

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Resumen y Perspectivas

Eduardo Morales y Hugo Jair Escalante

INAOE

Contenido

- 1 Introducción
- 2 Técnicas y tópicos no vistos
 - Curriculum Learning
 - Lifelong ML
 - Sesgo en los datos
 - Graph Networks
 - Topic modeling
 - Neuro-Simbólico
- 3 Perspectivas y Retos
- 4 Super-Inteligencia

Introducción

Técnicas y tópicos no vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y Retos

Super-Inteligencia

Resumen

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

- En el curso vimos varias de las técnicas recientes o no vistas en los otros cursos de Aprendizaje Computacional
- Existen técnicas que no vimos, y tópicos que no se trataron, por ejemplo, aprendizaje paramétrico basado en máxima verosimilitud, máquinas de Kernel, estimación bayesiana, *stream-learning*, *BigData*, etc.

Curriculum Learning

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

- Se sabe que humanos y animales aprenden mejor cuando ejemplos son presentados de manera organizada y siguiendo un orden (de lo sencillo a lo complejo)
- CL: Al presentar ejemplos de entrenamiento a máquinas de aprendizaje de manera organizada, es posible mejorar la rapidez de convergencia y capacidades de generalización

Y. Bengio et al. Curriculum learning. Proc. of ICML, 41–48, 2009.

Curriculum Learning

Ejemplo: Aprendizaje de representaciones distribuidas de términos vía CL





Figura: Aprendizaje de *embeddings* usando CL.

Y. Bengio et al. Curriculum learning. Proc. of ICML, 41–48, 2009.

Curriculum Learning

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Problemas:

- ¿Cómo definir la currícula?
- ¿Cómo realizar el aprendizaje?

Y. Bengio et al. Curriculum learning. Proc. of ICML, 41–48, 2009.

Lifelong ML

Métodos de aprendizaje (sistemas) que pueden aprender muchas tareas de uno o varios dominios a través de su tiempo *de vida*

- Retención secuencial de conocimiento
- Transferencia selectiva de dicho conocimiento cuando se aprende otra tarea
- Enfoque de sistemas



DuckDuckGo

Lifelong ML

Objetivo: Generar hipótesis o políticas más exactas!




Figura: A framework for LML.

Daniel L. Silver, Qiang Yang, Lianghao Li. Lifelong Machine Learning Systems: Beyond Learning Algorithms. 2013 AAAI Spring Symposium Series

Wei-Wei Tu, Hugo Jair Escalante, Isabelle Guyon, Daniel L. Silver, Evelyne Viegas, Yuqiang Chen. Autonomous Lifelong Machine Learning with Drift. NIPS Competition 2018.

Sesgo en los datos

- Métodos de aprendizaje están inherentemente sesgados a los datos en que fueron entrenados!
- Existe una preocupación creciente en el sesgo de los datos y cómo evitarlo (más ahora que ML es tan popular)




Figura: Artículos publicados en equidad.

https://www.youtube.com/watch?v=fMym_BKWQzk

Sesgo en los datos

- Algunos problemas:
 - Denigración, estereotipos, no - representación de minorías

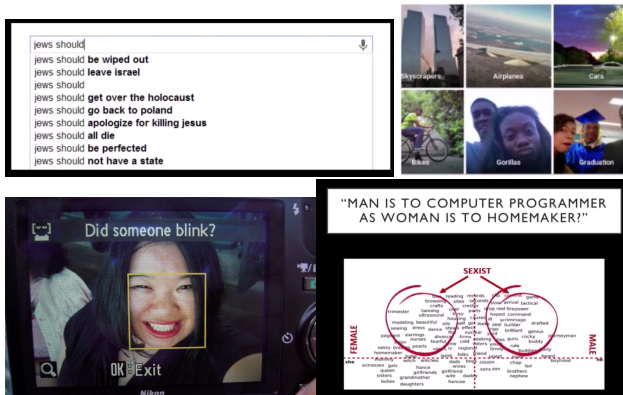


Figura: Ejemplos.

Sesgo en los datos

- Algunos problemas:
 - Denigración, estereotipos, no - representación de minorías




Figura: Ejemplos.

