

Inteligencia Artificial

Orígenes, Concepciones y Problemas

Leopoldo Bertossi

bertossi@scs.carleton.ca

¿De Dónde y Ahora?

- El término “Inteligencia Artificial” se acuña a fines de los 50
Para la primera conferencia científica en torno al tema
“Dartmouth Summer Research Project on Artificial Intelligence, 1956”
- Hasta ese momento era una colección desarticulada de visiones, sueños, enfoques, problemas, técnicas, etc.
Y sigue siéndolo ...
- Sin embargo, ha habido increíbles avances
- Triste área la de IA y sus cultores: los resultados, una vez establecidos, dejan de ser IA
Pasan a ser “commodities” tecnológicos (de la computación)
No más visiones ni desafíos en ese terreno (sólo mejoras) ...
- Son la visiones y sueños los que han siempre guiado a la investigación en IA
Y muchas promesas y profecías no siempre cumplidas ...

- Profecías han hecho avanzar la investigación
- Profecías han dañado la investigación y la IA
- Promesas incumplidas crearon cíclicamente etapas de escepticismo y reducción de popularidad

Y reducción del financiamiento para investigación

- Ha habido los cíclicos “inviernos de la IA”
- Una trayectoria ondulante en términos de resultados, popularidad, prestigio y financiamiento

- Hoy estamos en un caluroso verano de la IA
- Desde mediados de los 90
Con aceleración desde m/m 2010
Debido a la interacción, uso y retroalimentación (hasta hoy) con “big data”, data science, etc.
- Y el aumento de capacidad y rapidez de los computadores (Ley de Moore)
Avances en microchips y microelectrónica
- Mucho financiamiento, investigación, resultados, startups, institutos de investigación, nuevas aplicaciones
Múltiples vacantes en academia, empresa, organizaciones, ...
Nuevas y muchas conferencias, programas de estudio, etc.
- Nuevamente muchas expectativas ...
- Es “cool y sexy” dedicarse a la IA ...

Más Atrás Aún

- No hay IA sin (Ciencia de) Computación (CC)
- La CC nace a mediados de los años 30

Con los primeros modelos matemáticos de computador y algoritmo

Principal (pero no único) personaje: Alan Turing

- CC motivada por problemas formulados por lógicos matemáticos (desde principios del siglo 20)
- IA influida por creación de primeros computadores hacia fines de los 40
- Rol prominente: John von Neumann, etc.



Motivaciones y Enfoques

- ¿Qué significaba hacer IA?
- No había consenso
 - Ni parece haberlo hoy (volveremos ...)
- ¿Simular mediante el computador el funcionamiento inteligente del cerebro humano (CH)?
- ¿Estudiar y modelar el funcionamiento del CH a través de la computación?
- ¿Replicar en el computador el funcionamiento del CH?
- ¿Conseguir que el computador *exhiba* externamente inteligencia del tipo humano?


Ha sido explícita o implícitamente la versión predominante de la IA

- Y después de todo, se trataba de que computadores exhibieran inteligencia (del tipo humano)

Más precisamente, programas (sistemas) para (en) computadores

- Famoso e influyente es el temprano “Test de Turing” (1950)

“Un sistema computacional (A) es inteligente si un humano (C), interactuando a través de un computador simultaneamente con él y con un humano (B), no puede distinguir al computador del humano”



- Notar que aquí no importa si el computador está funcionando internamente como un ser humano

Áreas de la IA

- No hay un área unificada de la ciencia y tecnología llamada “Inteligencia Artificial”
Más bien una colección disconexa de áreas y formas de entender y hacer las cosas
- Hay ciencia sofisticada para ciertas áreas y problemas de IA
- Esto se ve tanto a la luz de su historia como a la luz de lo que hoy existe y se hace en IA
- En una primera etapa los juegos fueron una fuente de inspiración y estudio, e.g. de damas, el “gato”, ajedrez, etc.
Captura, representación y uso de “heurísticas”
- Hoy sistemas de IA vencen a campeones de ajedrez y go
Almacenamiento, acceso y uso de muchos patrones; y análisis rápido de múltiples combinaciones
No tanto heurísticas ...

