

SISTEMAS NEURO-SIMBÓLICOS: CERRANDO LA BRECHA ENTRE EL APRENDIZAJE BASADO EN DATOS Y EL RAZONAMIENTO LÓGICO

Márquez Gutiérrez, Pedro Rafael; García Mata, Carmen Leticia;
Robledo Vega, Isidro
Tecnológico Nacional de México/Tecnológico de Chihuahua
División de Estudios de Posgrado e Investigación
Avenida Tecnológico #2909, Chihuahua, Chih., México, CP 31310
Tel +52(614) 201-200, Fax +52(614) 413-5187
{pedro.mg, carmen.gm, isidro.rv}@chihuahua.tecnm.mx

RESUMEN.

El aprendizaje y razonamiento neuronal-simbólico (NSLR) es un campo interdisciplinario emergente que tiene como objetivo integrar las fortalezas de las redes neuronales y el razonamiento simbólico para construir sistemas de IA más robustos, interpretables y flexibles. Este artículo revisa el estado actual de NSLR, discutiendo los enfoques clave, los desafíos y las direcciones futuras. Al combinar las capacidades de reconocimiento de patrones del aprendizaje profundo con la expresividad lógica de la IA simbólica, NSLR busca superar las limitaciones inherentes a cada paradigma cuando se usa de forma independiente. Este enfoque híbrido tiene el potencial de avanzar significativamente en el desarrollo de sistemas de IA capaces de razonar, aprender de menos ejemplos y proporcionar decisiones explicables.

Palabras Clave: Aprendizaje neuronal-simbólico (NSLR), redes neuronales, razonamiento simbólico, IA robusta, interpretabilidad, reconocimiento de patrones, aprendizaje profundo, IA simbólica, enfoque híbrido, razonamiento y decisiones explicables.

ABSTRACT.

Neural-symbolic learning and reasoning (NSLR) is an emerging interdisciplinary field that aims to integrate the strengths of neural networks and symbolic reasoning to build more robust, interpretable, and flexible AI systems. This article reviews the current state of NSLR, discussing key approaches, challenges, and future directions. By combining the pattern recognition capabilities of deep learning with the logical expressiveness of symbolic AI, NSLR seeks to overcome the limitations inherent in each paradigm when used independently. This hybrid approach has the potential to significantly advance the development of AI systems capable of reasoning, learning from fewer examples, and providing explainable decisions.

Keywords: Neural-symbolic learning (NSLR), neural networks, symbolic reasoning, robust AI, interpretability, pattern recognition, deep learning, symbolic AI, hybrid approach, reasoning, and explainable decisions.

1. INTRODUCCIÓN

La Inteligencia Artificial (IA) ha sido testigo de avances significativos en los últimos años, impulsados en gran medida por el éxito de las técnicas de aprendizaje profundo. Estos enfoques han logrado resultados de vanguardia en varios

dominios, incluida la visión por computadora, el procesamiento del lenguaje natural y los juegos, Figura 1.




Figura 1. Dominio de la IA.

<https://www2.deloitte.com/cl/es/pages/technology/articles/parte-1-inteligencia-artificial-definida.html>

Sin embargo, a pesar de su éxito, los modelos de aprendizaje profundo suelen ser criticados por su falta de interpretabilidad y capacidad de razonamiento. Por otro lado, la IA simbólica, que se basa en sistemas basados en inferencia lógica, sobresale en tareas que requieren razonamiento, pero tiene dificultades con la escalabilidad y el aprendizaje de los datos sin procesar.

El aprendizaje y razonamiento neuro-simbólico (NSLR) es un área de investigación interdisciplinaria que tiene como objetivo cerrar esta brecha combinando las fortalezas de ambos paradigmas. Este documento proporciona una descripción general completa de NSLR, destacando su importancia, metodologías clave y aplicaciones potenciales. También se

discuten los desafíos que deben abordarse para aprovechar todo el potencial de NSLR, Figura 2.




Figura 2. Computación Neuro-Simbólica.

