

# Ciencia de Datos y Lenguaje Natural

## Clase 1.1

Grupo PLN - INCO

Universidad de la República

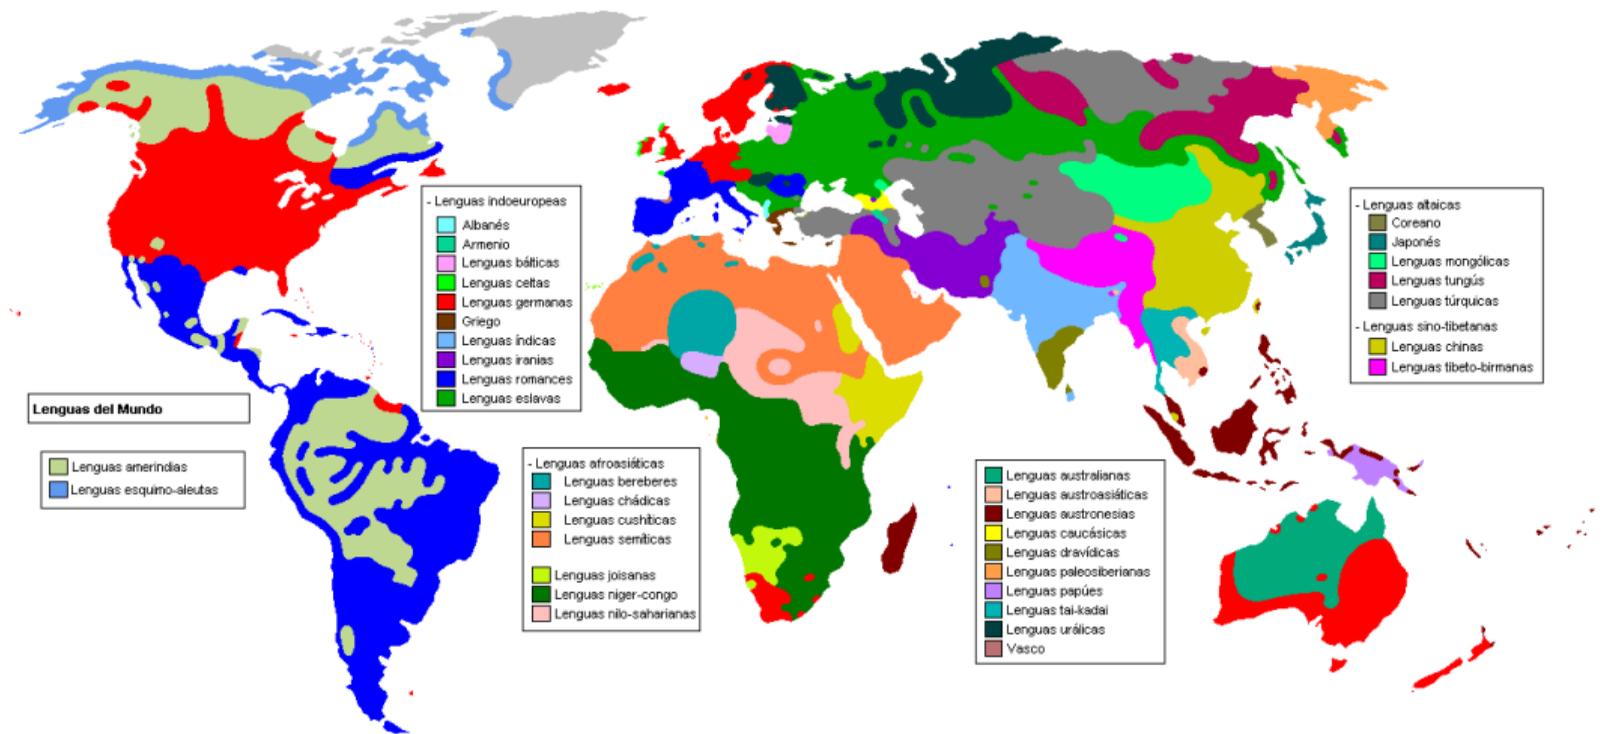
8 de agosto de 2022

- ▶ Por Lenguaje Natural entendemos el lenguaje de los humanos.
- ▶ Son en realidad diversas lenguas, según [www.ethnologue.com](http://www.ethnologue.com) hay más de 7.000 lenguas vivas.
- ▶ No nos entendemos hablando con hablantes de otras lenguas, ni podemos leer muchas veces siquiera textos escritos en otros alfabetos.