Áreas de la IA: Heurísticas

- Heurísticas son ciertas prácticas y procesos que suelen llevar a la solución de un problema

Son como “reglas a dedo” con un origen parcial en la intuición y experiencia; una “apuesta informada”

No hay garantía (matemática) de que llevan a una solución ni a la “mejor” solución


Los seres humanos (inteligentemente) las usan

- El problema es aprender, diseñar, formular y aplicar heurísticas
Representaciones simbólicas del problema, reglas simbólicas de acción, y funciones numéricas que miden localmente la cercanía a la meta
- En ajedrez, parta evitando que le den un mate pastor ...
Más adelante en el juego, se usará otras heurísticas ...
- También aparecen en problemas de logística

Áreas de la IA: Problemas Combinatorios

- Problema típico: El **Vendedor Viajero**

Hay que recorrer las $N = 10$ ciudades sin repetirse una ciudad, y por una ruta de costo mínimo



Otros: Dado un contenedor, meter dentro la máxima cantidad de objetos de distintos tamaños

Scheduling: Poner en una tabla de tiempo distintos eventos de distinta duración de forma óptima, y con restricciones temporales

- Estos problemas son (matemáticamente demostradamente) difíciles de resolver (óptimamente)

Hasta hoy **no hay métodos computacionales eficientes y generales para resolverlos** (y se conjetura que no los hay)

- Hay algoritmos (implementados computacionalmente) que funcionan bien y rápido con las instancias “grandes” que uno encuentra “en la práctica”

- Ahí hay uso de heurísticas y soluciones aproximadas

Durante los 80 se decía que IA se trataba de ser capaz de enfrentarse inteligentemente a estos problemas (NP-completos)

- En mi opinión, una concepción equivocada

Un ser humano, por inteligente que sea, es capaz de resolver (sin computación) sólo instancias muy pequeñas

- Ultimamente se está revisitando estos problemas desde el punto de vista de aprendizaje automatizado (machine learning)

[← Go to ICLR 2022 Conference homepage \(/group?id=ICLR.eu/2022/Conference\)](#)

Graph Neural Network Guided Local Search for the Traveling Salesperson Problem

[/paper?id=arXiv2008080](#)

Benjamin Hudson [\(/profile?id=Benjamin_Hudson1\)](#), Qingbiao Li [\(/profile?id=Qingbiao_Li1\)](#), Matthew Malencia [\(/profile?id=Matthew_Malencia1\)](#), Amanda Prorok [\(/profile?id=Amanda_Prorok1\)](#)

28 Sept 2021 (modified: 14 Mar 2022) ICLR 2022 Poster Readers:  Everyone Show

Bibtex [Show Revisions \(/revisions?id=arXiv2008080\)](#)

Keywords: Traveling Salesman Problem, Graph Neural Network, Metaheuristic, Guided Local Search, Hybrid

Abstract: Solutions to the Traveling Salesperson Problem (TSP) have practical applications to processes in transportation, logistics, and automation, yet must be computed with minimal delay to satisfy the real-time nature of the underlying tasks. However, solving large TSP instances quickly without sacrificing solution quality remains challenging for current approximate algorithms. To close this gap, we present a hybrid data-driven approach for solving the TSP based on Graph Neural Networks (GNNs) and Guided Local Search (GLS). Our model predicts the regret of including each edge of the problem graph in the solution. GLS uses these predictions in conjunction with the original problem graph to find solutions. Our experiments demonstrate that this approach converges to optimal solutions at a faster rate than three recent learning-based approaches for the TSP. Notably, we reduce the mean optimality gap on the 100-node problem set from 1.534% to 0.705%, a 2x improvement, when generalizing from 20-node instances to the 100-node problem set, we reduce the optimality gap from 18.66% to 2.62%, a 7x improvement.

One-sentence Summary: We present a hybrid data driven approach for solving the TSP based on Graph Neural Networks (GNNs) and Guided Local Search (GLS), which outperforms state-of-the-art learning-based approaches and non-learning GLS algorithms.

Áreas de la IA: Razonamiento Lógico

- Otro problema temprano: **Razonamiento Lógico Clásico**

Por ejemplo, demostraciones geométricas automatizadas

- Mucho énfasis en soluciones “simbólicas”, basada en procesamiento computacional de símbolos

- “*Todos los hombres son mortales*” y “*Sócrates es un hombre*”

¿Cómo inferir (computacionalmente) que “*Sócrates es mortal*”?

