puro en un 30 % y un 8 %.</p>	<p>(Okolo y Inam, 2018)</p>
<p>Una nueva generación de nanomateriales a base carbono para aplicaciones biomédicas.</p>	<p>Compuestos a base de grafeno utilizados en el área de la biomedicina, específicamente para el desarrollo de biosensores, acarreadores de fármacos hidrófobos, sustrato para la regeneración celular y liberación controlada de fármacos debido a sus propiedades eléctricas, ópticas, el área superficial y estructura.</p>	<p>(Andrade y col., 2012)</p>

Tabla 2. Aplicaciones de los NTC en los últimos 10 años en diferentes áreas. Continuación.

<p>Áreas de nanotubos de carbono-impresas en sustratos textiles y de papel.</p>	<p>Se prepararon estructuras de carbono mediante impresión flexográfica utilizando dispersiones de NTCPM en agua. Los NTC se aplicaron a un sustrato textil hecho de microfilamentos de poliéster y poliamida y a papel recubierto por ambos lados para producir capas conductoras de electricidad con aplicación en elementos calefactores.</p>	<p>(Fisher y col., 2011)</p>
---	--	------------------------------

Conclusiones

Mediante la presente investigación se concluyen aspectos importantes de los NTC, así como algunas de las aplicaciones que han tenido dentro de la investigación en la ciencia y nanotecnología en los últimos años, haciéndolos un nanomaterial interesante que aún se desconoce hasta donde llegan sus alcances. Sus aplicaciones van desde la industria biomédica hasta la eléctrica, en donde se han utilizado para la fabricación de biosensores, biopolímeros; así como nanomateriales para mejorar la conductividad eléctrica y capacidad térmica para ser utilizados en baterías, calefactores, o simplemente como complemento de otros materiales para potencializar sus propiedades o fortalecerlas dándoles estabilidad estructural. Debido a que muchas de estas aplicaciones solo se han hecho como parte de una investigación se espera que en el futuro realmente puedan ser utilizados como parte de materiales compuestos dentro de la industria para la fabricación de materiales de uso cotidiano como lo son los dispositivos electrónicos, marcadores moleculares para enfermedades o como materiales conductores a partir de matrices poliméricas, solo por mencionar algunas.

Agradecimientos

Se agradece a la Universidad Autónoma de Coahuila, a la Facultad de Ciencias Químicas, a la Maestría en Ciencia y Tecnología Química, de igual manera se agradece la beca con número 816345 otorgada por CONACYT para el desarrollo de dicha investigación, así como al apoyo proporcionado por el proyecto SEP-CONACyT Ciencias Básica 2017-2018 CB2017-2018 A1-S-44977.

Referencias

- Anshori, I., Nuraviana Rizalputri, L., Rona Althof, R., Sean Surjadi, S., Harimurti, S., Gumilar, G., Yulianto, B., & Handayani, M. 2021. Functionalized multi-walled carbon nanotube/silver nanoparticle (f-MWCNT/AgNP) nanocomposites as non-enzymatic electrochemical biosensors for dopamine detection. *Nanocomposites*, 7(1): 97-108. <https://doi.org/10.1080/20550324.2021.1948242>
- Anzar, N., Hasan, R., Tyagi, M., Yadav, N., & Narang, J. 2020. Carbon nanotube: A review on Synthesis, Properties and plethora of applications in the field of biomedical science. *Sensors International*, 1: 100003. <https://doi.org/10.1016/j.sintl.2020.100003>
- Baskaran, D., King, R. H. Crabtree, C. M. Lukehart, D. A. Atwood, & R. A. 2006. Carbon: Nanotubes. Scott (Eds.), *Encyclopedia of Inorganic Chemistry* (p. ia306). John Wiley & Sons, Ltd. <https://doi.org/10.1002/0470862106.ia306>
- Fang, S., Shen, L., & Zhang, X. 2017. Application of Carbon Nanotubes in Lithium-Ion Batteries. En *Industrial Applications of Carbon Nanotubes* (pp. 251-276). Elsevier. <https://doi.org/10.1016/B978-0-323-41481-4.00009-5>
- Fischer, T., Wetzold, N., Elsner, H., Kroll, L., & Hübler, A. 2011. Carbon Nanotube Areas-Printed on Textile and Paper Substrates. *Nanomaterials and Nanotechnology*, 1: 3. <https://doi.org/10.5772/50946>

González Velázquez, V. (2015). *Nanomateriales de Carbono, síntesis, funcionalización y aplicaciones* [Tesis doctoral inédita]. Universidad Carlos III de Madrid.

Grace, T., Shearer, C., Tune, D., Yu, L., Batmunkh, M., Biggs, M. J., AlOthman, Z. A., & Shapter, J. G. 2017. Use of Carbon Nanotubes in Third-Generation Solar Cells. En *Industrial Applications of Carbon Nanotubes* (pp. 201-249). *Elsevier*. <https://doi.org/10.1016/B978-0-323-41481-4.00008-3>

Guldi, D. M., & Martin, N. 2010. Carbon nanotubes and related structures: Synthesis, characterization, functionalization, and applications. *Wiley-VCH*. <https://doi.org/10.1002/9783527629930>

Hirsch, A., & Vostrowsky, O. 2006. Functionalization of Carbon Nanotubes. En T. J. J. Miller & U. H. F. Bunz (Eds.), *Functional Organic Materials* (pp. 1-57). Wiley-VCH Verlag GmbH & Co. KGaA. <https://doi.org/10.1002/9783527610266.ch1>

Ismail, N., Jalar, A., Afdzaluddin, A., & Bakar, M. 2021. Electrical resistivity of Sn-3.0Ag-0.5 Cu solder joint with the incorporation of carbon nanotubes. *Nanomaterials and Nanotechnology*, 11, 184798042199653. <https://doi.org/10.1177/1847980421996539>

Jafari Farsaani, D., & Ameri, E. 2022. Effect of sodium dodecyl sulfate on CO₂ and H₂S absorption enhancement of functionalized multiwall carbon nanotubes in water: Experimental study and empirical model. *Arabian Journal of Chemistry*, 15(12): 104314. <https://doi.org/10.1016/j.arabjc.2022.104314>