Sistemas de escritura, wikipedia

# Mapa de lenguas del mundo



## Ciencia de Datos y Lenguaje Natural

- ▶ Nos referimos al Procesamiento Automático del Lenguaje Natural, o sea, a programas que comprendan y/o generen lenguaje “en situación”.
- ▶ Al hablar de Ciencia de Datos y Lenguaje Natural nos referimos a métodos empíricos, basados en datos, para realizar las tareas asociadas al procesamiento del lenguaje.

## Historia del PLN

- ▶ Traducción automática
- ▶ Eliza (y los chatbots)
- ▶ Ubicuidad del procesamiento de lenguaje

## La traducción automática

- ▶ Uno de los primeros grandes proyectos de la informática
- ▶ Antecedente en la URSS en el 1936
- ▶ Muy relevante en la guerra fría, traducción del ruso al inglés
- ▶ los primeros traductores eran poco más que un sistema de búsqueda en un diccionario informatizado + alguna regla morfológica (género y número de sustantivos, conjugación de verbos)

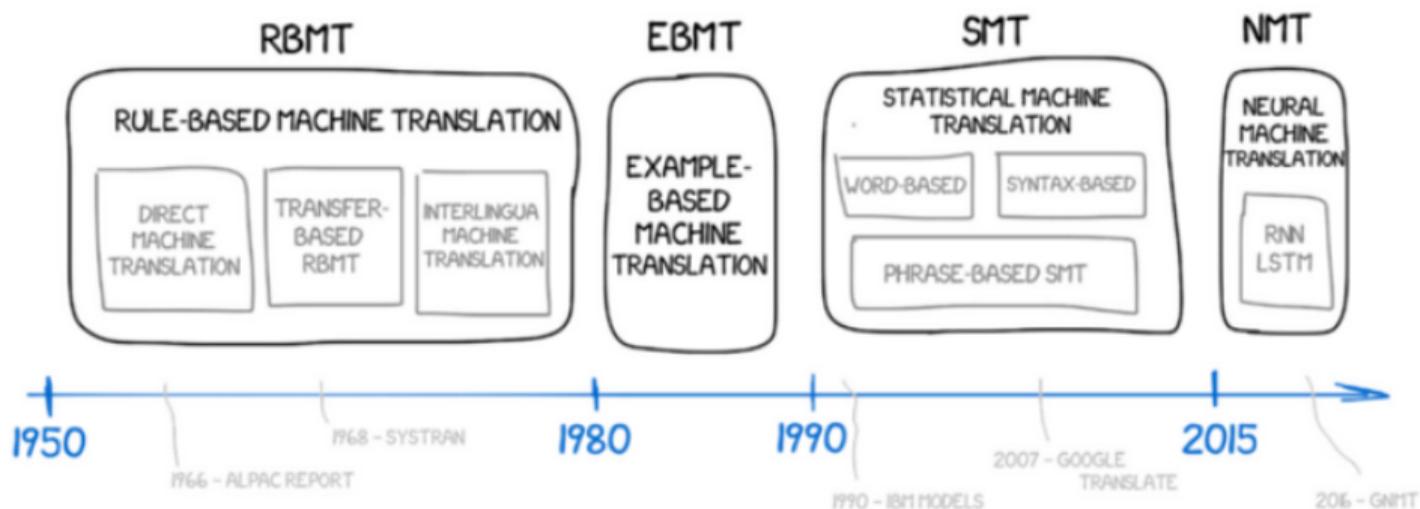
## La traducción automática, URSS 1933, Peter Troyanskii

I Я ICH YO	WANT ХОТЕТЬ WOLLEN QUERER	MANY МНОГО VIEL MUCHO	PERSIMMON ХУРМА PERSIMONE CACU
PRP., SUBJ, SINGULAR	VBP., PRESENT, SIMPLE, TRANSITIVE	JJ., DETERM, COMPARATIVE	NNS., PLURAL, COUNTABLE