<https://www.technologyreview.com/2019/04/30/135556/how-a-google-street-view-image-of-your-house-predicts-your-risk-of-a-car-accident/>

Sesgo en los datos

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia


¿Cómo lidiar con el problema? **FAT**

- *Fairness*: ¿Quién se beneficia del sistema? ¿A quién puede dañar?
- *Fairness forensics*
- Multidisciplinariedad real
- Ética en clasificación

https://www.youtube.com/watch?v=fMym_BKWQzk

Graph networks

- Redes neuronales que procesan grafos, las entradas son grafos y las salidas pueden ser grafos, etiquetas para grafos completos, etiquetas para nodos o aristas
- Se enfocan en resolver problemas de predicción estructurada en entradas y salidas



Thomas N. Kipf, Max Welling. Semi-Supervised Classification with Graph Convolutional Networks. ICLR 2017
 Justin Gilmer, Samuel S. Schoenholz, Patrick F. Riley, Oriol Vinyals, George E. Dahl. Neural Message Passing for Quantum Chemistry. ICML 2017
 Weihua Hu, Bowen Liu, Joseph Gomes, Marinka Zitnik, Percy Liang, Vijay Pande, Jure Leskovec. Strategies for Pre-training Graph Neural Networks. ICLR 2020

Graph networks

- Idea clave: usar las redes para aprender representaciones (embeddings) de nodos, subgrafos o redes
- Aplicaciones: (i) Visualización y descubrimiento de patrones; (ii) Agrupamiento, detección de comunidades; (iii) Clasificación de nodos, aprendizaje semi-supervisado; (iv) Link prediction




Figura: Aprendiendo embeddings para nodos.

William L. Hamilton, Rex Ying, Jure Leskovec: Representation Learning on Graphs: Methods and Applications. IEEE Data Eng. Bull. 40(3): 52-74 (2017)

Graph networks

- Idea clave: usar las redes para aprender representaciones (embeddings) de nodos, subgrafos o redes
- Aplicaciones: (i) Visualización y descubrimiento de patrones; (ii) Agrupamiento, detección de comunidades; (iii) Clasificación de nodos, aprendizaje semi-supervisado; (iv) Link prediction




Figura: Arquitectura encoder-decoder en GNNs.

William L. Hamilton, Rex Ying, Jure Leskovec: Representation Learning on Graphs: Methods and Applications. IEEE Data Eng. Bull. 40(3): 52-74 (2017)

Topic modeling

- Modelos probabilistas para representar documentos (objetos que pueden caracterizarse con la ocurrencia o no de elementos)
- Cada documento se modela como una distribución de probabilidad sobre un conjunto de "tópicos"
- Un tópico es una distribución de probabilidad sobre las palabras/elementos (en cada tópico un conjunto de palabras tiene más probabilidad de ser muestreado)

"Arts"	"Budgets"	"Children"	"Education"
NEW	MILLION	CHILDREN	SCHOOL
FILM	TAX	WOMEN	STUDENTS
SHOW	PROGRAM	PEOPLE	SCHOOLS
MUSIC	BUDGET	CHILD	EDUCATION
MOVIE	BILLION	YEARS	TEACHERS
PLAY	FEDERAL	FAMILIES	HIGH
MUSICAL	YEAR	WORK	PUBLIC
BEST	SPENDING	PARENTS	TEACHER
ACTOR	NEW	SAYS	BENNETT
FIRST	STATE	FAMILY	MANIGAT
YORK	PLAN	WELFARE	NAMPHY
OPERA	MONEY	MEN	STATE
THEATER	PROGRAMS	PERCENT	PRESIDENT
ACTRESS	GOVERNMENT	CARE	ELEMENTARY

Topic modeling

Introducción

Técnicas y tópicos no vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y Retos