Jang, S., & Park, Y. 2018. Carbon nanotube-reinforced smart composites for sensing freezing temperature and deicing by self-heating. *Nanomaterials and Nanotechnology*, 8: 184798041877647. <https://doi.org/10.1177/1847980418776473>

Kumar Jagadeesan, A., Thangavelu, K., & Dhananjeyan, V. 2020. Carbon Nanotubes: Synthesis, Properties and Applications. En P. Pham, P. Goel, S. Kumar, & K. Yadav (Eds.), *21st Century Surface Science. A Handbook*. IntechOpen. <https://doi.org/10.5772/intechopen.92995>

Li, H., Liu, Z., Gu, J., Wang, D., Qu, C., Bai, X., & Qiao, Y. 2019. Performances of epoxy-based composites with multi-wall carbon nanotubes and acrylic tri-block copolymer. *Nanocomposites*, 5(1): 28-35. <https://doi.org/10.1080/20550324.2019.1601804>

Okolo, C., & Inam, F. 2018. Observations of a novel strengthening mechanism in HDPE nanocomposites. *Nanocomposites*, 4(4): 215-222. <https://doi.org/10.1080/20550324.2018.1558798>

Pandey, R., & Chusuei, C. 2021. Carbon Nanotubes, Graphene, and Carbon Dots as Electrochemical Biosensing Composites. *Molecules*, 26(21): 6674. <https://doi.org/10.3390/molecules26216674>

Pastukhov, L., Mercx, F., Peijs, T., & Govaert, L. 2018. Long-term performance and durability of polycarbonate/carbon nanotube nanocomposites. *Nanocomposites*, 4(4): 223-237. <https://doi.org/10.1080/20550324.2018.1558799>

Raja, M., & Subha, J. (2014). A. Tiwari & S. K. Shukla, Wiley (Ed.), *Carbon Nanotubes and Their Applications*. [En línea]. Disponible en: <https://doi.org/10.1002/9781118895399.ch5>. Fecha de consulta: 20 de abril de 2023.

Raval, J. P., Joshi, P., & Chejara, D. R. (2018). Biomaterials. In Woodhead (Ed.), *Carbon nanotube for targeted drug delivery*. [En línea]. Disponible en: <https://doi.org/10.1016/B978-0-12-813741-3.00009-1>. Fecha de consulta: 22 de abril de 2023.

Saha, L., Nag, O., Doughty, A., Liu, H., & Chen, W. 2018. An Immunologically Modified Nanosystem Based on Noncovalent Binding Between Single-Walled Carbon Nanotubes and Glycated Chitosan. *Technology in Cancer Research & Treatment*, 17, 153303381880231. <https://doi.org/10.1177/1533033818802313>

Thauer, E., Ottmann, A., Schneider, P., Möller, L., Deeg, L., Zeus, R., Wilhelmi, F., Schlestein, L., Neef, C., Ghunaim, R., Gellesch, M., Nowka, C., Scholz, M., Haft, M., Wurmehl, S., Wenelska, K., Mijowska, E., Kapoor, A., Bajpai, A., ... Klingeler, R. 2020.

Filled Carbon Nanotubes as Anode Materials for Lithium-Ion Batteries. *Molecules*, 25(5): 1064. <https://doi.org/10.3390/molecules25051064>

Wang, F., Zhao, S., Jiang, Q., Li, R., Zhao, Y., Huang, Y., Wu, X., Wang, B., & Zhang, R. 2022. Advanced functional carbon nanotube fibers from preparation to application. *Cell Reports Physical Science*, 3(8): 100989. <https://doi.org/10.1016/j.xcrp.2022.100989>

Wang, W., Lu, F., Veca, L. M., Mezziani, M. J., Wang, X., Cao, L., Gu, L., & Sun, Y. P. 2009. Carbon Nanotubes and Nanocomposites for Electrical and Thermal Applications. En R. B. King, R. H. Crabtree, C. M. Lukehart, D. A. Atwood, & R. A. Scott (Eds.), *Encyclopedia of Inorganic Chemistry* (p. ia356). John Wiley & Sons, Ltd. <https://doi.org/10.1002/0470862106.ia356>

Wang, Y., Bailey, J., Zhu, Y., Zhang, Y., Boetcher, S., Li, Y., & Wu, C. 2022. Application of carbon nanotube prepared from waste plastic to phase change materials: The potential for battery thermal management. *Waste Management*, 154: 96-104. <https://doi.org/10.1016/j.wasman.2022.10.003>

Wei, H., Zhan, H., Wang, Y., Gu, Y., Wang, S., Zhang, Z., & Li, M. 2021. Impacts from the stacking morphology on the tensile performance of double-walled carbon nanotube bundles. *Carbon*, 178: 345-354. <https://doi.org/10.1016/j.carbon.2021.03.023>

Xue, Y. 2017. Carbon Nanotubes for Biomedical Applications. En *Industrial Applications of Carbon Nanotubes* (pp. 323-346). Elsevier. <https://doi.org/10.1016/B978-0-323-41481-4.00011-3>

Yaragalla, S., Dussoni, S., Zahid, M., Maggiali, M., Metta, G., Athanasiou, A., & Bayer, I. S. 2021. Stretchable graphene and carbon nanofiber capacitive touch sensors for robotic skin applications. *Journal of Industrial and Engineering Chemistry*, 101: 348-358. <https://doi.org/10.1016/j.jiec.2021.05.048>

Zhou, M., Wang, Z., & Wang, X. 2017. Carbon Nanotubes for Sensing Applications. En Industrial Applications of Carbon Nanotubes (pp. 129-150). *Elsevier*.
<https://doi.org/10.1016/B978-0-323-41481-4.00005-8>

Modelado Cinemático de Mecanismos Robóticos empleando Redes Neuronales

Kinematic Modeling of Robotic Mechanisms using Neural Networks

**Héctor A. Moreno¹, J. Fidencio Flores², Isela G. Carrera¹, J. Rolando Rodríguez¹,
Roberto G. Adán¹, Mario A. García-Murillo³**

¹Facultad de Ingeniería Mecánica y Eléctrica, Universidad Autónoma de Coahuila,
Barranquilla S/N, Guadalupe, 25750, Monclova, Coahuila, México.