<https://www.linkedin.com/pulse/computaci%C3%B3n-neuro-simb%C3%B3lica-un-cambio-de-paradigma-en-gonz%C3%A1lez-disla-lexse/>

2. ANTECEDENTES Y MOTIVACIÓN

2.1. Limitaciones de los enfoques puros.

Las limitaciones de los enfoques puramente neuronales o simbólicos han motivado la exploración de métodos híbridos. Los modelos de aprendizaje profundo son poderosos para extraer características de los datos y generalizar entre tareas, pero a menudo operan como "cajas negras", lo que dificulta la comprensión de sus procesos de toma de decisiones [7]. Además, estos modelos suelen requerir grandes cantidades de datos etiquetados y luchan contra tareas que requieren un razonamiento de sentido común [4], Figura 3.




Figura 3. M.C. Escher, **Relatividad**, 1953.

<https://historia-arte.com/obras/relatividad-de-escher>

Por el contrario, los sistemas de IA simbólica se basan en enunciados y lógica matemática, que permiten un razonamiento y una toma de decisiones transparentes. Estos sistemas pueden realizar razonamientos complejos y son inherentemente explicables. Sin embargo, los enfoques simbólicos son menos eficaces cuando se trata de datos no estructurados y no se adaptan bien a conjuntos de datos grandes y ruidosos [1], Figura 4.



Figura 4. Tipos de Datos

<https://forum.huawei.com/enterprise/es/datos-estructurados-y-datos-no-estructurados/thread/667228583078281216-667212895836057600>

NSLR tiene como objetivo combinar las capacidades de aprendizaje basadas en datos de las redes neuronales con el razonamiento estructurado de los sistemas simbólicos, lo que lleva a una IA que puede aprender de los datos y razonar sobre ellos de una manera similar a la humana.

2.2. Clases de Lógicas.

En la implementación de sistemas inteligentes, se utilizan diferentes clases de lógicas para abordar diversos problemas y situaciones. Aquí mencionamos algunas de las principales lógicas empleadas [11]:

1. **Lógica Proposicional.** Se basa en proposiciones que pueden ser verdaderas o falsas, utilizando operadores como AND, OR, y NOT. Es el nivel más básico de lógica y se utiliza principalmente en sistemas de control y razonamiento simple.
2. **Lógica de Primer Orden (Lógica de Predicados).** Permite trabajar con relaciones y cuantificadores (como "todos" o "algunos"), haciendo posible representar estructuras más complejas como objetos, sus propiedades, y las relaciones entre ellos. Es ampliamente usada en la inteligencia artificial simbólica y sistemas expertos.
3. **Lógica Difusa.** A diferencia de la lógica clásica, que solo admite valores de verdadero o falso, la lógica difusa permite grados de verdad. Es útil en sistemas inteligentes que necesitan manejar incertidumbre o información incompleta, como los sistemas de control difuso o en la toma de decisiones.
4. **Lógica Difusa.** A diferencia de la lógica clásica, que solo admite valores de verdadero o falso, la lógica difusa permite grados de verdad. Es útil en sistemas inteligentes que necesitan manejar incertidumbre o información incompleta, como los sistemas de control difuso o en la toma de decisiones.