Super-Inteligencia

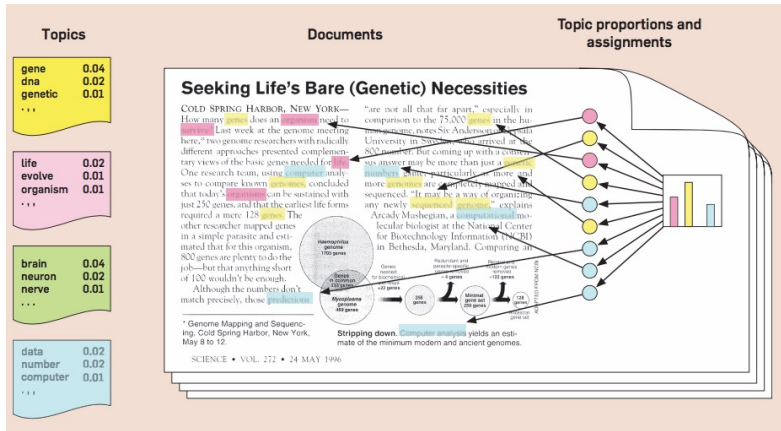



Figura: Diagrama general de modelado basado en tópicos.

Topic modeling

¿Cómo se aprenden los tópicos?

- Se asume un modelo generativo para los documentos
- Se encuentran los parámetros del modelo que maximiza probabilidad de los datos

1. Choose $N \sim \text{Poisson}(\xi)$.
2. Choose $\theta \sim \text{Dir}(\alpha)$.
3. For each of the N words w_n :
 - (a) Choose a topic $z_n \sim \text{Multinomial}(\theta)$.
 - (b) Choose a word w_n from $p(w_n | z_n, \beta)$, a multinomial probability conditioned on the topic z_n .



$$p(\theta, \mathbf{z} | \mathbf{w}, \alpha, \beta) = \frac{p(\theta, \mathbf{z}, \mathbf{w} | \alpha, \beta)}{p(\mathbf{w} | \alpha, \beta)}$$

Neurosimbólico

- En los últimos años se han visto avances muy importantes en ML
- En algunas áreas ha representado un cambio de paradigma, visión, lenguaje natural, reconocimiento de voz, juegos, etc.
- Estamos en el 3er verano de IA, y aunque lejos de GAI, no necesariamente se requiere sistemas realmente inteligentes para ser útiles y se espera que el interés comercial siga
- Se cree que posiblemente se reduzca el entusiasmo, pero que no se va a tener otro invierno

A. D'Avila Garcez, L.C. Lamb (2020). Neurosymbolic AI: The 3rd wave. arXiv:2012.05876v2

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Neurosimbólico

(A) The Cartoon History of AI



(B) The Cartoon History of AI



- Sin embargo, siguen las preocupaciones por seguridad, confianza, interpretabilidad y responsabilidad
- Algunos autores piensan que se está llegando a una planicie con las NN y que se requiere razonamiento simbólico

G. Marcus, E. Davis (2019). Rebooting AI: Building Artificial Intelligence We Can Trust. Pantheon Books

Introducción

Técnicas y tópicos no vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y Retos

Super-Inteligencia

Neurosimbólico

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos


Super-
Inteligencia

- El área de neuro-simbólico ha estado presente desde hace mucho tiempo en IA, pero ha adquirido más relevancia recientemente
- Una vez que “salgan” símbolos de las redes neuronales, éstos se pueden manipular relativamente fácil
- El problema sigue siendo cómo conectarlos
- El tercer ingrediente importante es la parte probabilista
- Kautz propone una taxonomía de 6 diseños

H. Kautz (2022). The Third Summer: AAAI Robert S. Engelmore Memorial Lecture. The AI Magazine 43(1): 105-125

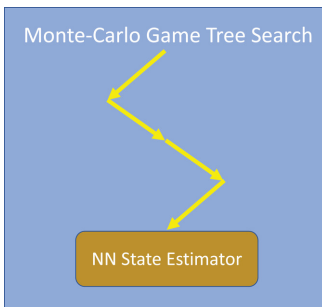
Symbolic Neuro Symbolic

- Esta es el procedimiento estándar de DP actual para LN
- La red recibe símbolos, secuencias de palabras, las cuales se convierten en vectores (con word2vec, GloVe, etc) y pasan a una red neuronal



Symbolic[Neuro]

- Se usa una reconocedor de patrones neuronal dentro de un resolovedor de problemas simbólico
- Ejemplo, AlphaGo usa como resolovedor MCTS que usa una red neuronal como evaluador



Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Neuro: Symbolic \rightarrow Neuro

