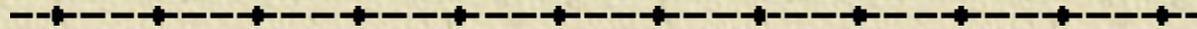


# Manejo de Corpus 101



Heidi Johnson

El Archivo de los Idiomas Indígenas de  
Latinoamérica (AILLA)  
Universidad de Texas en Austin



# Definiciones

---

- ✦ **Archivo de preservación:** un repositorio fidedigno creado y mantenido por una institución con un *compromiso a permanencia demostrado* y un compromiso a la preservación sobre lo largo de los recursos archivados.
- ✦ **Archivo local o centro de lenguas:** un repositorio donde crean o admiten recursos y donde proveen acceso a recursos a una comunidad particular. No se preocupan de preservación sobre lo largo.
- ✦ **Corpus de documentación de lenguas:** la colección de materiales documental creada por investigadores y hablantes naturales.

# Lo que se debe archivar - I

---

## ✦ Grabaciones, ambas audio y video:

- ✦ eventos públicos: ceremonias, discursos...
- ✦ narrativas: históricas, tradicionales, mitos...
- ✦ sesiones de elicitación
- ✦ instrucciones: como construir una casa, como tejer un petate, como pescar, ...
- ✦ literatura: oral o escrita – obras creativas
- ✦ conversaciones: si no son tan personales

# Lo que se debe archivar - II

---

## ✦ Textos y más (manuscrito o digital):

- transcripciones, traducciones, & anotaciones
- comentarios
- notas del campo
- listas para elicitación, ortografías
- juegos de datos, bases de datos, hojas de cálculo
- esbozos, e.g. gramáticos, etnografías

## ✦ Fotografías

## ✦ Tesis, artículos no-publicados, memorias...

# Lo que se debe archivar - III

---

## ✦ Materiales para enseñanza y aprendizaje:

- ◆ lecciones elemental
- ◆ calendarios, carteles, etc.
- ◆ diccionarios ilustrados, enciclopedias
- ◆ diseños de curriculum
- ◆ cualquiera cosa que otra gente encontrarían útil o de inspiración en sus propios programas.

# Lo que NO se debe archivar

---

- ✦ Cualquiera cosa que puede hacer daño o dar vergüenza á los hablantes.
  - ◆ pero estas pueden ser archivadas con una fecha límite de 50 – 100 años.
- ✦ Obras sagradas con usos muy restringidos.
  - ◆ estas pueden ser archivadas si el acceso es controlado por miembros de la comunidad que tienen autoridad apropiada.

# Cuando se debe archivar?

---

- ✦ Lo más pronto que sea posible:
  - ◆ a prevenir daño accidental o pérdida;
  - ◆ a recobrar formatos útiles de presentación.
- ✦ Se puede restringir acceso a obras en curso.
- ✦ Se puede añadir transcripciones, etc. más tarde.

# Porqué se debe archivar? I

---

- ✦ preservar grabaciones de lenguas en peligro/de minoridad para las generaciones que vienen.
- ✦ facilitar el re-uso de materiales para:
  - ◆ programas para el mantenimiento y revitalización de lenguas;
  - ◆ estudios de tipología, historia, etc;
  - ◆ cualquiera clase de estudio – lingüístico, antropológico, psicológico – que Ud. no hace.

# Porqué se debe archivar? II

---

- ✦ fomentar el desarrollamiento de literaturas, ambas orales y escritas, para lenguas en peligro.
- ✦ hacer saber que documentación existe para cuales lenguajes.
- ✦ aumentar su CV aún antes de que esté listo a publicar resultados.

# Archivar puede ser una forma de publicar

- 
- ✦ Aunque los recursos sean restringidos, los metadatos son publicados.
  - ✦ Liste Recursos Archivados en su CV para ganar reconocimiento para su trabajo.
  - ✦ Reconozca á los creadores del obra:

Sánchez Morales, Germán. (1994). "Satornino y los soldados." [audio] Heidi Johnson, (Researcher.) [online] ZOH001R010. Access=public.  
<http://www.ailla.utexas.org>: Archive of the Indigenous Languages of Latin America.

# Como construir un corpus listo para archivar - I

- 
- ✦ Regla #1: Marque cada cosita que produce con una **COHERENCIA DESPIEDADADA**. Si no sabemos que es, no lo podemos archivar.
  - ✦ Regla #2: Contacte sus archivistas amistosos y pidanos que le ayudamos.
  - ✦ Regla #3: Pruebe su sistema antes de salir: aparatos, modo de catalogar, etiquetas.

# Como construir un corpus listo para archivar - II

- 
- ✦ Defina un sistema al respecto a los derechos y desarrolle una práctica consistente para obtener el consentimiento, e.g., formularios y/o declaraciones grabadas.
  - ✦ Siempre pida permiso para todo:
    - grabación
    - archivación
    - extracción, publicación, etc.
  - ✦ Habla de quien puede / no puede leer/oir/ver las obras.
  - ✦ Aprenda como hablar con sus consultantes sobre derechos: visite a la Escuela de Prácticas Mejoras en <http://emeld.org/school/classroom/ethics/index.html>

# Etiquetar I : grabaciones

---

- ✦ Audio - grabe una “cabecera” con informaciones básicas, en una lengua de contacto – inglés, español, portugués...