5. **Lógica Temporal.** Se enfoca en el razonamiento sobre el tiempo y el orden de eventos. Es utilizada para modelar y verificar sistemas que dependen de la secuencia de eventos o procesos, como los sistemas de control en tiempo real.
 6. **Lógica Modal.** Introduce nociones de posibilidad y necesidad, permitiendo expresar afirmaciones sobre lo que es posible o necesario en un sistema. Se utiliza en sistemas inteligentes para modelar conocimiento, creencias, y razonamiento sobre incertidumbre.
 7. **Lógica Descriptiva.** Es la base de muchos lenguajes de representación del conocimiento, como OWL (Web Ontology Language). Se utiliza en sistemas que necesitan organizar y razonar sobre grandes volúmenes de conocimiento estructurado, como en sistemas de información y web semánticas.
 8. **Lógica Inductiva.** En lugar de partir de axiomas para llegar a conclusiones, esta lógica generaliza a partir de ejemplos específicos. Es crucial en el aprendizaje automático, donde el sistema induce reglas o patrones a partir de datos.
 9. **Lógica de Probabilidades.** Combina la lógica con probabilidades para manejar incertidumbre y razonamiento probabilístico. Es utilizada en redes bayesianas y otros sistemas que necesitan hacer inferencias bajo incertidumbre, muy común en sistemas de diagnóstico y predicción.
 10. **Lógica No Monótona.** Permite la retractación de conclusiones cuando se dispone de nueva información. A diferencia de las lógicas clásicas, en las que las conclusiones siempre son verdaderas si las premisas son verdaderas, esta lógica permite el cambio de conclusiones en base a nueva evidencia, lo cual es útil en sistemas que evolucionan con el tiempo.
 11. **Lógica Deontica.** Se ocupa del razonamiento sobre normas, obligaciones y permisos. Es útil en sistemas inteligentes que necesitan tomar decisiones éticas o legales, como sistemas de toma de decisiones automáticas en el campo jurídico o en la ética de la IA.
- Estas lógicas permiten a los sistemas inteligentes tomar decisiones complejas, adaptarse a diferentes contextos y manejar incertidumbre, lo que las hace esenciales en aplicaciones como robótica, sistemas expertos, IA simbólica, y razonamiento basado en conocimiento.
- ### 2.3. Clases de Redes Neuronales.
- Las redes neuronales se utilizan ampliamente en la implementación de sistemas inteligentes debido a su capacidad para aprender y generalizar a partir de datos. Existen diferentes tipos de redes neuronales, cada una diseñada para abordar problemas específicos. Se presentan algunas de las principales [12, 13]:
1. **Redes Neuronales Feedforward (FNN).** Son el tipo más básico de red neuronal, donde la información fluye en una sola dirección, desde la capa de entrada hacia la capa de salida, sin ciclos ni retroalimentación. Son útiles para problemas de clasificación y regresión.
 2. **Redes Neuronales Convolucionales (CNN).** Diseñadas principalmente para procesar datos con estructura de cuadrícula, como imágenes. Las CNN utilizan capas convolucionales para detectar patrones locales y características en imágenes. Son ampliamente utilizadas en reconocimiento de imágenes, visión por computadora y análisis de video.
 3. **Redes Neuronales Recurrentes (RNN).** Estas redes tienen conexiones que permiten que la salida de una neurona se retroalimente como entrada en la misma capa o en capas anteriores. Son ideales para el procesamiento de datos secuenciales, como en el análisis de series temporales, procesamiento del lenguaje natural (NLP), y traducción automática.
 4. **Redes de Memoria a Largo y Corto Plazo (LSTM).** Son un tipo de RNN diseñadas para mitigar el problema del "gradiente desvanecido". Los LSTM pueden mantener información relevante durante largos periodos, por lo que son muy efectivas en tareas que requieren memoria a largo plazo, como traducción automática y predicción de secuencias.
 5. **Redes Neuronales de Atención y Transformadores.** Las arquitecturas de atención y los transformadores permiten a las redes neuronales enfocarse en partes específicas de los datos de entrada, mejorando la eficiencia en tareas de procesamiento del lenguaje natural (NLP). Los transformadores, como el modelo BERT y GPT, se han vuelto el estándar para tareas de NLP, como generación de texto y clasificación de secuencias.
 6. **Redes Generativas Antagónicas (GAN).** Consisten en dos redes que compiten entre sí: una red generadora que crea ejemplos falsos y una red discriminadora que intenta distinguir entre ejemplos reales y falsos. Las GAN se utilizan principalmente en la generación de imágenes, videos, y modelos 3D, así como en la mejora de imágenes de baja resolución.
 7. **Autoencoders.** Estas redes están diseñadas para aprender una representación comprimida de los datos de entrada. Los *autoencoders* son útiles para reducción de dimensionalidad, detección de anomalías y aprendizaje no supervisado. Son utilizados en sistemas de recomendación y para la eliminación de ruido en imágenes y señales.
 8. **Redes Neuronales Boltzmann (RBM) y Redes Creencias Profundas (DBN).** Las RBM son redes neuronales estocásticas que se utilizan principalmente para modelar distribuciones probabilísticas y extracción de características. Las DBN, que consisten en múltiples

capas de RBM, se utilizan en reconocimiento de patrones, generación de imágenes y aprendizaje de características profundas.