²Unidad Profesional Interdisciplinaria de Ingeniería Campus Coahuila, Instituto Politécnico
Nacional. Gustavo Díaz Ordaz 1011, Pueblo Nuevo, 25500 San Buenaventura, Coahuila,
México.

³Departamento de Ingeniería Mecánica, DICIS, Universidad de Guanajuato, 36885,
Salamanca, Guanajuato, México.

Correo electrónico: h_moreno@uadec.edu.mx

RESUMEN

Desde los inicios de la robótica ingenieros e investigadores ha dedicado varios esfuerzos al estudio del modelado cinemático de mecanismos robóticos. Este modelado es esencial para la simulación, el diseño, la planificación de trayectorias y el control de esta clase de dispositivos. A medida que fueron surgiendo nuevas arquitecturas de robots, cuya cinemática es irresoluble analíticamente, se comenzaron a proponer modelos basados en métodos computacionales. En este documento se presenta, a manera didáctica, diversos conceptos relativos al modelado cinemático de mecanismos robóticos empleando redes neuronales. Primero se presenta una introducción al modelado cinemático de robots y una revisión a las técnicas que se ha propuesto en la literatura científica. Posteriormente, se ofrece una breve explicación sobre diferentes términos que existen el área de la inteligencia artificial, el machine learning y las redes neuronales. Luego de ello se describen algunos trabajos relevantes que se han hecho en el modelado cinemático empleando redes neuronales, los procedimientos para diseño de arquitecturas y los principales criterios de desempeño que hay que considerar. Finalmente se presenta un ejemplo de la aplicación de las redes neuronales al modelado de una rueda híbrida de geometría variable y se describe el software empleado para ello.

PALABRAS CLAVE: Modelo cinemático, Redes Neuronales, Robótica, Diseño e Implementación.

ABSTRACT

Since the beginning of robotics, engineers and researchers have devoted several efforts to the study of the kinematic modeling of robotic mechanisms. This modeling is essential for the simulation, design, trajectory planning and control of this class of devices. As new robot architectures emerged, whose kinematics cannot be solved analytically, models based on computational methods began to be proposed. This paper presents, in a didactic way, several concepts related to the kinematic modeling of robotic mechanisms using neural networks.

First, an introduction to kinematic modeling of robots and a review of the techniques that have been proposed in the scientific literature are presented. Subsequently, a brief explanation of different terms that exist in the area of artificial intelligence, machine learning and neural networks is given. This is followed by a description of some relevant works that have been done in kinematic modeling using neural networks, the procedures for architecture design and the main performance criteria to be considered. Finally, an example of the application of neural networks to the modeling of a variable geometry hybrid wheel, and the use of software for this purpose, is presented.

KEYWORDS: Kinematic model, Neural Networks, Robotics, Design and Implementation.

1. INTRODUCCIÓN

Un robot es un dispositivo que mediante la interacción física con el ambiente realiza una tarea o misión comandada por un usuario. Estos dispositivos pueden ser teleoperados o contar con diversos niveles de autonomía. La interacción física se realiza a través del sistema mecánico del robot. Este sistema puede estar compuesto de una plataforma de locomoción (terrestre, acuática, o aérea), un brazo robótico, y un efector final o herramienta. Dada la relevancia del sistema mecánico de un sistema robótico, la comunidad científica dedicada a la robótica ha realizado desde sus inicios estudios sobre del modelado matemático de la mecánica de estos dispositivos.

El modelado matemático de mecanismos robóticos tiene dos áreas principales, el modelado cinemático y el modelado dinámico. El modelado cinemático de un robot consiste en encontrar las ecuaciones algebraicas que relacionan los movimientos de los actuadores del robot (motores eléctricos, neumáticos o hidráulicos) con los movimientos del efector final que realiza la tarea de interés. Por otra parte, el modelado dinámico de un robot consiste encontrar las ecuaciones que relacionan las fuerzas y torques generados por los actuadores con los movimientos que se producen el robot y las fuerzas que se aplican en el efector final.

Ambos modelos juegan un papel fundamental en el estudio del desempeño de robots a través de simulación, en el diseño mecánico y en el control al ejecutar una tarea.

Inicialmente era deseable que el modelo cinemático de un robot se obtuviera analíticamente, resolviendo ecuaciones algebraicas que proveían soluciones de forma cerrada. A medida que surgieron nuevas arquitecturas de robots, cuya cinemática era irresoluble analíticamente se comenzaron a proponer modelos basados en métodos numéricos. En este documento se presenta, a manera didáctica, diversos conceptos relativos al modelado cinemático de mecanismos robóticos empleando redes neuronales. En la siguiente sección se explica en que consiste el modelado cinemático de robots y una revisión a las técnicas que se ha propuesto en la literatura científica. Posteriormente, se presenta una explicación sobre diferentes términos que existen en el área de la inteligencia artificial, el machine learning y las redes neuronales. Luego de ello se describen algunos trabajos relevantes que se ha hecho al respecto, los procedimientos para diseño de arquitecturas de redes neurales y los principales criterios de desempeño que hay que considerar. Finalmente se presenta un ejemplo de la aplicación de las redes neuronales al modelado de una rueda híbrida de geometría variable, y el empleo de software para ello.

2. MODELADO CINEMÁTICO DE MECANISMOS ROBÓTICOS

El modelado cinemático de un robot consiste en la determinación de las relaciones existentes entre las coordenadas operacionales del robot y sus variables articulares; las *coordenadas operacionales* describen la situación (posición y orientación) del órgano terminal, con respecto a un marco de referencia fijo; y las *variables articulares* son las que definen la posición relativa de un eslabón de la cadena cinemática con respecto al precedente.

2.1 MODELADO CINEMÁTICO DE POSICIÓN

En este modelado se obtienen las ecuaciones que permiten determinar las coordenadas operacionales (posiciones y orientaciones del eslabón de interés) a partir de las variables articulares (ángulos y longitudes controlados por los actuadores).