Razonamiento lógico

Procesamiento simbólico de representaciones simbólicas

- En 1996 un sistema para (descubrir) y hacer demostraciones matemáticas de propósito general demuestra por primera vez un teorema matemático que nadie había podido demostrar (conjetura hasta ese momento)



- Otra aplicación simbólicas: **planificación** (automatizada)
- Se da una lista de especificaciones (simbólicas) de acciones con sus efectos y precondiciones
Por ejemplo, “al tomar una caja debo tener las manos libres y el efecto es que la caja queda en mis manos”
- Se da una meta: que la “caja quede en la mesa fuera de la habitación donde estoy”
- El robot debe diseñar un plan de acción para conseguir la meta
- Problemas de este tipo requieren de la combinación de procesamiento simbólico
Posiblemente, con heurísticas adicionales relacionadas con la cercanía a la meta
- ¿Cómo el robot puede estar seguro de que “después de abrir la puerta de la habitación e ir a buscar la caja, la puerta aún está abierta”? (inercia, persistencia)

Áreas de la IA: Sentido Común

- Un problema identificado tempranamente como importante:
Razonamiento con Sentido Común (SC)
- El SC es propio de la inteligencia humana
- Permite razonar y funcionar en la ausencia de conocimiento completo y explícito
- *“Normalmente las aves vuelan”* y *“Piolín es un ave”*



¿Concluimos que *“Piolín vuela”*?

En general, sí, porque en la ausencia de información sobre la posible anomalía de Piolín, concluimos (que es normal y) que vuela

- Esto no es razonamiento lógico clásico
- ¿Cómo dotar a sistemas inteligentes computacionales de SC?
- Hay soluciones relativamente satisfactorias en el contexto del razonamiento simbólico

Pero no en general en IA

Áreas de la IA: Aprendizaje de Máquina

- “Machine Learning” (ML) se da en múltiples sabores
- Se trata de crear modelos computacionales sobre la base de datos de entrenamiento (o de interacción con el medio)



Por ejemplo, un modelo (e implementación) de un sistema para toma de decisiones (en un dominio particular)


- Muchas clases de modelos
- Tal vez los más famosos y aplicados: **Redes Neuronales**

De nuevo, en muchos sabores (arquitecturas, supuestos, etc.)

- “Inspiradas” en actividad cerebral (lejos de modelarla o simularla)

El enfoque “conexionista” de la IA





- Las variables x_1, x_2, x_3, x_4 podrían describir (numéricamente) la situación socio-financiera de un mismo individuo
- La RN neuronal “aprendió” a decidir si otorgar un préstamo y por cuánto

y_1 responde SI/NO (0/1), e y_2 da el monto

- Las funciones f_i son aprendidas a partir de los datos de entrenamiento

Por ejemplo, podemos querer que el primer f de arriba a la izquierda sea de la forma

$$f(x_1, x_2, x_3, x_4) = ax_1^2 + bx_2 + cx_4 + x_3^2 + d$$

Hay que aprender los “parámetros” (numéricos) a, b, c, d

- El gran éxito de ML (e IA) se debe en gran parte a las RNs
- Existen desde temprano en IA, pero las exitosas de última generación aparecen alrededor del 2010
- Pueden ser enormemente complejas en términos de número de variables, número de capas, de compuertas, funciones usadas, etc.
- Entrenarlas “bien” puede requerir de una enormidad de datos (complejos)

En parte explica el auge de la [Ciencia de Datos](#)

- Todo tipo de aplicaciones: procesamiento de lenguaje natural, procesamiento de audio e imágenes, interpretación de redes sociales, toma de decisiones, predicciones, prescripciones, ...
- Cuando son muy complejos, estos modelos son difíciles de [interpretar](#), y los resultados difíciles de [explicar](#)

- Hay muchas otras clases de modelos en ML, en particular para clasificación, entre ellos, **Arboles de Decisión**
- Tenemos datos categóricos y obtenemos números:


Outlook	Temperature	Humidity	Wind	Play
sunny	high	high	weak	no
sunny	high	high	strong	no
overcast	high	high	weak	yes
rain	medium	high	weak	yes
rain	low	normal	weak	yes
rain	low	normal	strong	no
overcast	low	normal	strong	yes
sunny	medium	high	weak	no
sunny	low	normal	weak	yes
rain	medium	normal	weak	yes
sunny	medium	normal	strong	yes
overcast	medium	high	strong	yes
overcast	high	normal	weak	yes
rain	medium	high	strong	no