9. **Redes Neuronales Espaciotemporales.** Estas redes combinan características de las RNN y CNN para procesar tanto información espacial como temporal. Son usadas en aplicaciones que requieren la comprensión de secuencias de imágenes o videos, como la predicción de movimientos y actividades humanas.
10. **Redes Neuronales de Grafos (GNN).** Diseñadas para trabajar con datos que tienen estructura de grafo, como redes sociales o estructuras moleculares. Las GNN se utilizan para tareas como clasificación de nodos, predicción de enlaces y recomendaciones.

Estas redes neuronales proporcionan diferentes enfoques para resolver una variedad de problemas, desde visión por computadora hasta procesamiento del lenguaje natural, generación de contenido, y más, cada una adaptándose a las necesidades del sistema inteligente.

3. ENFOQUES DE INTEGRACIÓN NEURONAL-SIMBÓLICA.

Se han propuesto varios enfoques para integrar las redes neuronales con el razonamiento simbólico. A continuación, repasamos algunos de los métodos más destacados:

3.1. Sistemas Neuro-Simbólicos.

Los sistemas neuronales-simbólicos son arquitecturas que integran redes neuronales con representaciones simbólicas, como programas lógicos o grafos de conocimiento. Un enfoque consiste en codificar el conocimiento simbólico como restricciones dentro de una red neuronal, asegurando que los resultados de la red se adhieran a ciertas reglas lógicas [2]. Esto permite que la red mantenga la expresividad del razonamiento simbólico mientras se beneficia de la flexibilidad de los modelos neuronales.

3.2. Programación lógica diferenciable

La programación lógica diferenciable implica incorporar el razonamiento lógico en redes neuronales, donde las operaciones lógicas se transforman en funciones diferenciables. Por ejemplo, [8] proponen utilizar *TensorLog*, un marco que permite el aprendizaje diferenciable de extremo a extremo a través de bases de conocimiento. Este enfoque permite la integración de la inferencia lógica directamente en el proceso de aprendizaje, lo que permite que el modelo aprenda y razona simultáneamente.

3.3. Aprendices de Conceptos Neuro-Simbólicos

Los aprendices de conceptos neurosimbólicos combinan redes neuronales con razonamiento simbólico para el aprendizaje de conceptos y la generalización. Por ejemplo, [6] introdujeron el Aprendiz de Conceptos Neuro-Simbólicos (NS-CL), que aprende conceptos visuales e interpreta imágenes a través de una

combinación de percepción neuronal y razonamiento simbólico. Este enfoque aprovecha las fortalezas de ambos paradigmas para lograr un aprendizaje más efectivo e interpretable.

3.4. Grafo, redes neuronales y lógica

Las redes neuronales de grafos (GNN) se han utilizado para incorporar el razonamiento simbólico en las arquitecturas neuronales. Por ejemplo, en [9] propusieron un método para integrar la lógica de primer orden con las GNN para realizar un razonamiento lógico sobre datos estructurados en grafos. Este enfoque permite a la red capturar dependencias complejas y razonar sobre las relaciones de forma estructurada.

4. APLICACIONES DEL APRENDIZAJE Y RAZONAMIENTO NEURO-SIMBÓLICO

NSLR ha demostrado ser prometedor en una variedad de aplicaciones, que incluyen:

4.1. Procesamiento del lenguaje natural (PLN)

En NLP, NSLR se ha utilizado para mejorar tareas como la traducción automática, el análisis de sentimientos y la respuesta a preguntas mediante la incorporación de restricciones lógicas y capacidades de razonamiento en modelos neuronales [5]. Esta integración ayuda a mitigar la fragilidad de los modelos neuronales en el manejo de tareas lingüísticas ambiguas o complejas.

