

## Diseño de sistemas de TA

- A la hora de diseñar un sistema se decide principalmente su **aplicación**
  - Esto generalmente determina que **tipo** de sistema a implementar
- Los sistemas pueden **clasificarse** por distintos aspectos (no mutuam. excluyentes)
  1. Pares de idiomas y direcciones tratados
  2. Intervención humana en el proceso
  3. Tipo de tarea a realizar
  4. Estrategias de traducción implementada

## 1. Idiomas y direcciones tratados

- Idiomas: sistemas **bilingüe** vs. **Multilingüe**
  - Sistemas que tratan 1 par de lenguas o muchos
- Direcciones: de qué LO a qué LM traduce
  - LO = lengua origen, LM = lengua meta (o SL/TL)
  - Sistema bilingüe puede ser **uni-direccional** o **bi-direccional**
  - Sistemas multilingüe puede ir de un idioma a muchos o en cualquier dirección entre muchos idiomas o tratar varios pares pero no todas las direcciones
- Ejemplos
  - EUROTRA de/hacia 9 idiomas  $\rightarrow 9 * 8 = 72$  pares
  - Primeras versiones de Systran eran una colección de sistemas bilingües uni-direccionales

## Sistemas multilingüe

- Los “verdaderos” sistemas **multilingüe** mantienen el tratamiento de cada idioma en **módulos independientes**
  - Ej. tratan EN como LO siempre igual aunque LM sea ZH, ES o QU
- Cuando es preferible un sistema puramente multilingüe?
  - Discusión Ariane o KANT vs. Météo

## 2. Intervención humana (1/2)

- El proceso de pasar de LO a LM puede realizarse sin intervención humana (**off-line**) o con asistencia humana (**interactivos**)
- Sistemas interactivos involucran al usuario durante el proceso de traducción
  - Sobre ciertas decisiones de traducción, ej para resolver ambigüedades
  - Si el texto a traducir contiene sintaxis o vocabulario que no reconoce
  - Propone traducciones a medida que el usuario tipea (predicción de palabras y/o frases)
- Tienen **requerimientos** estrictos (**rapidez** para tiempo real, usuarios **expertos** en LMs)
- Eliminan el costo de pre/post edición pero podrían no reducir el tiempo de producción (ver biblio 4)

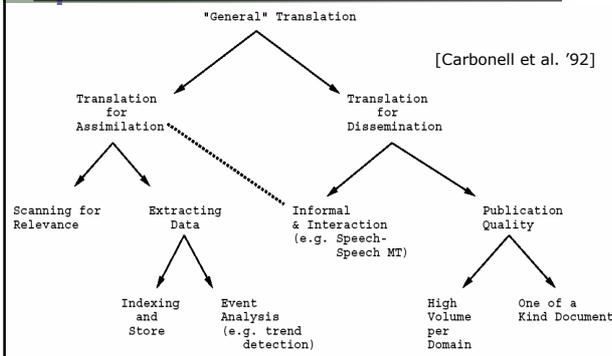
## 2. Intervención humana (2/2)

- Proceso off-line puede requerir intervención humana
- Antes de la traducción = **pre-edición** del texto
  - Antes de TA eliminar ambigüedades, construcciones complejas, vocabulario desconocido, etc  $\rightarrow$  asociado a **lenguajes controlados**
  - Requiere alto conocimiento del sistema a usar
- Después de la traducción = **post-edición** Un humano arregla la TA  $\rightarrow$  cuesta menos que traducir de cero y es más rápido
  - Requiere competencia casi nativo en LM

## 3. Tareas a realizar (1/2)

- Algunas **tareas** requieren cierto nivel de **calidad** de la TA para realizarse con éxito
- En general hay 2 tareas principales
  - **Asimilación**: sacar la idea del texto o encontrar palabras clave para **indexar** o evaluar pertinencia de un documento a una búsqueda
  - **Diseminación**: apunta a publicar el texto sin editar o usarlo en etapa siguiente de un pipeline
- Mejorar la calidad implica mejorar el sistema?  
 $\rightarrow$  ver “Good applications for crummy MT”

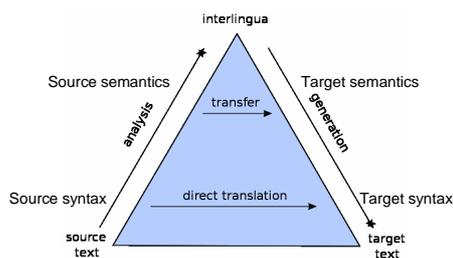
### 3. Tareas a realizar (2/2)



### 4. Estrategias de traducción

- Clasificar los sistemas por el tipo de **paradigma** que implementan es lo más común
- Hay muchos y siguen apareciendo
  - Basada en reglas
    - Directa
    - Transferencia
    - Interlingua
  - Basada en ejemplos
  - Estadística
  - Híbridos

### Pirámide de Vaquois (1968)



### Traducción directa

- También llamados “primera generación” traducen de origen a destino mediante **diccionarios y gramáticas**
- Proceso
  - Traducción **palabra a palabra**
  - Reglas de **reordenación local**
- Puede suceder que
  - Frases sin sentido
  - Podría ser útil en lenguaje controlado