$Fr(\text{Play} = \text{yes}) = \frac{9}{14}$	$Fr(\text{Play} = \text{no}) = \frac{5}{14}$
$Fr(\text{Outlook} = \text{sunny} \text{Play} = \text{yes}) = \frac{2}{9}$	$Fr(\text{Outlook} = \text{sunny} \text{Play} = \text{no}) = \frac{3}{5}$
$Fr(\text{Outlook} = \text{overcast} \text{Play} = \text{yes}) = \frac{4}{9}$	$Fr(\text{Outlook} = \text{overcast} \text{Play} = \text{no}) = 0$
$Fr(\text{Outlook} = \text{rain} \text{Play} = \text{yes}) = \frac{3}{9}$	$Fr(\text{Outlook} = \text{rain} \text{Play} = \text{no}) = \frac{2}{5}$
$Fr(\text{Temp} = \text{high} \text{Play} = \text{yes}) = \frac{2}{9}$	$Fr(\text{Temp} = \text{high} \text{Play} = \text{no}) = \frac{2}{5}$
$Fr(\text{Temp} = \text{medium} \text{Play} = \text{yes}) = \frac{4}{9}$	$Fr(\text{Temp} = \text{medium} \text{Play} = \text{no}) = \frac{2}{5}$
$Fr(\text{Temp} = \text{low} \text{Play} = \text{yes}) = \frac{3}{9}$	$Fr(\text{Temp} = \text{low} \text{Play} = \text{no}) = \frac{1}{5}$
$Fr(\text{Humidity} = \text{high} \text{Play} = \text{yes}) = \frac{3}{9}$	$Fr(\text{Humidity} = \text{high} \text{Play} = \text{no}) = \frac{4}{5}$
$Fr(\text{Humidity} = \text{normal} \text{Play} = \text{yes}) = \frac{6}{9}$	$Fr(\text{Humidity} = \text{normal} \text{Play} = \text{no}) = \frac{1}{5}$
$Fr(\text{Wind} = \text{strong} \text{Play} = \text{yes}) = \frac{3}{9}$	$Fr(\text{Wind} = \text{strong} \text{Play} = \text{no}) = \frac{3}{5}$
$Fr(\text{Wind} = \text{weak} \text{Play} = \text{yes}) = \frac{6}{9}$	$Fr(\text{Wind} = \text{weak} \text{Play} = \text{no}) = \frac{2}{5}$

- Y con ellos “aprendemos” un modelo de decisión


- Con los datos originales usados como “datos de entrenamiento” construir un **algoritmo de decisión**
- Podemos decidir en forma automatizada si jugar o no
- Aquí tenemos un **árbol de decisión**
(simplificado, sólo 3 features)
- **Se aprende y se usa de manera automatizada**

Con cualquier combinación de valores
(los datos de entrenamiento no contienen todas las combinaciones posibles)



- Podemos decidir con los datos de entrada
 $e = \langle \text{high, sunny, strong} \rangle$

- Decisión: “No”



Nuevas Tendencias

- **IA Neuro-Simbólica:**

Vimos que hay IA simbólica y conexionista

Han sido escuelas separadas en competencia (y disputa)

- Se percibe la necesidad de combinar ambas metodologías

Por ejemplo, sistemas de razonamiento simbólico que invocan a RNs

O agregar proposiciones simbólicas sobre el dominio a los datos con los que aprende una RN

- Por ejemplo, se puede decir explícitamente *“Todo postulante a un préstamo tiene una cuenta en el banco”*

¿Para qué aprender esto usando una gran cantidad de datos?

- **Volviendo a lo Básico:**

- Las RNs no modelan ni reconstruyen la composición ni la actividad cerebral (inteligente)

Esta última aún no se conoce plenamente ni se entiende

- RNs pueden tener hasta 175 mil millones de parámetros

Las RNs aprenden con muchos datos

- El cerebro humano tiene alrededor de 100 mil millones de neuronas

Los seres humanos no necesitan muchos datos ...

Ni tienen la capacidad de procesarlos rápida y masivamente

- Parte de la comunidad de IA está volviendo a estudiar cómo aprenden los seres humanos; los niños en particular

Colaboración con Neurociencia y Psicología Cognitiva

- **Explicaciones e Interpretabilidad:**

- Cuando un algoritmo toma una decisión, el afectado (o dueño del sistema) puede querer **saber por qué**
- El algoritmo del banco puede rechazarme la solicitud de préstamo
 - ¿Por qué? ¿Me está discriminando?
 - ¿Me está tratando de manera justa? (“fairness” es todo un tema)
- El algoritmo debería entregar una explicación
 - Esto requiere de algo extra
- Las explicaciones vienen en todos los sabores
- Hay modelos que son más explicables e interpretables que otros
- Comparar la red neuronal con el árbol de decisión

Relevancia en Ambito Militar

- En el ámbito militar las oportunidades que abre la IA son enormes
- 1. Cuerpos, uniformes y vehículos dotados de multiples sensores de todo tipo

Con sonido, imágenes, ..., **interpretados** inmediatamente

Transformados en narrativas auditivas, textuales, ...