El *modelado cinemático directo de posición* consiste en encontrar una función que nos permita determinar los valores del vector de coordenadas operaciones \mathbf{x} , conocidos los valores del vector de variables articulares \mathbf{q} :

$$\mathbf{x} = \mathbf{f}(\mathbf{q})$$

Por otro lado, existe también el *modelado cinemático inverso de posición*, en este caso se obtiene vector de variables articulares \mathbf{q} dado valores del vector de coordenadas operaciones \mathbf{x} :

$$\mathbf{q} = \mathbf{f}^{-1}(\mathbf{x})$$

Este modelado es el que permite al robot realizar las tareas siguiendo los puntos en el espacio programados.

Generalmente, en el modelado cinemático de posición los sistemas de ecuaciones son trascendentes y en ciertos casos no es posible obtener una solución de manera analítica. En estos casos es donde se han empleado métodos numéricos para resolver las soluciones respectivas.

2.2 MODELADO CINEMÁTICO DE VELOCIDAD

El *modelado cinemático directo de velocidad* consiste en la determinación de las relaciones existentes entre las velocidades articulares y las velocidades operacionales del robot; dichas relaciones generalmente se representan de la siguiente manera:

$$\dot{\mathbf{x}} = \mathbf{J}\dot{\mathbf{q}}$$

Donde $\dot{\mathbf{x}} = \frac{dx}{dt}$ es el vector de velocidades operacionales, $\dot{\mathbf{q}} = \frac{dq}{dt}$ es el vector de velocidades articulares y \mathbf{J} es una matriz jacobiana. El *modelado cinemático inverso de velocidad* se obtiene fácilmente al invertir la matriz jacobiana:

$$\dot{\mathbf{q}} = \mathbf{J}^{-1}\dot{\mathbf{x}}$$

La obtención de estos modelos es relativamente sencilla, consiste en derivar las ecuaciones de posición y posteriormente expresar el sistema de ecuaciones lineales en forma matricial.

En mecánica de robots se han realizado varios estudios en los que se emplea la matriz Jacobiana para evaluar el desempeño cinemático del mecanismo robótico en posiciones particulares o globalmente en el espacio de trabajo. Diversos índices de desempeño basados en la matriz Jacobiana se han empleado tanto para la planificación de trayectorias como para el diseño óptimo (Moreno y col., 2012).

2.3 MODELADO CINEMÁTICO DE ACELERACIÓN

Derivando la ecuación de velocidad se pueden obtener las relaciones de aceleración de las variables cinemáticas, en este caso el modelo cinemático directo de aceleración está dado por la siguiente expresión:

$$\ddot{\mathbf{x}} = \mathbf{J}\ddot{\mathbf{q}} + \dot{\mathbf{J}}\dot{\mathbf{q}}$$

Donde, $\ddot{\mathbf{x}}$ es el vector de aceleraciones operacionales, $\ddot{\mathbf{q}}$ es el vector de aceleraciones articulares y $\dot{\mathbf{J}}$ es la derivada temporal de la matriz jacobiana. El modelo cinemático inverso de aceleración se obtiene de la siguiente forma:

$$\ddot{\mathbf{q}} = \mathbf{J}^{-1}(\ddot{\mathbf{x}} - \dot{\mathbf{J}}\dot{\mathbf{q}})$$

2.4 MODELADO CINEMÁTICO BASADO EN MÉTODOS NUMÉRICOS

Como se mostró en los apartados anteriores, únicamente el modelado cinemático de posición es el que presenta dificultades para resolverse analíticamente. Tanto los problemas de velocidad y aceleración consisten de ecuaciones lineales, fácilmente resolubles con los métodos del álgebra lineal. Se puede clasificar en términos generales a los modelos cinemáticos de posición de robots en:

- **Modelos Analíticos.** Estos modelos se obtienen a partir de resolver las ecuaciones del análisis de posición y obtener soluciones en forma cerrada. Siempre es deseable obtener modelos analíticos ya que su precisión numérica es la máxima y son computacionalmente más eficientes. Para arquitecturas de robots sencillas es posible obtener estas soluciones en forma cerrada y generalmente involucran sistemas de ecuaciones trascendentes. En robots seriales la cinemática directa se obtiene fácilmente mediante las matrices de transformación homogénea, mientras que es más difícil resolver la cinemática inversa, y en ciertas arquitecturas no es posible. En robots paralelos sucede lo contrario en ambos casos.
- **Modelos Cuasi-analíticos.** Estos modelos consisten en resolver la cinemática obteniendo parte de las incógnitas de manera analítica, y el resto de a través de un método computacional. En (Yime y col., 2011) se presenta el análisis de un robot paralelo con cinemática desacoplada, en donde la cinemática directa se resuelve analíticamente para el problema de posición y mediante el algoritmo de Newton-Raphson para el problema de orientación. En (Sadjadian y Taghirad, 2005) se resuelve la cinemática directa de un robot paralelo redundante, para ello se formula el problema de manera dos elementos de la matriz de orientación (la cual define el resultado de la cinemática directa) se obtienen numéricamente resolviendo un problema de optimización con restricciones. Posteriormente el resto de los elementos de la matriz de rotación se obtienen analíticamente a partir de los valores de esos dos elementos.

- **Modelos Numéricos.** Cuando no es posible obtener de manera analítica la solución de las ecuaciones de posición, se recurre a obtener la solución mediante métodos computacionales. Algunos de estos métodos son iterativos y otros se obtienen de expresiones cuyos parámetros son previamente determinados. La principal desventaja de emplear estos métodos es que siempre estará presente un margen de error, el cual se puede disminuir, sin embargo, se requerirá de un mayor coste computacional.
- **Uso de Sensores Extra.** Algunos investigadores han propuesto la resolución de la cinemática mediante la obtención de información adicional proveniente de sensores adicionales de posición (Baron y Angeles, 2000). Conociendo los valores de ciertas variables cinemáticas mediante la medición directa a través de sensores es posible simplificar las ecuaciones de posición y resolverlas para determinar la solución de la cinemática directa. Algunas dificultades que se han encontrado en este esquema es el ruido presente en las señales de los sensores.