4.2. Visión y percepción

En visión artificial, los enfoques NSLR se han aplicado a tareas como la comprensión de escenas y el reconocimiento de objetos, donde la capacidad de razonar sobre las relaciones y la información contextual es crucial [10]. Al combinar la percepción neuronal con el razonamiento simbólico, estos sistemas pueden lograr resultados más precisos y explicables.

4.3. Sistemas autónomos

Los sistemas autónomos, como los coches autónomos y los robots, se benefician de NSLR al integrar el procesamiento de datos sensoriales con la toma de decisiones lógica. Esta combinación permite que el sistema no solo perciba el entorno, sino que también razona sobre las acciones y sus consecuencias de manera transparente y confiable [3].

5. DESAFÍOS Y DIRECCIONES FUTURAS

Si bien NSLR es muy prometedor, se deben abordar varios desafíos para avanzar en el campo:

5.1. Escalabilidad y eficiencia

La integración de redes neuronales con razonamiento simbólico puede ser computacionalmente costosa, especialmente cuando se trata de datos a gran escala y reglas lógicas complejas. Se necesita investigación para desarrollar algoritmos y arquitecturas más eficientes que puedan escalar a aplicaciones del mundo real.

5.2. Explicabilidad e interpretabilidad

Uno de los principales objetivos de NSLR es mejorar la interpretabilidad de los sistemas de IA. Sin embargo, lograr una integración sin fisuras en la que el proceso de razonamiento sea potente y totalmente explicable sigue siendo un reto importante.

5.3. Generalización y robustez

Los sistemas NSLR deben ser capaces de generalizar a partir de datos limitados y manejar entradas ruidosas o ambiguas. Se requiere más investigación para mejorar la robustez de estos sistemas y garantizar que puedan funcionar de manera efectiva en diversos entornos.

5.4. Marcos de aprendizaje híbridos

El desarrollo de marcos de aprendizaje híbridos que puedan integrar sin problemas componentes simbólicos y neuronales es un área crítica de investigación futura. Dichos marcos deben permitir combinaciones flexibles de aprendizaje y razonamiento, manteniendo al mismo tiempo la eficiencia y la interpretabilidad.

6. PRUEBA DE CONCEPTO

Implementar una aplicación neuro-simbólica en Python implica integrar las capacidades de aprendizaje profundo con el razonamiento lógico simbólico. A continuación, se muestra un ejemplo básico donde se usa una red neuronal para el reconocimiento de patrones y una capa lógica simbólica para realizar inferencias.

Paso 1: Instalación de las librerías necesarias:

```
pip install tensorflow sympy numpy
```

Paso 2: Definir la red neuronal para reconocimiento de patrones

```
import tensorflow as tf
from tensorflow.keras import layers, models

# Red neuronal simple
def create_neural_network():
    model = models.Sequential()
    model.add(layers.Dense(32, activation='relu', input_shape=(10,))) # 10 características
    model.add(layers.Dense(16, activation='relu'))
    model.add(layers.Dense(3, activation='softmax')) # 3 clases de salida
    model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy'])
    return model

# Crear el modelo
model = create_neural_network()

# Simular datos de entrada y etiquetas
import numpy as np
X_train = np.random.random((100, 10)) # 100 muestras de entrenamiento
y_train = tf.keras.utils.to_categorical(np.random.randint(3, size=(100, 1)), num_classes=3)

# Entrenar el modelo
model.fit(X_train, y_train, epochs=5)
```