*“Hoy, el 28 de octubre 2005, estamos en San Miguel Chimalapa, Oaxaca, en la casa de Sr. Germán Sánchez Morales. Sr. Sánchez nos va a contar la historia de Juan Flojo en zoque.”*

- ✦ Video – hagalo en el estilo Hollywood: use una tabla con la info escrita. O parate enfrente de la camera y platica la cabecera.
- ✦ Metadatos grabados así no se pierden nunca.

# Etiquetar II: media y archivos

---

✦ Decida el tema fundamental para organizar su sistema de etiquetas:

- ◆ media, e.g. CD1, cuaderno A
- ◆ nombres o iniciales de consultantes
- ◆ lenguas/dialectos (use el código de 3 letras)
- ◆ nombres o iniciales de lingüistas
- ◆ géneros, e.g. lexicas, narrativos, ...

# Etiquetar III: ítemes relacionados

---

Materiales de la documentación de lenguas típicamente viene en *juegos* relacionados:

- ✦ grabación de una historia + texto interlinear + traducción repasada + comentario
- ✦ entrevista + fotografías
- ✦ sesión de elicitación grabada + notas del campo
- ✦ grabaciones simultáneas de audio y video

# Etiquetar IV: clases de relaciones

---

- ✦ derivación: una transcripción se deriva de una grabación
- ✦ serie: una grabación larga que ocupa varias media (cds solamente guardan 650 mb  $\approx$  60 mins)
- ✦ parte-entero: grabaciones en video y audio hechas simultaneamente del mismo evento
- ✦ asociación: (borrosa) fotografías, comentarios

# Etiquetar V: AILLA IDs

---

✦ ZOH001R040I001.mp3

- ✦ ZOH = código del idioma
- ✦ 001 = número del depósito (el primero)
- ✦ R040 = recurso (juego) 40 en ese depósito
- ✦ I001 = primer ítem (archivo) en ese recurso
- ✦ .mp3 = que clase de archivo

✦ Apoya nuestra sistema administrativa: archivamos muchas lenguas, hacemos un depósito a la vez...

# Etiquetar VI: nombres enormes

-----  
Facilita relacionar archivos digitales en un disco duro. (Cortesía de Tony Woodbury.)

- ✦ SJQ-2007\_09\_11-Txt\_ec-acw-1.wav
- ✦ SJQ-2007\_09\_11-Txt\_ec-acw-2.wav
- ✦ SJQ-2007\_09\_11-Txt\_ec-acw.eaf
- ✦ SJQ-2007\_09\_11-Txt\_ec-acw.jpg

# Nombres enormes II

- 
- ✦ SJQ: Chatino de San Juan Quiahije (lugar y lengua en un golpe)
  - ✦ 2007\_09\_11: fecha de grabación en formato ISO AAAA-MM-DD
  - ✦ Txt: clase de discurso en este proyecto.
  - ✦ ec: narrador/consultante
  - ✦ acw: investigador
  - ✦ 1: número en una serie
  - ✦ .wav: tipo de archivo



# Nombres enormes IV

---

## ✦ Ventajas:

- ✦ incluyen los metadatos esenciales
- ✦ facilitan ordenación, identificación
- ✦ fácil mantener cosas relacionadas juntas, por medio del extensión del archivo (.wav, .eaf)

## ✦ Desventajas:

- ✦ largo para teclear! (pero cortas y pegas)
- ✦ más difícil relacionar cosas no-digitales, como cuadernos (pero no tanto)

# Catálogo del corpus / Metadata I

---

✦ Información catálogo para recursos digitales se llama *metadata*.

✦ Metadata apoya:

- ✦ guardando ítemes relacionados juntos
- ✦ protección de materiales sensibles
- ✦ buscando para la cosa que quiere
- ✦ el uso de recursos por otra gente
- ✦ citación apropiada de recursos archivados

# Metadata II : Info mínima

- 
- ✦ Nombres completos de todos los creadores: Ud. y los hablantes.
  - ✦ Lenguaje: sea específico y/o use el código.
  - ✦ Fecha de creación: AAAA-MM-DD.
  - ✦ Lugar de creación: sea específico.
  - ✦ Restricciones del acceso, instrucciones particulares sobre usos futuros.
  - ✦ Palabra clave del género, e.g. narrativa.

# Metadata III : Info adicional

---

- ✦ Depositante: info de contacto
- ✦ Proyecto: nombre, director, fundador, etc.
- ✦ Papeles de las participantes (e.g. hablador, investigador), edad, sexo, papel comunitario
- ✦ Los media: aparatos, formatos, fuentes
- ✦ Contenidos: descripciones del contexto de grabación, del sujeto – lo mas detalle, lo mejor.
- ✦ Citaciones: publicaciones pertinentes

# Herramientas para el manejo de corpus

---

IMDI Browser & IMDI Data entry

(<http://www.mpi.nl/IMDI>)

AILLA's Shoebox 2.0 & 5.0 templates

([http://www.ailla.utexas.org/site/download\\_md\\_forms\\_sp.html](http://www.ailla.utexas.org/site/download_md_forms_sp.html))

- ✦ Cualquier base de datos, hoja de cálculo, templatote de Word doc...
- ✦ Una carpeta de hojas sueltas con un formulario copiado.

# Sitios útiles

---

- ✦ AILLA: <http://www.ailla.utexas.org/>
- ✦ DELAMAN: <http://www.delaman.org/>
- ✦ IMDI: <http://www.mpi.nl/ISLE>
- ✦ OLAC: [http://www.language\\_archives.org](http://www.language_archives.org)
- ✦ EMELD:  
<http://emeld.org/school/index.html>
- ✦ Escribame: [ailla@ailla.utexas.org](mailto:ailla@ailla.utexas.org)