

Automatic transcriptions of folklore audio recordings

Trausti Dagsson, Rósa Þorsteinsdóttir, Finnur Ágúst
Ingimundarson (The Árni Magnusson Institute for Icelandic Studies)
Luke O'Brien (Tiro)



Ísmús

- Digitized audio archive
- The Árni Magnússon Institute for Icelandic Studies
- More than 2000 hours
- Mostly collected 1960 - 1980

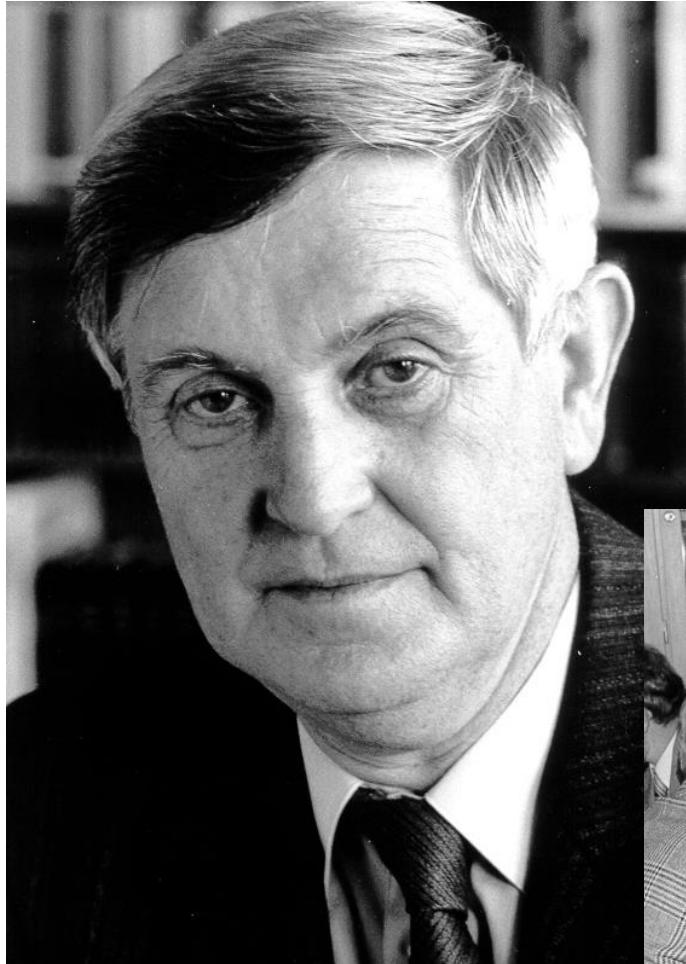


Main collectors

Hallfreður Örn Eiríksson (1932-2005)

Helga Jóhannsdóttir (1935-2006)

Jón Samsonarson (1931-2010)