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos


Super-
Inteligencia

- Se recibe como entrada y como salida una representación simbólica y se busca aprender este mapeo con una red neuronal
- Lample y Charton (2020) entrenan un transformer para hacer manipulación matemática simbólica

input: $\int x^n dx$ output: $(1/n+1) x^{n+1}$

Neuro{Symbolic}

- Transforman reglas simbólicas en patrones para estructuras jerárquicas dentro de una red neuronal
- Ejemplos: *Tensor product representations* (Smolensky et al. 2016) y *Logic tensor networks* (Serafini, Donadello y Garcez, 2017)



Nuero[Symbolic]

- Tener un razonamiento simbólico embebido dentro de una maquina neuronal
- Inspirado en D. Kahneman “Thinking fast and slow”: El Sistema 1 opera automáticamente y rápido sin mucho esfuerzo (NN) y el Sistema 2 necesita atención y esfuerzo mental (simbólico)
- El Sistema 1 está a cargo, genera una representación simbólica interna y decide cuando iniciar el Sistema 2 (que opera con estructuras simbólicas)
- La estructura simbólica podría ser parecido a lo que generan las redes neuronales que se usan en LN y la salida del razonamiento simbólico podría ser entrada a la red neuronal, de nuevo como se hacer en LN

D. Kahneman (2011). Thinking fast and slow. Penguin Books.

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

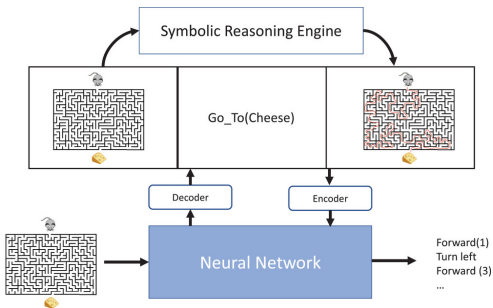
Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Nuero[Symbolic]



Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
RetosSuper-
Inteligencia

Persepectivas

- Desde hace tiempo se tiene un desarrollo acelerado del área (se pueden ver en el número de artículos y foros)
- En parte ha sido impulsado por:
 - Interés comercial que le han dado diversos nombres y \$\$: KDD, *Big Data*, *Deep Learning*, ...
 - Generación de datos: “90% de los datos en el mundo se han generado en los últimos 2 años”
 - Poder de cómputo (CPU, GPU, ...)
- Se está viviendo un re-surgimiento del área de Inteligencia Artificial (otra vez) con grandes expectativas (antes: Inicios, Sistemas Expertos, NN, KDD; ahora: DL)

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Retos

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

- Aprendizaje sin (con poca) guía
- Diversos tipos de aprendizaje, concurrentes, y por largo tiempo
- Aprendizaje de “sentido común”
- Selección automática de información relevante
- Aprender con poca información
- Organización del conocimiento aprendido

Tendencias y Expectativas

Una gran inversión de la industria y países desarrollados en el área:

- “Beijing is planning to build a 13.8 billion yuan (\$2.12 billion) AI development park”
- “Venture capital investment in AI doubled to US\$12 billion in 2017”
- “France to spend \$1.8 billion on AI to compete with US, China”
- “China will have more robots operating in its production plants by 2017 than any other country”
- ...

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Tendencias y Expectativas

(¿Cómo está México?)


Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning
Lifelong ML
Sesgo en los datos
Graph Networks
Topic modeling
Neuro-Simbólico

Perspectivas y
RetosSuper-
Inteligencia

- En Primaria-Preparatoria se enseña a usar paquetes
- Existen 200+ nombres de carreras en computación e informática, muchas con deficiencias matemáticas
- En investigación hay pocos grupos, son pequeños, no se reconocen los congresos
- México invierte menos del 0.5% del PIB en CyT



¿Se puede lograr una verdadera IA?

Antes:

- Gödel (teorema de incompletés)
- Dreyfus (manipulación simbólica no es fundamento de inteligencia)
- Searle (pensamiento real y simulado)
- Penrose (se requiere conocimientos de física no incluidos en las máquinas)

Ahora:

- Barret, Hawking, Musk (“el último invento del hombre”)
- ¿Pérdida masiva de empleos?
- ¿Cuándo se tendrá una super-inteligencia y sus consecuencias?