En la literatura científica se pueden encontrar diferentes propuestas para resolver numéricamente la cinemática de mecanismos robóticos, estas estrategias son:

- **El método de Newton- Raphson.** Este método es muy empleado para encontrar la solución a ecuaciones o sistemas de ecuaciones cuya solución analítica no es posible. Esta técnica es procedimiento iterativo, para lo cual se requiere la obtención de una matriz jacobiana que se emplea para calcular nuevos valores del vector de incógnitas que se acercan cada vez más a la solución del sistema. Si el vector de incógnitas converge a un valor, y el error de entre nuevos sucesivos cálculos es menor que un determinado valor, entonces se dice que el algoritmo encontró una solución (Puglisi y col., 2017). Este algoritmo tiene como desventaja que no asegura convergencia. Por otro lado, dependiendo del valor inicial el algoritmo puede converger a otro valor que no corresponde a la solución esperada. Finalmente, el número de iteraciones necesarias para encontrar una solución no es posible de determinar.

- **Aproximación por Series de Taylor.** En este esquema la solución de la cinemática se aproxima mediante una serie de potencias de Taylor. El número de coeficientes de la expansión viene determinado por el grado de precisión requerido. Resolver el problema de la cinemática consiste en calcular los coeficientes de la serie. En (Sadjadian y Taghirad, 2005) se consideraron diferentes trayectorias para el efector final y se determinaron los correspondientes desplazamientos del actuador utilizando la cinemática inversa. A continuación, se utilizó el par de datos para calcular los coeficientes de la expansión de Taylor utilizando la estimación por mínimos cuadrados a partir de los datos obtenidos de diversas trayectorias en el espacio de trabajo.
- **Redes Neuronales Artificiales.** Una de las características más interesantes de las redes neuronales es su capacidad para aproximar funciones no lineales. Además, los esquemas de redes neuronales son independientes de la estructura del sistema, lo que da lugar a un enfoque robusto con respecto a los cambios del entorno. Conocido de manera analítica un modelo cinemático se entrena una red neuronal con los datos obtenidos de la exploración del espacio de trabajo, obteniendo pares de datos de entradas y salidas, y con ello se generará el modelo inverso basado en la red neuronal. Una vez generado el modelo, el cálculo de la cinemática correspondiente no es un proceso iterativo, si no consiste en ejecutar las operaciones aritméticas y matriciales para el cálculo de las variables de salida, con un coste computacional constante.

A continuación, se presenta una explicación sobre diferentes términos que existen el área de la inteligencia artificial, el machine learning y las redes neuronales, de manera de que la sección de la aplicación de las redes neuronales al modelado cinemático sea más clara.

3. INTELIGENCIA ARTIFICIAL Y REDES NEURONALES

En esta sección se explican los conceptos de Inteligencia Artificial (IA), Aprendizaje Automático (Machine Learning) y Aprendizaje Profundo (Deep Learning). Los conceptos de Machine Learning, Inteligencia Artificial y Deep Learning, llegan a parecer lo mismo, pero

en realidad son diferentes aunque manejan algunas relaciones. A continuación se explican los conceptos de cada uno de ellos, sus tipos y la diferencia entre ellos.

La inteligencia artificial es un área de las ciencias computacionales que se encarga de buscar por medio de algoritmos la representación más cercana al conocimiento, en donde este incluye la toma de decisiones, el reconocimiento de objetos, la interpretación de ideas y así mismo es capaz de evolucionar para adaptarse en entornos multidisciplinarios.

3.1 REDES NEURONALES ARTIFICIALES

Las concepción de las redes neuronales surge de imitar por medio de modelos matemáticos de aproximación el comportamiento de las neuronas biológicas y su combinación para generar redes neuronales avanzadas.

Una red neuronal como en la **Figura 1** se compone de lo siguiente:

- X – Entradas del sistemas
- B – Bias
- W – Pesos de las Entradas
- FN – Funcion de Activacion
- Y – Salida del sistema





Figura 1 Estructura de una neurona artificial

La estructura de la **Figura 1** se comporta de tal manera que a cada entrada X se le asigna un peso W , en donde este peso es la importancia que tiene la entrada en el sistema para la toma de la decisión, el peso asignado se multiplica por su entrada, para posteriormente sumarse con B y obtener un valor que es introducido dentro de la función de activación FN , de las cuales pueden ser una función Gaussiana, Sigmoide, Trapezoidal, entre otras posibilidades, y finalmente obtener la señal de salida Y .

La selección de la función de activación se realiza al ejecutar el modelo y determinar cuál es la que mejor rendimiento tiene, este rendimiento se puede medir al momento de realizar lo que se denomina entrenamiento de la neurona.

Al hablar de entrenamiento nos referimos en plasmar la experiencia ya cuantificada que se tiene y dividirla en datos de entrenamiento y de verificación para saber que tan exacto queda el modelo.

Una vez que se tiene ya el modelo verificado se puede tomar como válido e introducir datos diferentes a los usados para entrenamiento y esperar una respuesta con un grado de exactitud y predicción acorde a la precisión buscada.



Capa de entrada

Capas ocultas

Capa de salida

Figura 2 Ejemplo de una red neuronal artificial

Cuando se tiene que tomar decisiones con una mayor complejidad se agrupan las neuronas para formar redes neuronales, en las cuales cada una de las neuronas se comporta de acuerdo con lo ya visto anteriormente y la salida de cada neurona es la entrada en la siguiente capa del sistema **Figura 2**.

3.2 APRENDIZAJE AUTOMÁTICO (MACHINE LEARNING)

Los algoritmos de Machine Learning, son algoritmos que se han desarrollado para encontrar patrones naturales en los datos que generan información y que ayuda a hacer mejores decisiones y predicciones. Los algoritmos de Machine Learning utilizan métodos computacionales para aprender información directamente de los datos sin relacionarse sobre ecuaciones predeterminadas como lo es un modelo. Se han encontrado aplicaciones, por ejemplo, para hacer decisiones críticas en el diagnóstico médico, transacciones de inventarios, pronóstico de carga energéticas y más. Las empresas comerciales en internet lo

utilizan para obtener información sobre el comportamiento de compra de sus clientes y hacer una predicción de lo que posiblemente se desea comprar. Un algoritmo de Machine Learning debe ser entrenado con una cantidad de datos adecuada y luego el resultado del aprendizaje se evalúa posteriormente para ver la precisión del aprendizaje y si el algoritmo utilizado es el correcto, esto se realiza en otros datos del mismo tipo pero que no se usaron en el entrenamiento.