2700 informants



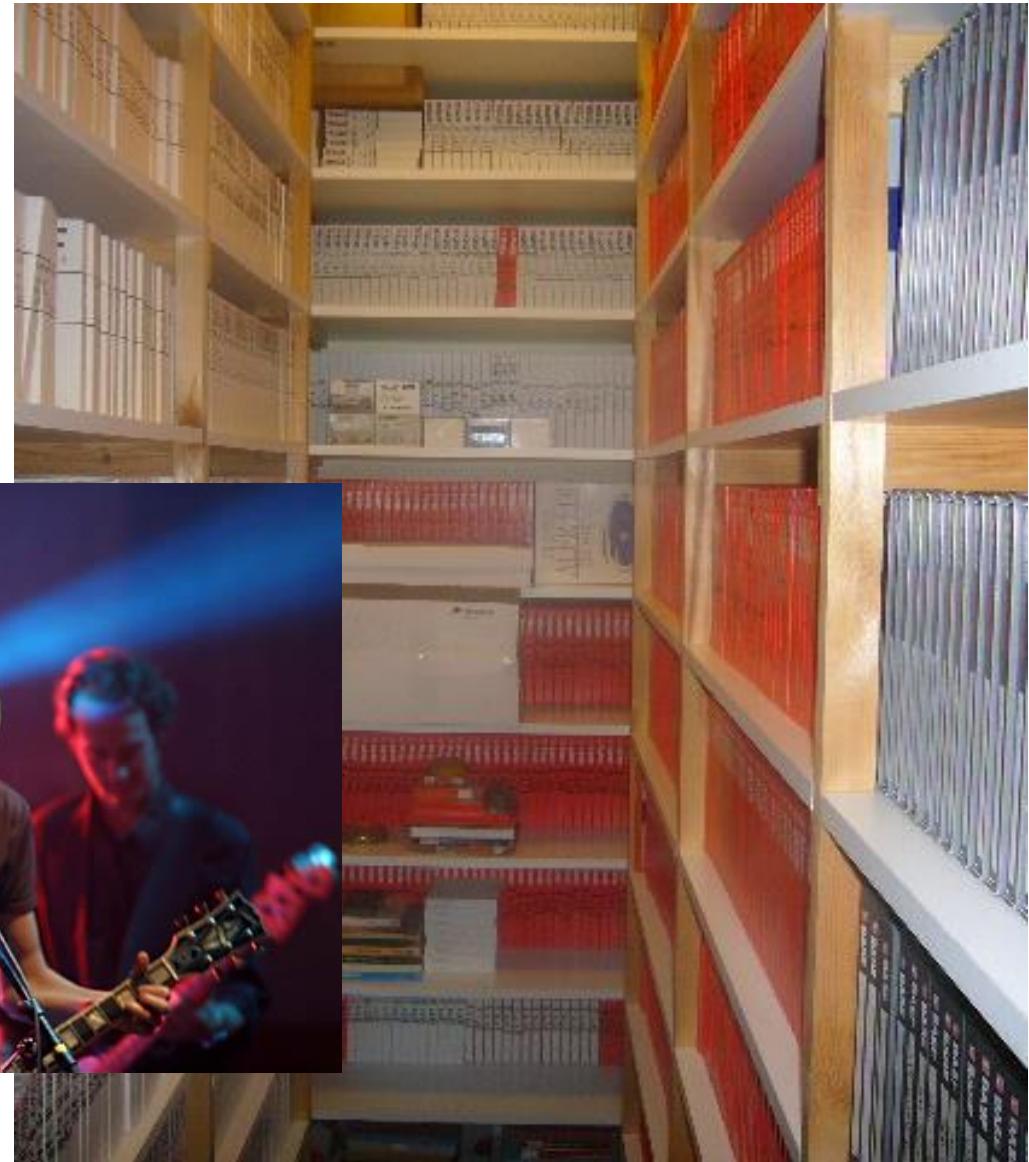
Ísmús

- Folklore and musicology platform
 - Ethnographic interviews
 - Legends database
 - Fairy tales
 - Letter collections
 - Musicology
 - and more...
- www.ismus.is



Ísmús

- Personal connections
- Artistic inspiration



Ísmús | Forsíða

ismus.is

ÍSMÚS

ÍSLENSKUR MÚSÍK- & MENNINGARAFUR

Forsíða Tónlist Þjóðfræði Um Ísmús Handraðinn

Leit

Tónlist

Um 1996 hófust tilraunir til að nýta tölву- og upplýsingatækni til að halda utan um og miðla íslenskri tónmenningu. Byrjað var á nótum í miðaldahandritum og síðan pappírshandritum fram á 19. öld. Um aldamótin bættust við elstu hljóðrit af vaxhólkum og þjóðfræðihljóðritanir Árnastofnunar sem sumar innihalda tónlistarefni. Orgel og tónmenning í kirkjum landsins var skrásett og þannig áfram. Tónlistarsafn Íslands varð til 2009 og tók við þessu starfi. Nú er svo komið að Ísmús er orðið einstakt tæki sem opnar sambætta gátt að tónmenningu Íslands fyrir og nú. Markmið til framtíðar er að auka og bæta upplýsinga- og freðslugildi verkefnisins eins og frekast er kostur.

Kirkjur Hljóðfærir Tónlistarfólk Hljómsveitir Viðburðir Meira

þjóðfræði

þjóðfræðisafn Stofnunar Árna Magnússonar í íslenskum fræðum inniheldur hljóðrit sem safnað hefur verið af starfsmönnum stofnunarinnar. Söfnunin fór fram á seinni hluta 20. aldar um alt land og í íslendingabýggðum vestan hafs. Þar er einnig að finna afrit af elstu íslensku hljóðritum sem varðveislt hafa frá upphafi 20. aldar og ýmis minni söfn sem stofnuninni hafa verið afhent til varðveislu. Í Sagnagrunni og Ævintýragrunni eru skráðar sagnir og ævintýri sem hafa verið prentuð í ýmsum þjóðsagnasöfnum.

Hljóðrit Sagnagrunnur Ævintýragrunnur Þjóðfræðileit Meira

Um Ísmús

Ísmús – íslenskur músík- og menningarafur – er gagnagrunnur sem geymir og birtir á vefnum gögn er varða íslenska menningu fyrir og nú: hljóðrit, þjóðsögur, ljósmyndir, kvíkmyndir, handrit og texta. Verkefnið er í umsjá Landsbókasafns Íslands – Háskolabókasafns og Stofnunar Árna Magnússonar í íslenskum fræðum.

Nánar

Fólk

Nöfn fólks sem skráð er í gagnagrunninum. Þetta getur verið heimildarmaður eða flytjandi (sá sem talað er við, segir frá, kveður, syngur eða flytur efni á annan hátt); spyrill eða upptökumaður. Á listanum er einnig tónlistarfólk og höfundar kvæða, vísna, rímnna og sálma og fólk sem tengist kirkjum, svo sem prestar, organistar og forsöngvarar.

Nánar

Staðir

Skráðir eru allir staðir sem koma fyrir sem upptökustaðir og sem fæðingarstaðir og heimili einstaklinga í gagnagrunninum. Á listanum eru bæjarnöfn, heimilisföng og hús, en einnig heiti heilla sveita og byggðarlaga, sýsla, borga og landa. Hér eru einnig skráðar kirkjur, prestaköll og prófastsdæmi.

Nánar Kort



Digitized - post-digitization - what's next?