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Super-Inteligencia

- Durante muchos años, los investigadores de IA se dejaron de cuestionar si era posible crear una inteligencia artificial
- A pesar del entusiasmo inicial, el problema resultó ser mucho más difícil de lo anticipado
- Con los avances recientes, tanto en generación y acceso a datos, computadoras más veloces, y algoritmos de DL, la gente ya no se cuestiona si se va a lograr, sino cuándo y cuáles pueden ser sus consecuencias
- Algunos autores predicen que con el desarrollo actual será posible crear una super-inteligencia (entes más inteligentes que el hombre)

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Super-Inteligencia

Existen varios candidatos para crear super-inteligencias:

- IA: Algunos creen la más probable y cercana
- Emulación del cerebro: Crear cerebros artificiales con base en los biológicos
- Bio-ingeniería (DNA): Cambiar el DNA para promover inteligencia (*selective breeding*)
- Implantes cerebrales: Combinar el cerebro con implantes que aumenten la capacidad cerebral (e.g., conectarse a Internet - memoria ilimitada, transmisión de datos, cálculos complejos ...)
- Fármacos: Aumentar la capacidad cerebral por medio de fármacos
- Organización Grupal: Crear grupos específicos para resolver problemas difíciles (super-inteligencia colectiva)

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Super-Inteligencia

Con base en encuestas de cuándo se podría tener una inteligencia a nivel del ser humano (HLMI):

- 2030 - 10%
- 2050 - 50%
- 2100 - 90%

Cuánto tiempo después se va a tener una super-inteligencia:

- 2 años después - 5%-10%
- 30 años después - 50%-75%

Creación de una super-inteligencia:

- 12% muy posible
- 17% posible
- 21% ni si ni no
- 24% poco probable
- 26% muy poco probable

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos


Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
RetosSuper-
Inteligencia

Super-Inteligencia



- Creer que en cuanto nos acerquemos a una inteligencia, se va a dar muy rápido la creación de una super-inteligencia
- Lo que se cree es que al crear un ente inteligente, éste va a poder desarrollar uno más inteligente y así sucesivamente (y algunos creen que se puede dar muy rápido - meses/años)
- Dadas las expectativas que se tiene se está creando una carrera hacia ésto (parecido a la carrera a la luna)

Introducción

Técnicas y tópicos no vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y Retos

Super-Inteligencia

¿Qué se espera a corto/mediano plazo?

- El surgimiento de muchas más aplicaciones/compañías que usan IA
- En términos de empleos, los robots van a reemplazar/modificar empleos:
 - Principalmente en telemarketing, cajeros, asistencia legal, choferes, comida rápida
 - y en menos medida en psicólogos, nutriólogos, enfermeras, curas, artistas, científicos ...
- Algunas estiman que reemplazarán entre 400 y 800 millones para el 2030
- Algunos estiman mayor creación de nuevos empleos en Robótica, IA, IHR, entretenimiento, *smart-X*, ...

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
RetosSuper-
Inteligencia

¿Qué se espera a corto/mediano plazo?

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

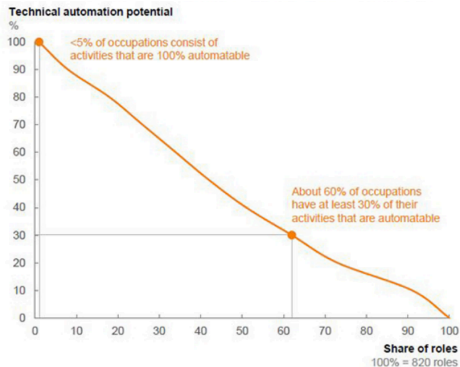
Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
RetosSuper-
Inteligencia

Super-Inteligencia

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

- Posiblemente se vaya a crear un “singleton” con ventaja y dominio competitivo sobre los demás
- Si no lo crea un gobierno, ¿que tal un grupo terrorista?
- ¿Se pueden monitorear los avances de los diversos grupos? ¿Se harían colaboraciones intencionales?