Paso 3: Implementación del razonamiento lógico

```
from sympy import symbols, Implies

# Definir las variables simbólicas
A, B = symbols('A B')

# Definir la regla lógica: Si la clase es 1, entonces A es verdadero
rule = Implies(B, A) # B representa la clase 1

# Evaluar la regla con los resultados de la red neuronal
def symbolic_reasoning(prediction):
    if prediction == 1: # Simulamos que la red predice la clase 1
        return rule.subs(B, True) # Sustituimos B por True (clase 1)
    else:
        return rule.subs(B, False) # Sustituimos B por False

# Simular una predicción de la red neuronal
prediction = np.argmax(model.predict(np.random.random((1, 10))))
logical_inference = symbolic_reasoning(prediction)
print(f"Predicción: {prediction}, Inferencia lógica: {logical_inference}")
```

Paso 4: Integración neuro-simbólica

```
Epoch 1/5
4/4 ————— 0s 3ms/step - accuracy: 0.3360 - loss: 1.1721
Epoch 2/5
4/4 ————— 0s 1ms/step - accuracy: 0.3546 - loss: 1.1280
Epoch 3/5
4/4 ————— 0s 1ms/step - accuracy: 0.3153 - loss: 1.1266
Epoch 4/5
4/4 ————— 0s 1ms/step - accuracy: 0.3855 - loss: 1.1098
Epoch 5/5
4/4 ————— 0s 1ms/step - accuracy: 0.3680 - loss: 1.1076
1/1 ————— 0s 30ms/step
Predicción: 1, Inferencia lógica: A
```

La red neuronal clasifica las entradas en una de varias clases. La capa simbólica luego toma esta predicción y aplica reglas lógicas definidas, permitiendo que el sistema realice inferencias basadas en conocimiento explícito.

6.1. Expansión de la idea

- Este es un ejemplo muy básico. En aplicaciones no académicas de sistemas neuro-simbólicos, se puede usar un motor lógico más avanzado para manejar reglas complejas y aplicar razonamiento de alto nivel.
- También es posible usar arquitecturas como Differentiable Neural Computers (DNC) que integran directamente el razonamiento simbólico en la red neuronal, Figura 5.

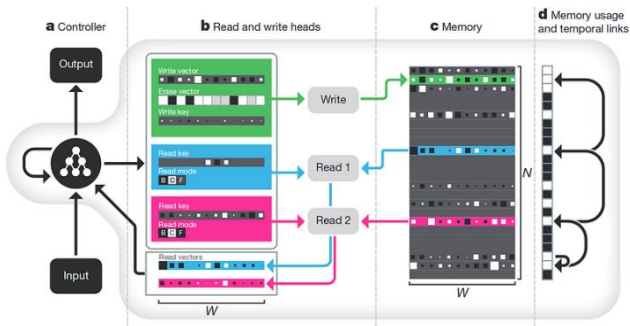


Figura 5. Differentiable Neural Computer

<https://towardsdatascience.com/rps-intro-to-differentiable-neural-computers-e6640b5aa73a>

6.2. Posibles mejoras:

- Usar redes neuronales más complejas como RNN o *transformers* para tareas de secuencias, Figura 6.
- Integrar ontologías y sistemas de razonamiento formal.
- Implementar aprendizaje retropropagado en las capas simbólicas para hacerlas parte del aprendizaje automático.

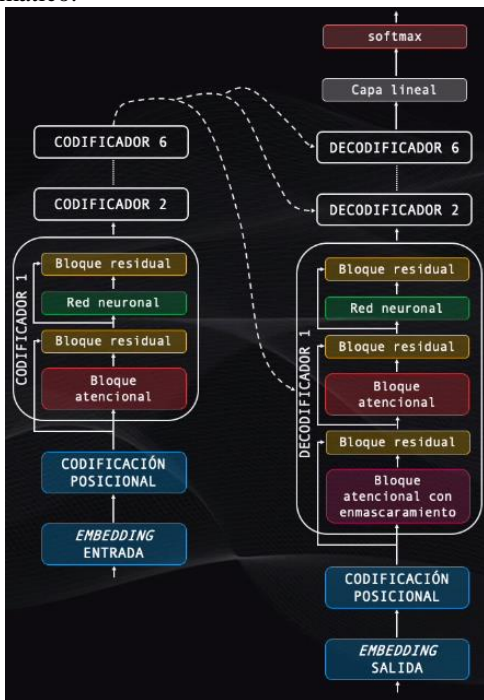


Figura 6. Redes Transformers

<https://www.codificandobits.com/blog/redes-transformer/>

El enfoque híbrido es poderoso en tareas que requieren tanto el reconocimiento de patrones (aprendizaje neuronal) como la toma de decisiones basadas en reglas y conocimientos estructurados (razonamiento simbólico).