- Current limitations
 - Limited metadata
 - Keywords
 - Short description

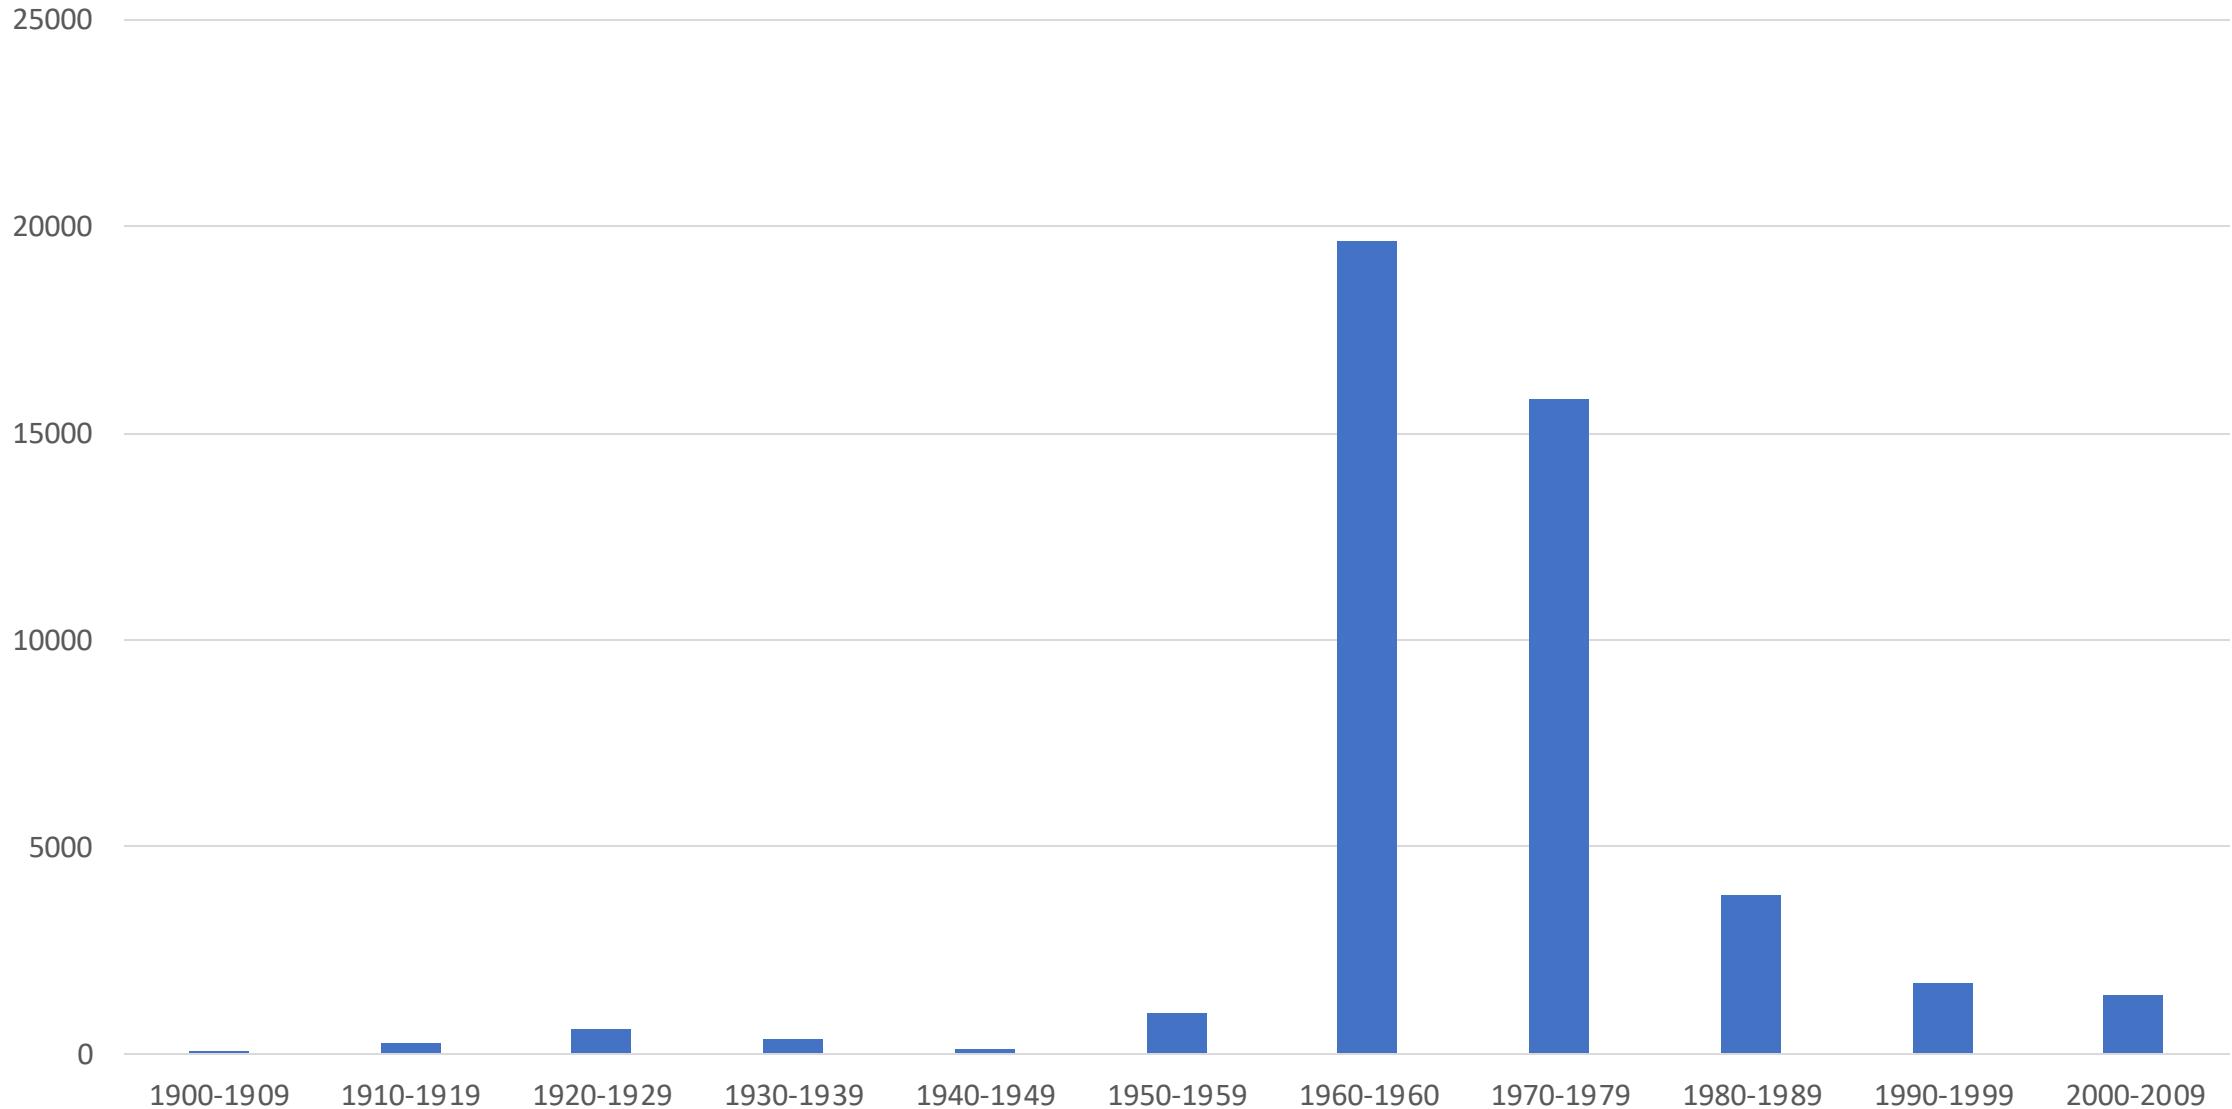


Automatic Transcriptions

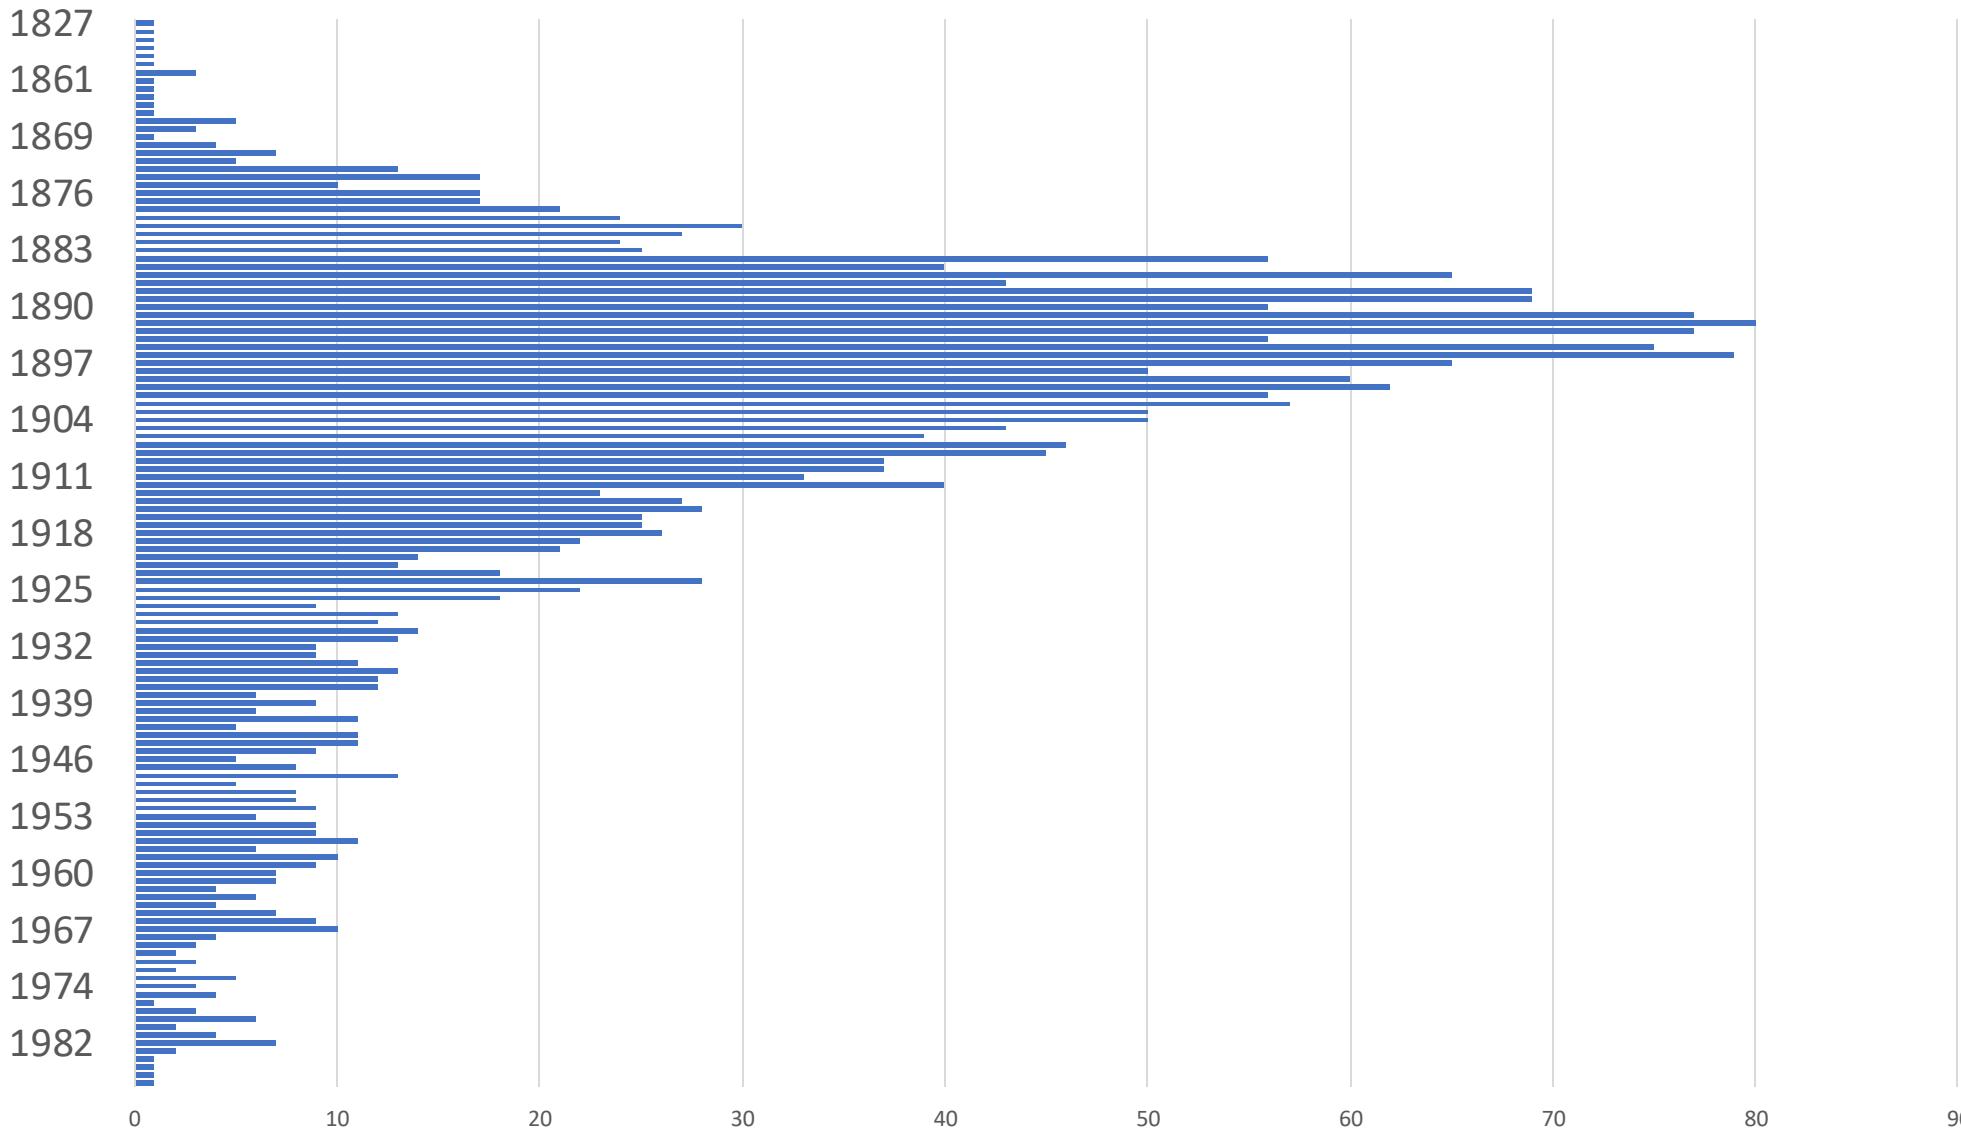
- The projects aim:
 - Train ASR system to automatically transcribe audio recordings from the Ethnology collection of Árnastofnun
 - Create a text corpus of speech data from the collection
- Funding from The Icelandic Center for Research (RANNÍS) through Centre for Digital Humanities and Arts
- Collaboration with technology company Tíró
- Participants:
 - Rósa Þorsteinsdóttir (The Árni Magnússon Institute for Icelandic Studies)
 - Trausti Dagsson (The Árni Magnússon Institute for Icelandic Studies)
 - Finnur Ingimundarson (The Árni Magnússon Institute for Icelandic Studies)
 - Luke O'Brien (Tíró)