Super-Inteligencia

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Miedos:

- Se van a desplazar empleos (los no o poco calificados) y se cree que pronto (aunque no se tenga una super-interligencia)
- Miedo de que termine con la raza humana
- ¿Se podría controlar?
- ¿Se pueden inculcar valores “humanos”?

¿Porqué IA es más difícil de lo que se cree?¹

- Desde los inicios de IA ha tenido ciclos de primaveras e inviernos
- En los inicios se hicieron predicciones irreales por los iniciadores del área (e.g., Simon, Shannon, Minsky, ...)
- Lo mismo ocurrió con los Sistemas Expertos y el Proyecto de la Quinta Generación de Japón
- Estamos viviendo lo mismo con las redes neuronales profundas (*“aprenden atajos de las respuestas correctas”*)
- Predicciones de super-inteligencia en pocos años: Russell, Altman (OpenAI), Legg (DeepMind), Zuckerberg (Facebook)

¹M. Mitchell (2021). Why AI is harder than we think.
arXiv:2104.12871v2

¿Porqué IA es más difícil de lo que se cree?: Las cuatro falacias

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Falacia 1: Existe un continuo de IA “estrecha” (*narrow*) hacia GAI

- Muchos avances se consideran como el primer paso hacia GAI (e.g., Deep Blue, Watson, GPT-3)
- “Es como asegurar que con el primer mono que subió a un árbol se estaba avanzando hacia el primer alunizaje” (S. Dreyfus)

¿Porqué IA es más difícil de lo que se cree?: Las cuatro falacias

Falacia 2: “Las cosas fáciles son fáciles y las difíciles son difíciles”

- McCarhty: “IA es más difícil de lo que pensamos”;
Minsky: “Es porque las cosas fáciles son difíciles”
- Moravac: “Es relativamente fácil hacer que las computadoras exhiban comportamiento experto en ciertas áreas y difícil o imposible que tengan las habilidades de un niño de un año cuando se trata de percepción y movilidad”
- Existe un gran desconocimiento de la complejidad de los procesos subconscientes
- Somos inconscientes de la complejidad de nuestro propio proceso de pensamiento

Introducción

Técnicas y
tópicos no
vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

¿Porqué IA es más difícil de lo que se cree?: Las cuatro falacias

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
Retos

Super-
Inteligencia

Falacia 3: El atractivo de la mnemotecnia

- El sistema “entiende”, “aprende”, “piensa”, ...
- Algunos de los *benchmarks* tienen nombres pretenciosos y se comparan con personas
- Resultados: “Un sistema de IA es mejor que las pesonas en ...”
- El problema es que esas pruebas no miden la generalidad de las habilidades

¿Porqué IA es más difícil de lo que se cree?: Las cuatro falacias

Falacia 4: Toda la inteligencia está en el cerebro

- La inteligencia se puede separar del cuerpo (*pure intelligence*)
- G. Hinton: “Para entender documentos a nivel humanos vamos a necesitar redes más grandes, pero seguramente la gente de hardware lo va a solucionar”
- Aunque los robots interactúan con el ambiente, su interacción es muy limitada
- La teoría cognitiva actual sugiere que nuestros pensamientos están asentados/asociados con la percepción, acción y las emociones, y que la mente y el cuerpo trabajan en conjunto para tener cognición (*embodied cognition*)

Introducción

Técnicas y
tópicos no
vistas

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y
RetosSuper-
Inteligencia

Conclusiones

- No está claro cómo evaluar el progreso hacia una GAI o cómo mejorar nuestra intuición de lo que es la inteligencia
- Necesitamos mejorar el vocabulario de lo que las máquinas pueden hacer y mejorar el entendimiento de la inteligencia
- O. Etzioni: “El sentido común en la materia oscura de la IA”
- Necesitamos dotar a las máquinas del conocimiento que los niños tienen acerca del espacio, tiempo, causalidad, objetos inanimados, seres vivos, capacidad de abstraer y hacer analogías (A. Turing - The Child Machine)
- Lo que se hace ahora no es ciencia es alquimia (T. Winograd’77, E.Horvitz’17)

Introducción

Técnicas y tópicos no vistos

Curriculum Learning

Lifelong ML

Sesgo en los datos

Graph Networks

Topic modeling

Neuro-Simbólico

Perspectivas y Retos

Super-Inteligencia