### Modelo simplista

1. Identificar y separar **oraciones**
2. Separar en **tokens** (tokenisation)
3. Manejo de **mayúsculas** (suelen sacarse o usarse para identificar entidades)
4. Búsqueda en **diccionario** y sustitución (puede incluir resolución de ambigüedades)
5. Copiar palabras **desconocidas, dígitos, puntuación, etc.**

### Modelo mejorado (Tucker 1987)

1. Búsqueda en **diccionario** origen y análisis **morfológico**
2. Identificación de **homógrafos**
3. Identificación de **sustantivos** compuestos
4. Identificación de frases **verbales** y **sustantivos**
5. Procesamiento de **expresiones** idiomáticas

## Modelo mejorado (Tucker 1987)

6. Procesamiento de preposiciones
7. Identificación de sujeto – predicado
8. Identificación de ambigüedades sintácticas
9. Síntesis y procesamiento morfológico de texto destino
10. Reordenamiento de palabras o frases en texto destino

## Análisis del modelo

- Problemas
  - La base es el análisis morfológico y un diccionario bilingüe → reordenamientos de larga distancia, estructura sintáctica
- Ventajas
  - podría ser útil para traducir entre idiomas muy cercanos
  - Es fácil de implementar

## Ejemplos de un sistema RU → EN [Hutchins&Somers]

*My trebuem mira.*  
We require world  
'We want peace.'

*On dopisal stranitsu i otložil ručku v storonu.*  
It wrote a page and put off a knob to the side.  
'He finished writing the page and laid his pen aside.'

*Včera my tselyi čas katalis' na lodke,*  
Yesterday we the entire hour rolled themselves on a boat.  
'Yesterday we went out boating for a whole hour.'

## Modelos indirectos

- También llamados “segunda generación”
- Usan representaciones intermedias para pasar de origen a destino
  - La idea es capturar la semántica del texto
- Dos variantes principales
  - Por transferencia
  - Interlingua

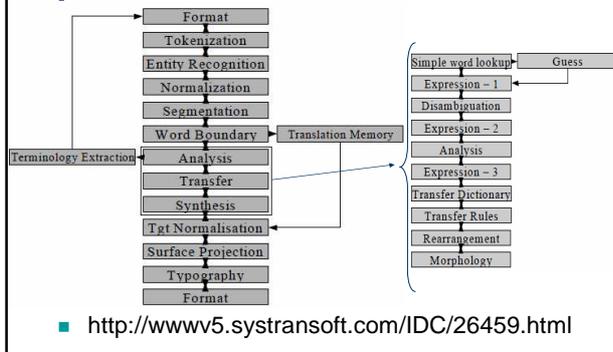
## Por transferencia

- Transferencia a nivel sintáctico
  - Transferir = pasar de LO a LM = traducir
- Se analizan ambos lenguajes con módulos dependientes del lenguaje
  - Ej. un módulo para EN→ES, otro para EN→FR, etc
- Se relacionan ambas estructuras con gramáticas bilingües
  - Reglas que indican como transformar LO en LM

## Por transferencia

- Proceso varía en cada sistema pero incluye
  - Análisis morfológico (POS tags)
  - Análisis sintáctico (parsing)
  - Transferencia léxica (diccionarios)
  - Transferencia estructural (gramáticas bilingües)
  - Síntesis (generación morfológica, reordenamiento, etc)

## Ejemplo: Systran



	A \$100 wrist-watch.
first xml representation	<pre>&lt;html&gt;&lt;hr&gt;A &lt;b&gt;\$100&lt;/b&gt; wrist-watch.&lt;/html&gt; &lt;?xml version="1.0"?&gt; &lt;document original format="html"&gt;&lt;tag&gt;&lt;lt;/hr&gt;&lt;/tag&gt;&lt;par id="1"&gt;A &lt;ts face="bold"&gt;\$100&lt;/ts&gt; wrist-watch.&lt;/par&gt; &lt;/document&gt;</pre>
tokenized text after entity recognition	<pre>[...] &lt;par id="1" xml:lang="en"&gt; &lt;token type="word" capit="first" id="t1"&gt;A&lt;/token&gt; &lt;ts face="bold"&gt;&lt;entity type="monval" id="t2"&gt;\$100&lt;/entity&gt;&lt;/ts&gt; &lt;token type="word" norm="wrist-watch" id="t3"&gt;wristwatch&lt;/token&gt; &lt;token type="punct" id="t4"&gt;.&lt;/token&gt; &lt;/par&gt; [...]</pre>
segmented translated text	<pre>[...] &lt;par id="1"&gt; &lt;tu group id="z1"&gt; &lt;tu xml:lang="en"&gt; &lt;token type="word" id="t1" capit="first"&gt;A&lt;/token&gt; &lt;ts face="bold"&gt;&lt;entity type="monval" id="t2"&gt;\$100&lt;/entity&gt;&lt;/ts&gt; &lt;token type="word" norm="wrist-watch" id="t3"&gt;wristwatch&lt;/token&gt; &lt;token type="punct" id="t4"&gt;.&lt;/token&gt; &lt;/tu&gt; &lt;translu xml:lang="fr"&gt; &lt;token id="t1" synt="pos=det"&gt;Une&lt;/token&gt; &lt;token type="word" type="noun" id="t3"&gt;montre-bracelet&lt;/token&gt; &lt;token type="det" id="t2"&gt;de&lt;/token&gt; &lt;ts face="bold"&gt;&lt;entity type="monval" id="t2"&gt;\$100&lt;/entity&gt;&lt;/ts&gt; &lt;token type="punct" id="t4"&gt;.&lt;/token&gt; &lt;/translu&gt; &lt;/tu group&gt; &lt;/par&gt; [...]</pre>
output text	<pre>&lt;html&gt;&lt;hr&gt;Une montre-bracelet de &lt;b&gt;\$100&lt;/b&gt;.&lt;/html&gt; Une montre-bracelet de \$100.</pre>