A history of machine translation from the Cold War to deep learning, Ilya Pestov  
<https://www.freecodecamp.org/news/a-history-of-machine-translation-from-the-cold-war-to-deep-learning-f1d335ce8b5/>

## La traducción automática, etapas hasta hoy

### A BRIEF HISTORY OF MACHINE TRANSLATION



## Traducción automática, sistemas basados en reglas

### *RBMT, Rule Based Machine Translation*

- ▶ Son sistemas de traducción automática basados en información lingüística sobre los idiomas de origen y destino, básicamente recuperados de diccionarios y gramáticas.
- ▶ Reglas manuales, directas o pasando por una *interlingua*.
- ▶ Técnica que sigue siendo útil, muchas veces como 1er abordaje.
- ▶ En el curso se va a experimentar con expresiones regulares, un caso de esta técnica.

## Traducción basada en ejemplos

### *EBMT, Example Based Machine Translation*

- ▶ Japón 1984
- ▶ Sistema basado en corpus paralelos
- ▶ Esa idea se mantiene hasta el día de hoy
- ▶ Idea de que los datos (corpus) son la fuente de conocimiento.

## Traducción estadística

### *SBMT, Statistical Based Machine Translation*

- ▶ IBM 1994
- ▶ Sistema basado en modelos estadísticos generado a partir de corpus paralelos.
- ▶ Se utilizan modelos de ambas lenguas y un modelo de transferencia
- ▶ Paradigma dominante hasta la segunda década del siglo XXI

## Traducción por Redes Neuronales Profundas

### *NMT Neural Machine Translation*

- ▶ Sigue la línea de los SMT...
- ▶ ... con varias innovaciones:
  - ▶ representaciones vectoriales de las palabras
  - ▶ modelo secuencial único, predice cada palabra a partir de toda la entrada
  - ▶ el formalismo es una red neuronal profunda
- ▶ Estado del arte al momento actual

## Sistemas que conversan, Respuestas a preguntas

- ▶ Asistentes personales, orientados a tareas, guiados por objetivo  
Gus, Siri, otros
- ▶ Respuestas a preguntas Abiertas a la web : Siri, Alexa, Wolfram, Google Colecciones cerradas : Squad
- ▶ pasando el test de Turing

## Psico-terapeuta en la computadora

- ▶ Joseph Weizenbaum, 1964-1966, MIT
- ▶ Programa de demostración, imitando un psicólogo.
- ▶ Consecuencias insospechadas, la gente se sentía bien y comprendida hablando con Eliza. Primer ejemplo de la concepción antropomórfica de una computadora
- ▶ 1964 !! no había monitor !! comunicaciones por una teletipo

# Psico-terapeuta?

Welcome to

```

EEEEEE LL      IIII  ZZZZZZZ  AAAAA
EE      LL      II    ZZ    AA  AA
EEEEEE LL      II    ZZZ    AAAAAA
EE      LL      II    ZZ    AA  AA
EEEEEE LLLLLL IIII  ZZZZZZZ  AA  AA
  
```

Eliza is a mock Rogerian psychotherapist.

The original program was described by Joseph Weizenbaum in 1966.

This implementation by Norbert Landsteiner 2005.

ELIZA: Is something troubling you ?

YOU: Men are all alike.

ELIZA: What is the connection, do you suppose ?

YOU: They're always bugging us about something or other.

ELIZA: Can you think of a specific example ?

YOU: Well, my boyfriend made me come here.

ELIZA: Is it important to you that your boyfriend made you come here ?

## Otros sistemas de diálogo

- ▶ Asistentes personales, orientados a tareas, guiados por objetivo  
Gus, Siri, otros
- ▶ Respuestas a preguntas Abiertas a la web : Siri, Alexa, Wolfram, Google Colecciones cerradas : Squad
- ▶ pasando el test de Turing

## Aplicaciones PLN en la vida corriente

- ▶ Búsqueda de información, respuestas a preguntas
- ▶ Corrección ortográfica y gramatical
- ▶ Autocompletado al escribir
- ▶ Análisis de sentimientos
- ▶ Sistemas de recomendación