7. CONCLUSIÓN

El aprendizaje y el razonamiento neuro-simbólico representan una dirección prometedora para el avance de los sistemas de IA que son a la vez potentes e interpretables. Al combinar las fortalezas de las redes neuronales y la IA simbólica, NSLR tiene el potencial de abordar muchas de las limitaciones actuales de cada paradigma. Si bien persisten desafíos significativos, la investigación en curso está avanzando hacia sistemas de IA más escalables, robustos y explicables. El futuro de NSLR radica en su capacidad para crear una IA que pueda aprender de los datos, razonar de manera lógica y proporcionar decisiones transparentes y confiables.

Este artículo proporciona una visión general de NSLR, discutiendo sus motivaciones, metodologías, aplicaciones y desafíos, con referencias a los avances recientes en el campo. A medida que avanza la investigación, se espera que NSLR desempeñe un papel crucial en el desarrollo de sistemas de IA que sean potentes e interpretables, lo que podría transformar varios dominios de la IA.

8. REFERENCIAS

- [1] Besold, T. R., Garcez, A. S., Bader, S., Bowman, H., Domingos, P., Hitzler, P., ... & Völker, J. (2017). Neural-symbolic learning and reasoning: A survey and interpretation. *Frontiers in Artificial Intelligence and Applications*, 305, 1-64.
- [2] Garcez, A. S., Gori, M., Lamb, L. C., Serafini, L., Spranger, M., & Tran, S. N. (2015). Neural-symbolic computing: An effective methodology for principled integration of machine learning and reasoning. *FLAIRS Conference*.
- [3] Garnelo, M., Arulkumaran, K., & Shanahan, M. (2019). Towards deep symbolic reinforcement learning. *arXiv preprint arXiv:1905.06060*.
- [4] Lake, B. M., Ullman, T. D., Tenenbaum, J. B., & Gershman, S. J. (2017). Building machines that learn and think like people. *Behavioral and Brain Sciences*, 40.
- [5] Liang, P., Potts, C., & Jia, Y. (2017). A compositional semantics for natural language and programming languages. *arXiv preprint arXiv:1704.06278*.
- [6] Mao, J., Gan, C., Kohli, P., Tenenbaum, J. B., & Wu, J. (2019). The neuro-symbolic concept learner: Interpreting scenes, words, and sentences from natural supervision. *International Conference on Learning Representations*.
- [7] Marcus, G. (2018). Deep learning: A critical appraisal. *arXiv preprint arXiv:1801.00631*.
- [8] Rocktäschel, T., & Riedel, S. (2017). End-to-end differentiable proving. *Advances in Neural Information Processing Systems*, 30.
- [9] Xu, K., Hu, W., Leskovec, J., & Jegelka, S. (2018). How powerful are graph neural networks? *International Conference on Learning Representations*.
- [10] Yi, K., Wu, J., Gan, C., Torralba, A., Kohli, P., & Tenenbaum, J. B. (2020). Neural-symbolic VQA: Disentangling reasoning from vision and language understanding. *Advances in Neural Information Processing Systems*, 33.
- [11] Letzen, Diego (2020), Las lógicas y los lógicos. *Análisis Filosófico* 40 (Especial): 133-157. ISSN 1851-9636. doi:10.36446/af.2020.430.
- [12] Matich, Damián Jorge (2001), *Redes Neuronales: Conceptos Básicos y Aplicaciones* (PDF). Buenos Aires, Argentina.
- [13] Andrew Ng, *Machine Learning Yearning*, Free ebook, <https://info.deeplearning.ai/machine-learning-yearning-book>, consultado el 7 de Agosto de 2024.