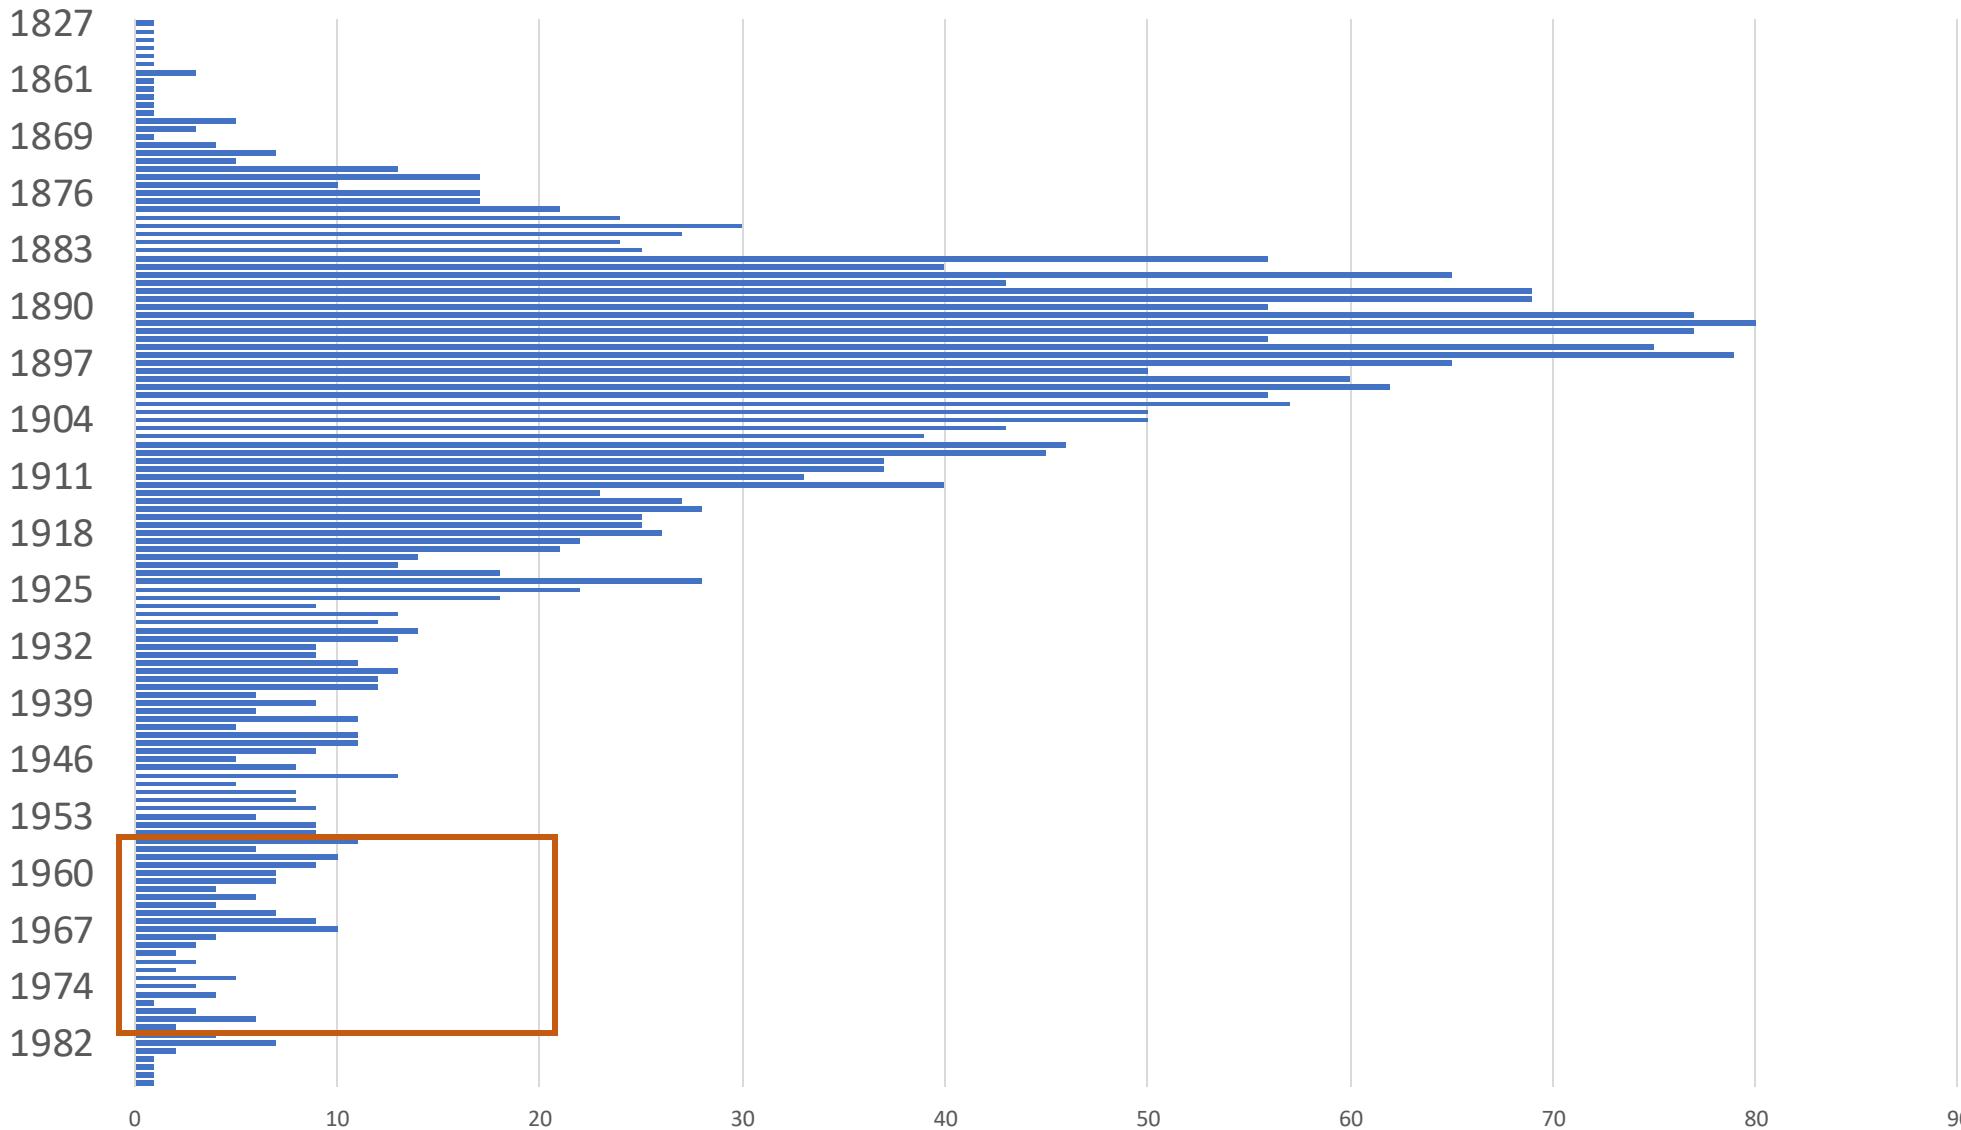
Years of Recording



Year of birth



Year of birth

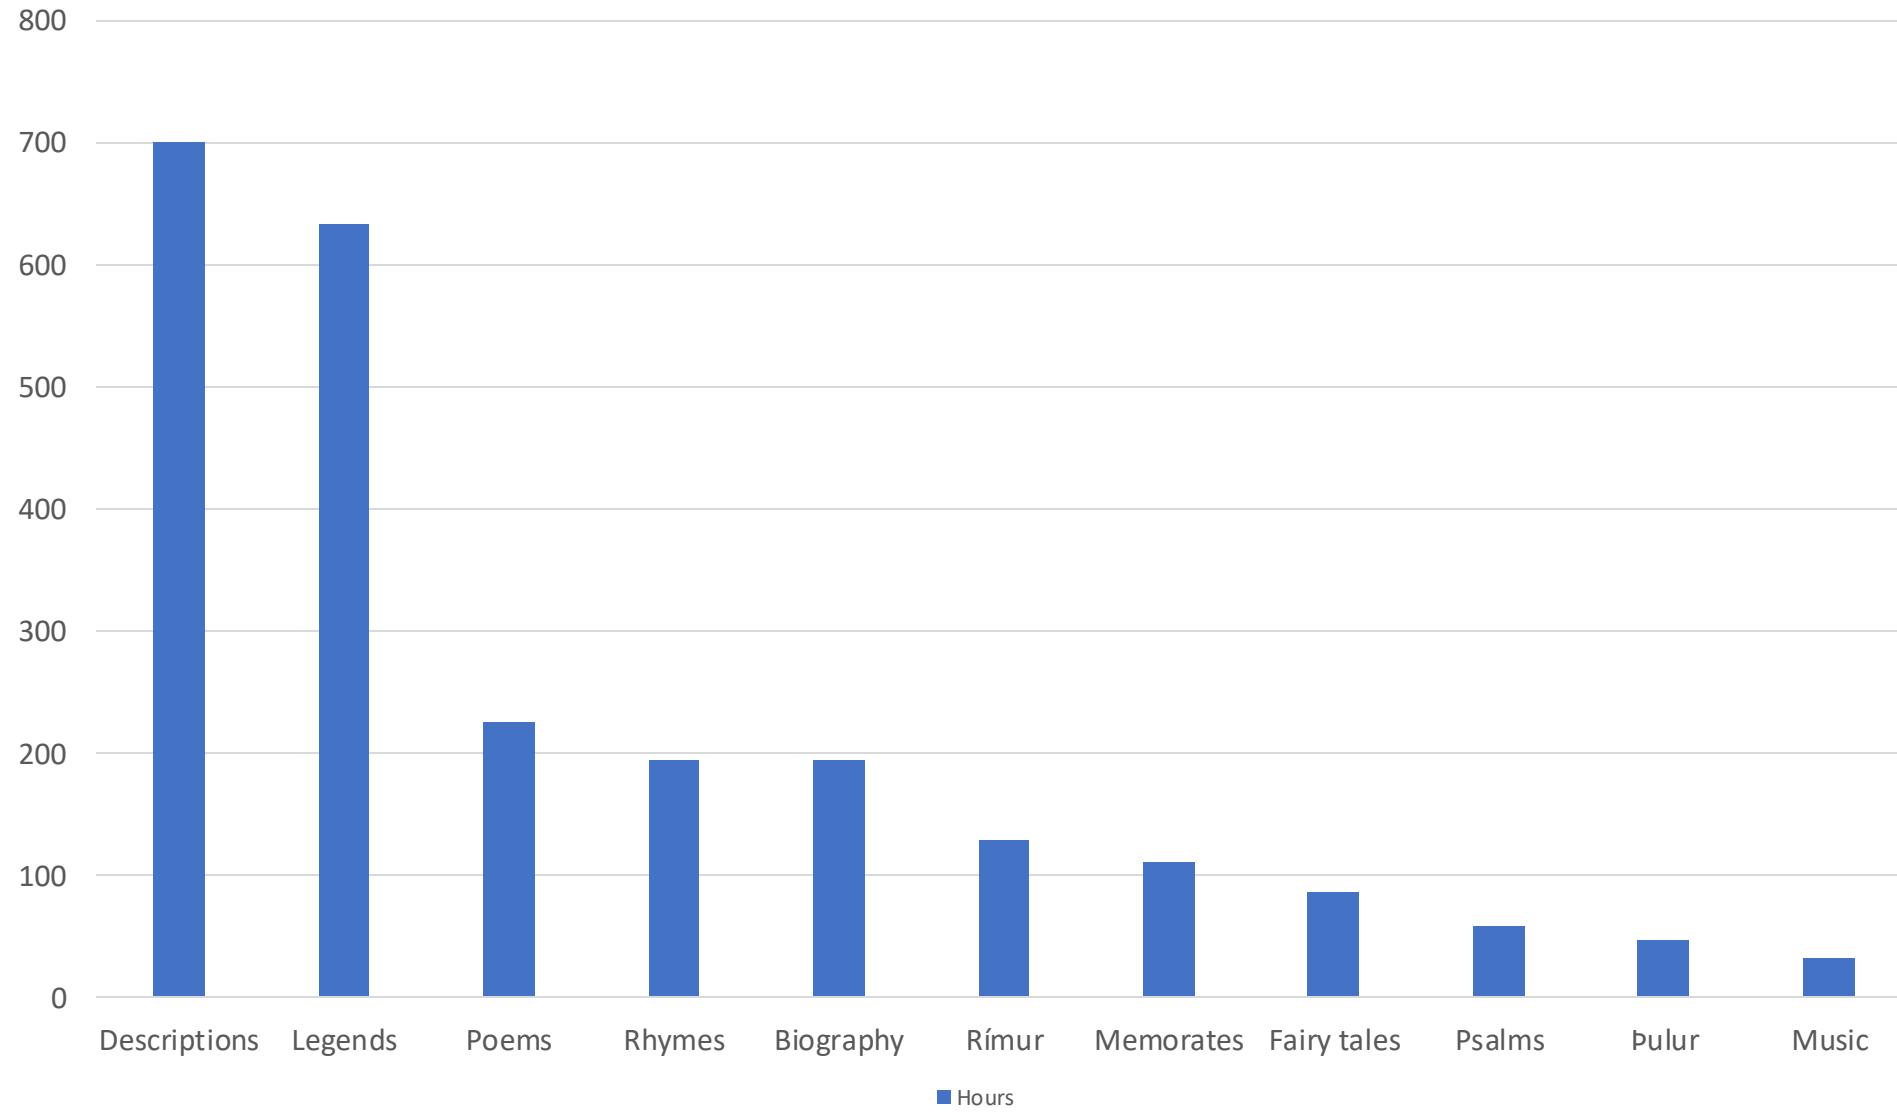


Gender of speakers

- 57% male
 - 1504 hours – 65%
- 42 % female
 - 821 hours – 35%



Genre



Preparation and Training

- Correction and time align of existing text data
- Training the model using neural network
- Testing and Correcting

1

00:00:00,000 --> 00:00:02,200

Jón M.:

2

00:00:02,200 --> 00:00:06,879

Nú en annars líkaði mér svona heldur vel í skóla.

3

00:00:07,089 --> 00:00:11,349

En ég var enginn námsmaður og hef aldrei verið



Models

- Acoustic Model
 - Relationship between audio and phonemes
 - TDNN (time-delayed neural network) chain model trained in Kaldi
 - Trained on:
 - Althingi's Parliamentary Speeches – corpus of 514 hours
 - 114 hours of speech from the first Samrómur release
 - 173 hours of unverified Samrómur data
 - 228 hours of dataset from RÚV (National Broadcast Company)



Models

- Language Model
 - N-gram language model
 - Trained on:
 - Corrected OCR data
 - The Icelandic Gigaword Corpus
 - Ethnographic data from the National Museum of Iceland
 - Audio file descriptions from Ísmús for their content
 - Place name data from the Icelandic Place Name Collection
 - Vocabulary data
 - The Database of Icelandic Morphology, etc.



The Results

- ~12.000.000 words
- Surprisingly good in most cases but sometimes surprisingly bad
- Still being evaluated

SÁM 84/91 EF

Sá ég hvar lifandi lá



SÁM 84/91 EF

00:55 | Spila hljóðskrá

Fella inn ...

Hlaða niður ↕

00:03 en dettur nú þarna inni þegar hún datt mér í huga mínum aftur sá ég hvar lifandi lá
00:11 þú skalt upp og undir mig ég skal upp og á þig það er hérna hjá mér sem í því þá var bara
00:23 það halda margir þetta sé annað en það ver en hvað er þetta
00:28 sá ég hvar lifandi lá það var hestur þú skalt upp og undir mig
00:36 það var það var kona þá hesturinn átti að standa upp
00:41 X ég skal upp og á því að hún ætlaði að setjast á hann það er hérna hjá mér sem þýðir þá að fara það var beislið
00:50 já 00:52 þú hefur heyrt um það þegar þú ert unglungum jájá



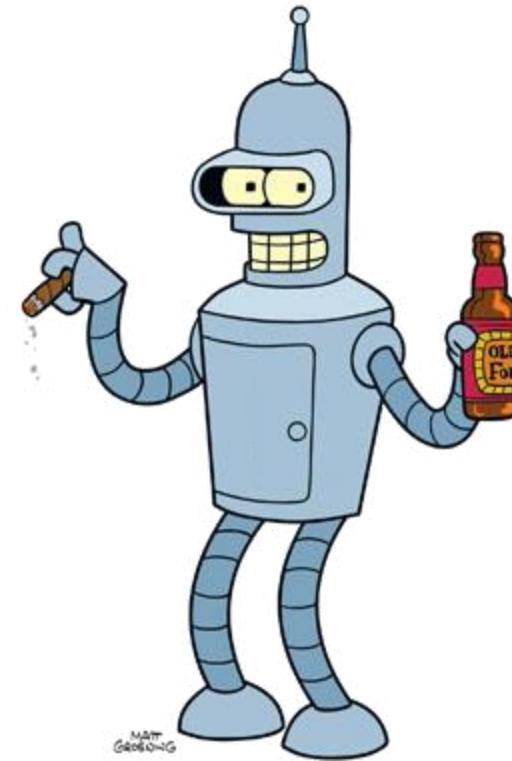
Challenges

- Poor audio quality
- Multiple speakers
- Not split into sentences
- "Já já, já já já" "ha?"
- Background noise
 - Children, spouses, clocks, telephones
- Uncertainty...



Challenges

- Poor audio quality
- Multiple speakers
- Not split into sentences
- "Já já, já já já" "ha?"
- Background noise
 - Children, spouses, clocks, telephones
- Uncertainty of the mindless robot



Usage

- Search functionality for Ísmús
 - Folklore search
 - Word distribution-based text linking
- Language research
 - Speech Text Corpus
- Usage of model for further transcriptions
 - E.g., RÚV (National Broadcast Company), National Library, etc.



Examples

- Narrative: [Elves \(huldufólk\)](#), Jenný Jónasdóttir (1904-1991)
- Fairy tale: [Steinunn Þorsteinsdóttir](#), (1887-1973)



Examples

- Singing: [Sjö sinnum það sagt er mér](#), Jón Stefánsson (1880-1971)
- Singing: Kom ég upp í Kvíslarskarð, [Tryggvi Sigtryggsson](#) (1894-1986)