2. Captura (y entrega) de imágenes de potenciales blancos, enemigos, depósitos estratégicos, ...
3. Interpretación de **intenciones** (y reacción)
4. **Coordinación** automática de múltiples dispositivos y personal militar
5. Lectura y transmisión del pensamiento en un team

Science & technology | The future of warfare

Tomorrow's soldiers will have their reality augmented

The Economist
Sept. 22, 2021

Relevant data will appear on their view of the battlefield



6. Toma de decisiones, reacciones y prescripciones, planificación automatizada, ...

7. ...

- Juntar datos puede ser (relativamente) fácil
Usarlos de manera rápida y efectiva durante la acción, no necesariamente ...

Ahí entran IA y Ciencia de Datos

- Además de muchas otras tecnologías: sensores, microelectrónica, criptografía, señales, GPS, visión computacional, simulación, etc.
- “Realidad virtual y aumentada”, video “juegos”, etc.


¿Estamos Preparados?

- Posiblemente se necesita entrenar más a los miembros de la fuerzas armadas en temas de ciencia de datos e IA

Y computación en términos más generales

- Los EEUU tienen academias para la formación académica y profesional de las fuerzas armadas

Con programas de postgrado; e investigación



The screenshot shows the official website of the Naval Postgraduate School's Computer Science department. At the top is the school's logo and name. Below is a search bar with the text 'Search CS'. A large banner image with the text 'Computer Science' is displayed. The mission statement follows, stating the department's goal to provide defense-relevant education and research. The 'Academics' section lists degree-granting programs, including MS, PhD, and MA programs in Computer Science and related fields.

NAVAL POSTGRADUATE SCHOOL

Computer Science

Search CS

Computer Science

The mission of the Computer Science department is to provide **defense-relevant, advanced education** and **research programs** to meet Naval unique needs, and increase the warfighting effectiveness of the U.S. Naval Forces, DoD and allied armed forces.

Academics

Degree-Granting Programs include:

- MS in [Computer Science](#) & [MOVES](#)
- PhD in [Computer Science](#) & [MOVES](#)
- [Master of Computing Technology](#) (DL only)
- [MA in Identity Management and Cyber Security \(MAIDMCS\)](#)
- [Doctorate in Computer Science](#)



Computer Science



Computer Science Research

Much of our research is multidisciplinary, involving students and faculty from mathematics, electrical engineering, mechanical engineering, and physics. Our research environment is unique in its blend of theory and practice, and with students' determination to put their thesis results into practice. Many of our student theses have led to publications in major conferences and frequent best-paper awards. We have 6 major categories: Cyber Security and Defense, Network, Mobility, Autonomous Systems, Data Science, and Software Engineering.

Cyber Security and Defense (CSD)

Provides knowledge in all areas of Information Security (INFOSEC) and develops the necessary skills for those who will be involved in development, evolution, or implementation of secure computer systems.

[Networks](#)

Provides fundamental and advanced knowledge in network architecture and system software for real-time and multicomputer systems and in the rapidly growing areas of wireless networking, mobile devices, and related topics, including mobile computing and wireless security.

Mobility

[Autonomous Systems](#)

Provides an understanding of [artificial intelligence](#) and human factors techniques for creating highly capable software agents that interact effectively with human users.

[Data Science](#)

[Software Engineering](#)

ACADEMICS HOME

[PROVOST](#) >

[ACADEMIC FACILITIES](#) >

[ACADEMIC RESOURCES](#)

[CALENDARS & EVENTS](#) >

[CANDIDATE INFORMATION](#) >

[FACULTY INFORMATION](#) >

[MAJORS & COURSES](#) >

[MAJORS LISTING](#)

[ACADEMIC ABBREVIATIONS](#)

[ACCREDITATION](#)

[COURSE CATALOG](#)

[COURSE CREDITS](#)

[COURSE REQUIREMENTS](#)

ACADEMICS



School of Engineering & Weapons

[Aerospace Engineering](#)

[Electrical & Computer Engineering](#)

[Mechanical Engineering](#)

[Naval Architecture & Ocean Engineering](#)

[Weapons, Robotics, & Control Engineering](#)

[School of Engineering & Weapons website](#)

School of Mathematics & Science

[Chemistry](#)

[Computer Science](#)

[Cyber Science](#)

[Mathematics](#)

[Oceanography](#)

[Physics](#)

¿Desafíos?

- ...

(muchos)

...

- Cuerpo de profesores

Difíciles de encontrar, pagar y retener

La academia tiene fuerte competencia con la empresa ...

Y las starups

- Retención de graduados ...