## Análisis del modelo

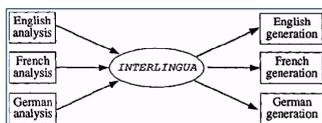
- Ventajas
  - Análisis más profundo que permite solucionar orden de palabras o constituyentes
- Desventajas
  - Es costoso si hay muchos pares de lenguas
    - Específicamente  $n$  analizadores LO,  $n$  generadores LM y  $n * (n - 1)$  módulos de transferencia
  - Reglas generalmente escritas a mano → se necesita un lingüista para esta tarea

## Modelo interlingua

- Se analiza el texto LO y se crea un **representación abstracta** del mismo
  - Interlingua o idioma pivote = lenguaje artificial neutro para cualquier idioma
- Interlingua contiene toda la información necesaria para **generar** texto en LM sin referirse a LO (proyección)
- Cada módulo de **análisis** puede ser **independiente** de módulos de **generación** y de otros módulos de análisis

## Modelo interlingua

- Interlingua permite traducir de un idioma a si mismo → "back-translation"
  - Usado durante el desarrollo para testear análisis y generación
- Agregar módulos de aumenta exponencialmente el nro de pares tratados



## Ejemplo de interlingua

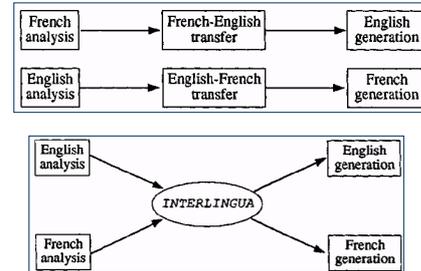
- Representación para "Does coffee give you headaches?"
- Quasi Logical Form vs. interlingua alternativa simplificada

```
[dcl,
form (verb (present, no, no, no, yes), E,
[ [give],
E,
term (q (bare, sing), X,
[coffee], X))
term (ref (pro, you, sing), Y,
[person, Y]),
term (q (bare, plur), Z,
[headache], Z)]]]]
[ [utterance_type, ynq],
[action, give],
[cause, coffee],
[pronoun, you],
[symptom, headache],
[tense, present], [voice, active]]
```

## Análisis del modelo

- Ventajas
  - Eficiente para el desarrollo de sistemas multilingües
  - Se podrían capturar diferencias sintácticas
    - The bottle floated into the cave → La botella entró a la cueva flotando (→ the bottle entered in the cave floating)
- Desventajas
  - Creación interlingua es muy difícil
  - Interlingua sigue siendo una representación en texto

## Transferencia vs Interlingua



- Cap 4 Hutchins & Somers

## La próxima clase

- Será sobre TA basada en ejemplos (example-based), estadística y traducción del habla
- Lectura pre-clase, con (\*) alcanzaría
  - "Example-Based Machine Translation: A New Paradigm" [Kit et al 2000]
  - (\*) "Towards a definition of example-based machine translation" [Hutchins 2005]
  - (\* pags 1 a 4) "A Statistical MT Tutorial Workbook" [Knight 1999]
  - "The mathematics of SMT: parameter estimation" [Brown et al 1993]

## Bibliografía

- 1) An introduction to machine translation- Hutchins&Somers
- 2) Machine translation: An introductory guide – Arnold et al
- 3) Carbonell, J. G. and Tomita, M., "New Approaches to Machine Translation,"
- 4) User-Friendly Text Prediction for Translators – Foster et al 2002
- 5) "Current strategies in machine translation research and development", Tucker 1987
- 6) A Framework Of A Mechanical Translation Between Japanese And English By Analogy Principle – Nagao 1984
- 7) The Mathematics of Statistical Machine Translation: Parameter Estimation [Brown et al 1993]
- 8) A Statistical MT Tutorial Workbook, Kevin Knight, 1999
- 9) The CMU TransTac 2007: Eyes-free and Hands-free Two-way Speech-to-Speech Translation System, Bach et al 2007
- 10) Performance Evaluation of Speech Translation Systems – Weiss et al 2008
- 11) Recursos para TA <http://www.computing.dcu.ie/~mforcada/fosmt.html>