Machine Learning utiliza 2 tipos de técnicas: aprendizaje supervisado y no supervisado, ver **Figura 3**. El aprendizaje supervisado es aquel que se entrena a partir de datos de entrada y salida conocidos, de tal manera que se pueda predecir datos futuros desconocidos. El aprendizaje no supervisado, encuentra patrones escondidos o estructuras intrínsecas en los datos de entrada. En la **Figura 3** se muestra las 2 tipos de técnicas que usa Machine Learning, supervisada y no supervisada con algunos de los algoritmos más utilizados. Estos algoritmos como han empezado a tener relevancia y aplicación se han ido desarrollando varias librerías en los lenguajes de programación más relevantes como son C++, Python y Matlab entre otros.




Figura 3: Tipos de técnicas de machine learning.

3.3 APRENDIZAJE PROFUNDO (DEEP LEARNING)

El aprendizaje profundo es un subcampo de la IA que se enfoca en crear modelos de redes neuronales grandes que sean capaces de hacer decisiones basadas en datos. Deep Learning está adaptada para situaciones donde los datos son complejos y los conjuntos de datos disponibles suelen ser enormes. Actualmente el aprendizaje es muy utilizado por empresas importantes como Facebook, que lo hace para analizar texto de conversaciones, otras empresas como Google, Baidu y Microsoft para búsqueda de imágenes. Los teléfonos inteligentes utilizan deep learning para reconocimiento de voz, y reconocimiento facial en las cámaras digitales. En el sector salud se está utilizando en el procesamiento médico de imágenes y el diagnóstico de condición de salud. El Deep Learning se emplea en los coches autónomos cuando hacen localización y mapeo, planeación de movimiento, dirección y percepción medioambiental así seguimiento del estado del controlador (Keller, 2019)

La diferencia entre el deep learning y el machine learning es cómo aprende cada algoritmo. El deep learning automatiza gran parte de la fase de extracción de características del proceso, lo que elimina parte de la intervención humana manual y permite el uso de conjuntos de datos más grandes. El deep learning se podría considerar como “machine learning escalable”. El machine learning tradicional, o "non-deep", depende más de la intervención humana para aprender. Los expertos humanos determinan la jerarquía de características para comprender las diferencias entre las entradas de datos, lo que por lo general requiere más datos estructurados para aprender (IBM, 2023).

4. MODELADO CINEMÁTICO EMPLEANDO REDES NEURONALES

Las redes neuronales se han empleado en diversos problemas de cinemática cuya solución es irresoluble analíticamente. En algunos mecanismos la cinemática directa se puede obtener

analíticamente, sin embargo, esto no es posible para la cinemática inversa, en otros mecanismos ocurre lo contrario. En este caso la cinemática directa se emplea para entrenar la red, la cual servirá de modelo de la cinemática inversa. En la literatura se pueden encontrar diversos trabajos en los que redes neuronales modelan la cinemática directa o inversa. En (Fouz y col., 2013) se estudian diversas arquitecturas de redes neuronales para resolver la cinemática inversa de un robot industrial de 5 grados de libertad. En (Duka, 2014) se estudia la precisión de las redes neuronales para calcular las posiciones deseadas en un robot plano de tres grados de libertad. En (Zubizarreta y col., 2015) y (Zubizarreta y col., 2018) se analiza el cálculo de la cinemática directa de un robot paralelo de tres grados de libertad con diferentes estructuras de redes neuronales, haciendo hincapié en la reducción del costo computacional, comparado con los métodos tradicionales como el algoritmo Newton-Raphson, también se menciona que el cálculo es mucho más rápido utilizando redes neuronales, sin afectar el error máximo.

El procedimiento que se sigue para definir la arquitectura de la red neuronal es el siguiente, considerando que se desea tener un modelo para la cinemática inversa:

1. Se obtiene el modelo cinemático directo de manera analítica. Este modelo se empleará posteriormente para entrenar la red. En muchos mecanismos es posible obtener el modelo analítico directo, pero no el inverso, y viceversa. Si no es posible obtener ningún modelo analítico podrían emplearse otros métodos numéricos, como Newton-Raphson para obtener el modelo que se empleara para entrenar la red.
2. Se define el espacio de trabajo y su discretización para obtener de cada punto, los datos de entrada y salida de la cinemática directa, para posteriormente emplearlos para entrenar la red neuronal que se empleara como nuestro modelo de cinemática inversa.
3. Para definir la arquitectura de la red neuronal es necesario encontrar el número de capas y neuronas que satisfacen los requerimientos de desempeño esperados. Este es un proceso iterativo en el que se varia de manera sistemática el número de neuronas de las capas ocultas y el número de capas ocultas. El objetivo es encontrar la

arquitectura con menor coste computacional que satisfaga los requerimientos de precisión y exactitud establecidos de acuerdo con la tarea que va a desempeñar el robot.

Los criterios de desempeño típicamente empleados para evaluar una arquitectura de red neuronal son:

- MSE, Error cuadrático medio.
- SSE, Suma residual de cuadrados.
- MAE, Error absoluto medio.
- Máximo error absoluto de aproximación.
- Tiempo de cómputo.
- Tiempo de entrenamiento.

Las arquitecturas de redes más empleadas para el modelado cinemático de mecanismos son el Perceptrón Multi Capa y las Redes de Base Radial, siendo el Perceptrón Multi Capa el que menor coste computacional tiene y es más adecuado para aplicaciones en tiempo real (Zubizarreta y col., 2018).

A continuación, se presenta el procedimiento que se siguió para desarrollar el modelo cinemático inverso basado en redes neuronales para una rueda híbrida de geometría variable.

4.1 MODELADO CINEMÁTICO DE UNA RUEDA TRANSFORMABLE

En la **Figura 4** se muestra una rueda HEISE 3RSRR, esta rueda es capaz de transformarse de una rueda circular convencional, a una rueda con extremidades, permitiendo tener las ventajas de cada modo de operación. El método de locomoción terrestre más eficiente son las ruedas circulares, mientras que las ruedas con extremidades se han empleado para aumentar la tracción de vehículos en terrenos complicados, además de que también tienen de

la capacidad de que tienen para subir escaleras. Los diseños de las ruedas HEISE fueron propuestos en (Moreno y col., 2020).




Figura 4 Rueda HEISE 3RSRR

4.1.1 MODELADO CINEMATICO DIRECTO

En la **Figura 5** se presenta el esquema cinemático de la rueda HEISE RSRR. El mecanismo consiste en una barra deslizante, un rin y una serie brazos extensibles, la cadena cinemática consiste en una secuencia de articulaciones como sigue: rotacional R_1 , esférica S , rotacional R_2 y rotacional R_3 . Cuando se actúa la articulación R_r se puede hacer girar la rueda. Por otro lado, para extender/flexionar las piernas se actúa la articulación prismática P_l .

Con los vectores presentados en el esquema cinemático de la i -ésima pierna del mecanismo, se pueden escribir las ecuaciones en lazo cerrado:

$$\mathbf{a}_i + \mathbf{r}_{2i} + \mathbf{p} = \mathbf{s}_i$$

$$\mathbf{b}_i + \mathbf{c}_i + \mathbf{r}_{1i} = \mathbf{s}_i$$

A partir de estas ecuaciones se resuelve la cinemática directa, conocido el valor de las variables articulares q_p y q_r se determina primero la postura de todos los eslabones, es decir conocido \mathbf{p} y \mathbf{r}_{1i} , se determinan las orientaciones de los vectores \mathbf{a}_i , \mathbf{b}_i y \mathbf{c}_i .




Figura 5 Esquema cinemático para la i -ésima pierna de una rueda RSRR

Finalmente, la posición de la punta de la i -ésima pierna es se obtiene la siguiente ecuación:

$$\mathbf{t}_i = [(l_T/L_2)\mathbf{R}_\vartheta + \mathbf{I}_2]^1 \mathbf{b}_i + {}^1\mathbf{c}_i + {}^1\mathbf{r}_{1i}$$

Donde l_T es la longitud del eje de tracción e \mathbf{I}_2 es la matriz identidad. \mathbf{R}_ϑ es la matriz de rotación alrededor del eje perpendicular al plano de movimiento del eje de tracción para un valor dado de ϑ .

El problema cinemático directo aunque implica ecuaciones trascendentes es relativamente fácil de resolver, sin embargo la cinemática directa presenta dificultades para resolverse analíticamente, además de que se ha encontrado que para una postura hay al menos 6 soluciones posibles de la cinemática directa. Por lo tanto, este problema se resolvió mediante el empleo de redes neuronales (Flores y col., 2021).

4.1.2 ENTRENAMIENTO DE LA RED NEURONAL

Para realizar el entrenamiento de redes neuronales se utiliza la herramienta de Matlab para Machine Learning, donde solo es necesario introducir las características de la red neuronal a entrenar y con un conjunto de datos para entrenamiento, en la figura 6 se muestra el conjunto de datos utilizados para el entrenamiento, obtenidos de la cinemática directa.




Figura 6 Datos de entrenamiento para las redes neuronales

El conjunto de datos que se utilizó fue creado utilizando la cinemática directa, obteniendo las coordenadas t_i para cada posición de los servomotores (q_p y q_r), posteriormente se entrenaron diversas topologías de redes neuronales para hacer una comparación de rendimiento, el resumen de las topologías utilizadas se muestra en la tabla 1.




Figura 7 Estructuras utilizadas en los dos grupos de redes neuronales

Tabla 1 Lista de topologías utilizadas, se muestra el número de capas ocultas y las neuronas por capa

Número de red neuronal	Red 1	Red 2	Red 3	Red 4	Red 5	Red 6	Red 7	Red 8	Red 9	Red 10	Red 11
Única red	1*[10]	1*[15]	1*[20]	2*[10]	1*[10] 1*[20]	2*[15]	1*[20] 1*[10]	2*[20]	3*[10]	3*[20]	3*[30]
Red doble Q_r	2*[10]	2*[20]	2*[30]	3*[10]	3*[20]	3*[30]	-	-	-	-	-
Red doble Q_p	1*[10]	1*[20]	1*[30]	2*[10]	2*[20]	3*[30]	-	-	-	-	-

Se utilizaron dos grupos de redes neuronales, uno de ellos maneja los datos de entrada y de salida en una sola red (Red única), en el otro grupo se hizo que cada salida fuera manejada por una red diferente (Red doble), ver **Figura 7**. En ambos casos se empleó un Perceptrón Multicapa, las capas ocultas se empleó como función de activación la tangente sigmoide, y para la capa de salida una función lineal.

Para pruebas se creó un conjunto de datos con 10000 puntos que fueron introducidos en la red neuronal, para posteriormente obtener el rendimiento midiendo el error absoluto medio para cada red neuronal.

Los resultados obtenidos se muestran en las **Figuras 8 y 9**, como se puede observar las redes pertenecientes al grupo 2 tuvieron un mejor rendimiento que las redes del grupo 1, esto debido a la topología utilizada (Una red neuronal para cada salida).

También se hizo una comparativa del tiempo empleado para entrenamiento, mostrado en la **Figuras 10 y 11**, se observa que en general, las redes pertenecientes al grupo 2 les tomo más tiempo de entrenamiento ya que se requiere entrenar 2 redes para cada caso.




Figura 8 Error absoluto medio de posición para el primer grupo de redes neuronales




Figura 9 Error absoluto medio de posición para el segundo grupo de redes neuronales




Figura 10 Tiempo empleado en entrenamiento para el primer grupo de redes neuronales




Figura 11 Tiempo empleado en entrenamiento para el segundo grupo de redes neuronales

En la **Figura 12** se muestra una simulación en la que se emplea una red neuronal entrenada para resolver la cinemática inversa. En la simulación se realiza una trayectoria circular.




Figura 12 Simulación de la cinemática directa

4.2 SOFTWARE PARA ENTRENAR REDES NEURONALES

El software Matlab ofrece varias librerías para diferentes aplicaciones, concretamente se utilizó la librería de machine learning, que permite crear y entrenar redes neuronales fácilmente a través de una interfaz gráfica, su desventaja es que algunos parámetros se manejan de manera predeterminada, sin embargo, a través de código es posible modificarlos, algunos de los parámetros que se pueden modificar son:

- Número de capas
- Número de neuronas por capa
- Algoritmo de entrenamiento
- Forma de cuantificación de error
- Medida del error objetivo
- Numero de iteraciones para el entrenamiento
- Pruebas de validación

Una vez que la red es creada y entrenada se dispone de algunas opciones para trabajar con ella. Una es la creación de una función para uso dentro del software Matlab, otra opción es exportar las matrices de la red neuronal para uso fuera del software con otras opciones de programación en diferentes lenguajes que puedan hacer operaciones con matrices. Para esto se guardan las matrices que pertenecen a la red neuronal en un archivo de datos (.mat), que luego se importan en otro lenguaje, por ejemplo, Python, dentro de este lenguaje de programación se pueden encontrar librerías para las operaciones con matrices, además de la librería para el manejo de archivos con extensión (.mat). Una vez que las matrices son importadas, será necesario hacer la codificación con las operaciones requeridas para hacer funcionar la red neuronal (implementar las funciones ReLU, tangente-sigmoide, etc.), una vez concluido esto la función de la red neuronal está lista puede emplearse, por ejemplo, en el algoritmo de control programado en la computadora un robot.

5. CONCLUSIONES.

La simulación, diseño, planificación de trayectorias y control de mecanismos robóticos requieren del modelado cinemático. A medida que han surgido nuevas arquitecturas de robots cuya cinemática no es resoluble analíticamente, se han propuesto modelos basados en métodos computacionales. Este artículo proporciona una explicación didáctica de los conceptos relacionados con el modelado cinemático de mecanismos robóticos utilizando redes neuronales. Primero, se presentó una introducción al modelado cinemático de robots, seguido de una revisión de las técnicas propuestas en la literatura científica. Luego, se ofrece una breve explicación de los términos relacionados con la inteligencia artificial, el machine learning y las redes neuronales. Después, se describieron algunos trabajos relevantes en el modelado cinemático mediante redes neuronales, incluyendo los procedimientos para el diseño de arquitecturas y los criterios de desempeño principales que deben considerarse. Finalmente, se presenta un ejemplo de aplicación de las redes neuronales en el modelado de una rueda híbrida de geometría variable, junto con una descripción del software utilizado para ello.

El modelo de cinemática inversa basado en redes neuronales, presentado en este trabajo, será útil para controlar una Rueda HEISE con una sola extremidad, la cual se podría transformar en una rueda o una pierna según los requerimientos de la tarea. Con el modelo cinemático inverso se podrán determinar los movimientos requeridos en los motores dado un patrón de marcha para el extremo del eslabón de tracción.

Encontrar la mejor arquitectura de red neuronal para el modelo cinemático, es un proceso iterativo, en el que se varía el número de capas y el número de neuronas para encontrar aquella red que satisfaga las necesidades en términos de error admisible y tiempo de cómputo.

REFERENCIAS BIBLIOGRÁFICAS

Baron, L. & Angeles, J. (2000). The direct kinematics of parallel manipulators under joint-sensor redundancy. *IEEE Trans Robot Autom* 16(1):12–19.

Duka, A. (2014). Neural Network based Inverse Kinematics Solution for Trajectory Tracking of a Robotic Arm, *Procedia Technology*, Volume 12, Pages 20-27, ISSN 2212-0173, <https://doi.org/10.1016/j.protcy.2013.12.451>.

Flores J.F. , H. A. Moreno, I. G. Carrera, M. A. Garcia & R. G. Adan, (2021), Inverse Kinematics of a RSRR HeIse wheel using Neural Networks, 2021 XXIII Robotics Mexican Congress (ComRob), Tijuana, Mexico, 2021, pp. 19-24, doi: 10.1109/ComRob53312.2021.9628728.

Fouz, M., Bayoumy & A. Rezek, S. (2013). Neural network based inverse kinematics for a robotic manipulator. 5th International Conference on Aerospace Sciences & Aviation Technology, ASAT - 15 May, 2013, Cairo, Egypt.

IBM (2023). Inteligencia Artificial, url: <https://www.ibm.com/mx-es/topics/artificial-intelligence>, acceso online: 6 de Mayo 2023.

Kelleher, J. (2019). *Deep Learning*, MIT Press 2019, ISBN: 026235490X, 9780262354905.

Moreno, H., Saltarén, R, Carrera, I., Puglisi, L. & Aracil, R. (2012) , Índices de Desempeño de Robots Manipuladores: una revisión del Estado del Arte, *Revista Iberoamericana de Automática e Informática industrial*, 9(2), pp. 111–122. doi: 10.1016/j.riai.2012.02.005.

Moreno, H., Carrera, I., Pámanes , J. A., & Baca, J. (2018). Ruedas HeIse: Familia de Mecanismos para Implementar Ruedas Híbridas de Geometría Variable. *Revista Iberoamericana De Automática E Informática Industrial*, 15(4), 427–438. <https://doi.org/10.4995/riai.2017.8798>

Puglisi, L., Saltaren, R., García, C., Cárdenas, P. & Moreno, H. (2017). Implementation of a generic constraint function to solve the direct kinematics of parallel manipulators using Newton-Raphson approach. *Control Engineering and Applied Informatics*. 19: 71-79.

Sadjadian, H. & Taghirad, H.. (2005). Comparison of Different Methods for Computing the Forward Kinematics of a Redundant Parallel Manipulator. *Journal of Intelligent and Robotic Systems*. 44: 225-246. 10.1007/s10846-005-9006-4.

Zubizarreta, A., Larrea, M., Irigoyen, E., Cabanes, I. & Portillo, E. (2018), Real time direct kinematic problem computation of the 3PRS robot using neural networks, *Neurocomputing*, Volume 271, Pages 104-114, ISSN 0925-2312, <https://doi.org/10.1016/j.neucom.2017.02.098>.

Zubizarreta, A., Larrea, M., Irigoyen, E. & Cabanes, I. (2015). Real Time Parallel Robot Direct Kinematic Problem Computation Using Neural Networks. 10.1007/978-3-319-19719-7_25.